

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**NÖROLOJİK BOZUKLUKLARIN TRANSFER ÖĞRENME
TEMELLİ ANALİZİ**

YÜKSEK LİSANS TEZİ

MUSTAFA SUBAN DUT

DENİZLİ, ARALIK - 2024

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**



**NÖROLOJİK BOZUKLUKLARIN TRANSFER ÖĞRENME
TEMELLİ ANALİZİ**

YÜKSEK LİSANS TEZİ

MUSTAFA SUBAN DUT

DENİZLİ, ARALIK - 2024

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu alıřmanın dođrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan alıřmalara atfedildiđine beyan ederim.

Mustafa Suban DUT

ÖZET

NÖROLOJİK BOZUKLUKLARIN TRANSFER ÖĞRENME TEMELLİ ANALİZİ

YÜKSEK LİSANS TEZİ

MUSTAFA SUBAN DUT

PAMUKKALE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

(TEZ DANIŞMANI: DOÇ. DR. MERİÇ ÇETİN)

DENİZLİ, ARALIK - 2024

Nörolojik hastalıklar, insan hayatını önemli ölçüde etkileyen ve genellikle ilerleyici özelliklere sahip hastalıklardır. Bu hastalıklar, kişinin motor ve bilişsel işlevlerinde kayıplara neden olarak yaşam kalitesini düşürmekte ve günlük aktivitelerini kısıtlamaktadır. Özellikle Alzheimer, Multipl Skleroz (MS) ve beyin tümörleri gibi nörolojik hastalıklar, erken teşhis edilmediğinde tedavi şansı azalmaktadır. Bu bağlamda, tanı ve erken teşhis için gelişmiş teknolojilere olan ihtiyaç artmaktadır. Bu tezde, nörolojik bozuklukların analizi ve sınıflandırılması için transfer öğrenme temelli yaklaşımların uygulanabilirliği incelenmiştir. Bu amaçla, bu tez çalışması için önerilen bir Evrişimli Sinir Ağı (Convolutional Neural Networks-CNN) modelinin sınıflandırma performansı, VGG16, ResNet50, InceptionV3 ve Görüntü Transformatörü (Vision Transformer-ViT) gibi ön eğitilmiş TL modellerinin performansları ile karşılaştırılmıştır. Tasarlanan modeller, MS-2, Br35h, MS-3, Alzheimer ve beyin tümörü veri kümeleri üzerinde eğitilmiştir. Elde edilen sonuçlar, her bir modelin farklı veri kümeleri üzerindeki başarımlarının kıyaslanması yoluyla analiz edilmiştir. Önerilen CNN modeli, MS-2, Br35h ve MS-3 sınıflandırmalarında VGG16 ve InceptionV3 gibi güçlü modellerle karşılaştırıldığında neredeyse aynı doğruluk seviyelerine ulaşmıştır. Ayrıca sonuçlar, TL yöntemlerinin nörolojik hastalıkların tanı ve teşhisinde özellik çıkarımı uygulanarak potansiyel olarak yüksek doğruluk oranları sunduğunu göstermektedir. Bu da, transfer öğrenmenin, sınırlı veri setleriyle çalışılsa dahi güçlü bir çözüm sunabileceğini ve tıbbi teşhis süreçlerinde önemli bir katkı sağlayabileceğini ortaya koymaktadır.

ANAHTAR KELİMELER: Yapay Zeka, Derin Öğrenme, Transfer Öğrenme, Evrişimli Sinir Ağları, Görüntü Transformatörleri

ABSTRACT

TRANSFER LEARNING BASED ANALYSIS OF NEUROLOGICAL DISORDERS

MSC THESIS

MUSTAFA SUBAN DUT

PAMUKKALE UNIVERSITY INSTITUTE OF SCIENCE

COMPUTER ENGINEERING

(SUPERVISOR:ASSOC. PROF. DR. MERİÇ ÇETİN)

DENİZLİ, DECEMBER 2024

Neurological disorders are diseases that significantly affect human life and are generally progressive. These disorders reduce the quality of life and limit daily activities by causing losses in the motor and cognitive functions of the person. Especially neurological diseases such as Alzheimer, Multiple Sclerosis (MS) and brain tumors, when not diagnosed early, the chance of treatment decreases. In this context, the need for advanced technologies for diagnosis and early detection is increasing. In this thesis, the applicability of transfer learning-based approaches for the analysis and classification of neurological disorders is investigated. For this purpose, the classification performance of a proposed Convolutional Neural Network (CNN) model for this thesis is compared with the performances of pre-trained TL models such as VGG16, ResNet50, InceptionV3 and Vision Transformer (ViT). The designed models are trained on MS-2, Br35h, MS-3, Alzheimer and brain tumor datasets. The obtained results are analyzed by comparing the performance parameters of each model on different datasets. The proposed CNN model has achieved almost the same accuracy values in MS-2, Br35h and MS-3 classifications when compared to powerful models such as VGG16 and InceptionV3. In addition, the results show that TL methods offer potentially high accuracy rates by applying feature extraction in the diagnosis and prognosis of neurological diseases. This shows that transfer learning can provide a powerful solution even when working with limited datasets and can make a significant contribution to medical diagnosis processes.

KEYWORDS: Artificial Intelligence, Deep Learning, Transfer Learning, Convolutional Neural Networks, Image Transformers

İÇİNDEKİLER

Sayfa

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
TABLO LİSTESİ	vi
KISALTMALAR LİSTESİ	vii
ÖNSÖZ	viii
1. GİRİŞ	1
1.1 Tezin Amacı	1
1.2 Tezin Önemi	2
1.3 Tezin Akışı	3
2. NÖROLOJİK BOZUKLUKLAR	4
2.1 Nörolojik Bozukluklar Nedir?.....	4
2.2 Nörolojik Hastalıklar	6
2.2.1 Alzheimer Hastalığı	6
2.2.2 Demans	7
2.2.3 Multipl Skleroz	7
2.2.4 Beyin Tümörleri.....	7
2.2.5 Epilepsi	8
2.2.6 Parkinson Hastalığı	8
2.3 Nörolojik Bozukluklarda Tanı ve Erken Teşhis.....	8
2.3.1 Klinik Değerlendirme ve Nörolojik Muayene	9
2.3.2 Görüntüleme Teknikleri ve Elektrofizyolojik Testler	9
2.3.3 Laboratuvar Testleri.....	9
2.3.4 Erken Teşhis ve Makine Öğrenimi	9
3. LİTERATÜR TARAMASI	12
3.1 Problem Tanımı	12
3.2 Literatür Özeti	13
4. MATERYAL VE YÖNTEM	16
4.1 Makine Öğrenimi Yöntemleri	16
4.1.1 Denetimli Öğrenme.....	16
4.1.2 Denetimsiz Öğrenme	17
4.1.3 Yarı Denetimli Öğrenme	17
4.2 Derin Öğrenme Yöntemleri.....	18
4.2.1 Evrişimli Sinir Ağları.....	18
4.2.1.1 Önerilen CNN Modeli.....	21
4.2.2 Transfer Öğrenme	24
4.2.3 Görüntü Transformatörleri.....	25
4.3 Veri Ön İşleme Süreçleri	28
4.3.1 Veri Artırımı	28
4.3.2 Veri Normalizasyonu	29
4.3.3 Eğitim ve Doğrulama Verisi Ayrımı	29
4.3.4 Sınıf Dengeleme	29

4.4	Değerlendirme Metrikleri	30
4.5	Hiperparametre Optimizasyonları	31
4.5.1	Öğrenme Oranı	31
4.5.2	Dönem Sayısı	31
4.5.3	Mini-Batch Boyutu	32
4.5.4	Optimizasyon Algoritması	32
4.5.5	Sönümlenme Oranı	33
4.5.6	Aktivasyon Fonksiyonları	33
4.5.7	Batch Normalizasyonu	33
4.6	Veri Kümeleri	33
4.6.1	MS-2 Veri Kümesi	34
4.6.2	Br35h Veri Kümesi	34
4.6.3	MS-3 Veri Kümesi	35
4.6.4	Alzheimer Veri Kümesi	36
4.6.5	Tümör Veri Kümesi	37
5.	UYGULAMA SONUÇLARI	38
5.1	Önerilen CNN Modeli Sınıflandırma Sonuçları	38
5.1.1	MS-2 Veri Kümesi için Sınıflandırma Sonuçları	38
5.1.2	Br35h Veri Kümesi için Sınıflandırma Sonuçları	40
5.1.3	MS-3 Veri Kümesi için Sınıflandırma Sonuçları	41
5.1.4	Alzheimer Veri Kümesi için Sınıflandırma Sonuçları	43
5.1.5	Tümör Veri Kümesi için Sınıflandırma Sonuçları	45
5.2	Transfer Öğrenme Kullanan Ön Eğitimli CNN Modelleri için Sınıflandırma Sonuçları	47
5.2.1	MS-2 Veri Kümesi için Ön Eğitimli CNN Modellerine Ait Sınıflandırma Sonuçları	47
5.2.2	Br35h Veri Kümesi için Ön Eğitimli CNN Modellerine Ait Sınıflandırma Sonuçları	48
5.2.3	MS-3 Veri Kümesi için Ön Eğitimli CNN Modellerine Ait Sınıflandırma Sonuçları	49
5.2.4	Alzheimer Veri Kümesi için Ön Eğitimli CNN Modellerine Ait Sınıflandırma Sonuçları	50
5.2.5	Tümör Veri Kümesi için Ön Eğitimli CNN Modellerine Ait Sınıflandırma Sonuçları	51
5.3	Transfer Öğrenme Kullanan Ön Eğitimli CNN Modelleri için İnce Ayar Sınıflandırma Sonuçları	52
5.3.1	MS-2 Veri Kümesi için İnce Ayar Sınıflandırma Sonuçları	53
5.3.2	Br35h Veri Kümesi için İnce Ayar Sınıflandırma Sonuçları	54
5.3.3	MS-3 Veri Kümesi için İnce Ayar Sınıflandırma Sonuçları	54
5.3.4	Alzheimer Veri Kümesi için İnce Ayar Sınıflandırma Sonuçları	55
5.3.5	Tümör Veri Kümesi için İnce Ayar Sınıflandırma Sonuçları	56
6.	SONUÇ VE DEĞERLENDİRME	57
7.	KAYNAKLAR	60
8.	ÖZGEÇMİŞ	66

ŞEKİL LİSTESİ

Sayfa

Şekil 4.1: Denetimli öğrenme mimarisi örneği.....	16
Şekil 4.2: Denetimsiz öğrenme mimarisi örneği	17
Şekil 4.3: Yarı denetimli öğrenme mimarisi örneği	18
Şekil 4.4: CNN mimari örneği.....	19
Şekil 4.5: Ön eğitilmiş ResNet50 mimarisi örneği	19
Şekil 4.6: Ön eğitilmiş InceptionV3 mimarisi örneği	20
Şekil 4.7: Ön eğitilmiş VGG16 mimarisi örneği.....	21
Şekil 4.8: Önerilen CNN modelinin yapısı.....	23
Şekil 4.9: Transfer öğrenme şema görünümü.....	25
Şekil 4.10: Görsel transformatör mimarisi	26
Şekil 4.11: Görsel transformatör – dikkat mekanizması	27
Şekil 4.12: Veri artırma örnekleri.....	28
Şekil 4.13: Öğrenme ve test hatası grafiği üzerinde doğru noktanın belirlenmesi	32
Şekil 4.14: MS-2 veri kümesi sınıf dağılımı.....	34
Şekil 4.15: Br35h veri kümesi sınıf dağılımı.....	35
Şekil 4.16: MS-3 veri kümesi sınıf dağılımı.....	36
Şekil 4.17: Alzheimer veri kümesi sınıf dağılımı.....	36
Şekil 4.18: Tümör veri kümesi sınıf dağılımı.....	37
Şekil 5.1: CNN modeli için MS-2 veri kümesi eğitim ve doğrulama kaybı sonuçları	39
Şekil 5.2: CNN modeli ile MS-2 veri kümesi için karmaşıklık matrisi	39
Şekil 5.3: CNN modeli için Br35h veri kümesi eğitim ve doğrulama kaybı sonuçları	40
Şekil 5.4: CNN modeli ile Br35h veri kümesi için karmaşıklık matrisi.....	41
Şekil 5.5: Önerilen CNN modeli için MS-3 veri kümesi eğitim ve doğrulama kaybı sonuçları	42
Şekil 5.6: Önerilen CNN modeli ile MS-3 veri kümesi için karmaşıklık matrisi.....	43
Şekil 5.7: Önerilen CNN modeli için Alzheimer veri kümesi eğitim ve doğrulama kaybı sonuçları	44
Şekil 5.8: Önerilen CNN modeli ile Alzheimer veri kümesi için karmaşıklık matrisi.....	45
Şekil 5.9: Önerilen CNN modeli ile tümör veri kümesi için karmaşıklık matrisi.....	46

TABLO LİSTESİ

Sayfa

Tablo 4.1: Önerilen CNN modelinin katman yapısı	22
Tablo 5.1: CNN modeli için MS-2 veri kümesine ait performans sonuçları ...	38
Tablo 5.2: CNN modeli için Br35h veri kümesine ait performans sonuçları ..	40
Tablo 5.3: CNN modeli için MS-3 veri kümesine ait performans sonuçları ...	41
Tablo 5.4: Önerilen CNN modeli için Alzheimer veri kümesine ait performans sonuçları	43
Tablo 5.5: Önerilen CNN modeli için tümör veri kümesine ait performans sonuçları	45
Tablo 5.6: Önerilen CNN modelinin tüm veri kümelerine ait performans sonuçları	47
Tablo 5.7: Ön eğitilmiş modeller için MS-2 veri kümesine ait sınıflandırma sonuçları	48
Tablo 5.8: Ön eğitilmiş modeller için Br35h veri kümesine ait sınıflandırma sonuçları	48
Tablo 5.9: Ön eğitilmiş modeller için MS-3 veri kümesine ait sınıflandırma sonuçları	49
Tablo 5.10: Ön eğitilmiş modeller için Alzheimer veri kümesine ait sınıflandırma sonuçları	50
Tablo 5.11: Ön eğitilmiş modeller için tümör veri kümesine ait sınıflandırma sonuçları	51
Tablo 5.12: TL ile ön eğitilmiş modeller için MS-2 veri kümesine ait sınıflandırma sonuçları	53
Tablo 5.13: TL ile ön eğitilmiş modeller için Br35h veri kümesine ait sınıflandırma sonuçları	54
Tablo 5.14: TL ile ön eğitilmiş modeller için MS-3 veri kümesine ait sınıflandırma sonuçları	54
Tablo 5.15: TL ile ön eğitilmiş modeller için Alzheimer veri kümesine ait sınıflandırma sonuçları	55
Tablo 5.16: TL ile ön eğitilmiş modeller için tümör veri kümesine ait sınıflandırma sonuçları	56
Tablo 6.1: TL özellik çıkarımı için genel karşılaştırma sonuçları	57
Tablo 6.2: TL ince ayar için genel karşılaştırma sonuçları	58

KISALTMALAR LİSTESİ

ML	:	Makine Öğrenimi
TL	:	Transfer Öğrenme
DL	:	Derin Öğrenme
MRI	:	Manyetik Rezonans Görüntüleme
CNN	:	Evrişimli Sinir Ağları
TP	:	Gerçek Pozitif
TN	:	Gerçek Negatif
FP	:	Yanlış Pozitif
FN	:	Yanlış Negatif
CT	:	Bilgisayarlı Tomografi
SGD	:	Stokastik Gradyan İniş
MS	:	Multipl Skleroz
PET	:	Pozitron Emisyon Tomografisi
SPECT	:	Tek Foton Emisyonlu Bilgisayarlı Tomografi
EEG	:	Elektroensefalografi
EMG	:	Elektronöromiyografi
NCS	:	Sinir İletim Çalışmaları
ViT	:	Görüntü Transformatörleri
CNS	:	Merkezi Sinir Sistemi
MCI	:	Hafif Bilişsel Bozukluk
RNN	:	Tekrarlayan Sinir Ağları
CIS	:	Klinik İzole Sendromu
ASD	:	Otizm Spektrum Bozukluğu
DNN	:	Derin Sinir Ağları
ANN	:	Yapay Sinir Ağları
ReLU	:	Doğrultulmuş Doğrusal Üniteler
CIS	:	Klinik İzole Sendromu
FMRI	:	Fonksiyonel Manyetik Rezonans Görüntüleme

ÖNSÖZ

Bu çalışmanın her aşamasında bana rehberlik eden, değerli bilgi ve tecrübeleriyle beni yönlendiren, aynı zamanda sabrı ve desteğiyle her zaman yanımda olan danışmanım Doç. Dr. Meriç ÇETİN'e sonsuz teşekkürlerimi iletmek isterim. Kendisi, akademik gelişimimde ve bu tezin ortaya çıkmasında büyük bir rol oynamıştır.

Ayrıca, bu zorlu süreçte bana destek olan, sabırla ve anlayışıyla beni motive eden sevgili eşim Emine Sultan DUT'a minnettarım. Onun varlığı ve desteği, bu çalışmayı tamamlamam da büyük bir ilham kaynağı olmuştur.

Son olarak, bu süreçte bana manevi destek veren anneme teşekkür ederim. Onların varlığı ve teşvikleri, bu çalışmayı başarıyla tamamlamam da büyük bir katkı sağlamıştır.

1. GİRİŞ

1.1 Tezin Amacı

Bu tezin amacı, nörolojik hastalıkların teşhis ve sınıflandırılmasında Makine Öğrenimi (ML-Machine Learning) yöntemlerinden Transfer Öğrenmeyi (TL-Transfer Learning) incelemektir. Aynı zamanda bu tez çalışması, nörolojik hastalıkların erken ve doğru teşhisinin yapılabilmesi için TL yöntemlerinin kullanımını optimize etmeyi de amaçlanmıştır. Bu sayede, sağlık hizmetlerinde teşhis süreçlerinin hızlanması, doğruluğun artırılması ve hastaların yaşam kalitesinin iyileştirilmesi hedeflenmiştir. Bu amaçla, bu tez çalışması için önerilen bir Evrişimli Sinir Ağı (Convolutional Neural Networks-CNN) modelinin sınıflandırma performansı, VGG16, ResNet50, InceptionV3 ve Görüntü Transformatörü (Vision Transformer-ViT) gibi ön eğitilmiş TL modellerinin performansları ile karşılaştırılmıştır. Tasarlanan modeller, farklı sınıflar barındıran MS-2, Br35h, MS-3, Alzheimer ve beyin tümörü gibi veri kümeleri üzerinde eğitilmiştir. Tez çalışmasının spesifik hedefleri şu şekilde sıralanabilir:

- Veri artırımı, veri normalizasyonu, sınıf dengeleme gibi veri ön işleme süreçlerinin model performansı üzerindeki etkilerini analiz etmek.
- Nörolojik bozuklukların analizi ve sınıflandırılması için yeni bir CNN modeli tasarımı yapmak.
- VGG16, ResNet50 ve InceptionV3 ve ViT gibi ön eğitilmiş farklı transfer öğrenme modellerinin nörolojik hastalıkların teşhisindeki başarılarını kıyaslamak.
- Önerilen CNN modelinin hız ve performans bakımından ön eğitilmiş modeller ile olan karşılaştırmalarını ele almak.
- Nörolojik bozuklukların analizi ve sınıflandırılması için transfer öğrenme temelli yaklaşımların uygulanabilirliğini CNN modellerinin performanslarını da göz önünde bulundurarak incelemek.
- Özellik çıkarımı ve hiperparametre optimizasyonu uygulamalarının ön eğitilmiş model performansları üzerindeki etkilerini incelemek.

1.2 Tezin Önemi

Nörolojik hastalıklar, dünya genelinde milyonlarca insanı etkileyen ve genellikle kronik ve ilerleyici seyreden rahatsızlıklardır. Parkinson hastalığı, Alzheimer hastalığı, epilepsi ve MS gibi nörolojik bozukluklar, hastaların yaşam kalitesini ciddi şekilde düşürebilir ve toplum sağlığı üzerinde büyük bir ekonomik yük oluşturabilir. Bu hastalıkların erken teşhisi ve doğru sınıflandırılması, hastaların uygun tedaviye daha hızlı erişimini sağlayarak hastalıkların ilerlemesini yavaşlatabilir ve yaşam kalitesini artırabilir. Nörolojik hastalıkların erken evrelerinde teşhis edilmesi, hastaların yaşam kalitesini önemli ölçüde iyileştirebilir ve hastalıkların ilerlemesini yavaşlatabilir.

Transfer öğrenme, büyük ve etiketlenmiş veri kümelerinin bulunmadığı durumlarda, önceden eğitilmiş modellerin bilgi aktarımını daha kısa sürede ve daha yüksek performans ile elde etmesine olanak tanır. Özellikle, nörolojik bozuklukların teşhisinde kullanılan biyomedikal veriler, sınırlı miktarları ve etiketleme zorlukları nedeniyle analiz süreçlerinde zorluk yaratmaktadır. Bu tez çalışması, TL yöntemlerinin erken teşhis süreçlerinde etkin bir şekilde kullanılabileceğini göstermeyi amaçlamaktadır. Bu amaçla, literatürde yaygın olarak kullanılan bazı derin öğrenme modelleri ile bazı TL modelleri tasarlanmıştır. Önerilen CNN modeli, VGG16, ResNet50, InceptionV3 ve ViT modellerinin nörolojik hastalıkların teşhisindeki performansları analiz edilerek, bu alandaki en etkili derin öğrenme yöntemlerin belirlenmesine çalışılmıştır. Veri çoğaltma, veri normalizasyonu ve sınıf dengeleme gibi veri ön işleme tekniklerinin model performansı üzerindeki etkilerini inceleyen bu tez, yapay zeka (AI-Artificial Intelligence) modellerinin daha genel ve doğru sonuçlar üretebilmesi için gerekli adımları vurgulamaktadır.

Çalışmanın bulgularının, nörolojik hastalıkların teşhis süreçlerinde derin öğrenme yöntemlerinin kullanımını teşvik edeceği, sağlık hizmetlerinin doğruluğunu ve hızını artırabileceği düşünülmektedir. Böylece, hastalar daha hızlı ve doğru teşhisler alabilir, tedavi süreçleri iyileştirilebilir ve genel sağlık hizmetlerinin kalitesi artırılabilir. Bu tez çalışması nörolojik hastalıkların teşhisinde derin öğrenme tekniklerinin potansiyelini ortaya koyarak hem akademik hem de pratik uygulamalar açısından değerli bilgiler sunmaktadır. Bu alandaki ilerlemeler, tıp ve sağlık

hizmetlerinde önemli gelişmelere yol açabilir ve nörolojik hastalıklarla mücadelede yeni yaklaşımlar geliştirilmesine katkıda bulunabilir.

1.3 Tezin Akışı

Bu tez, nörolojik hastalıkların teşhisinde derin öğrenme modellerinin etkinliğini değerlendirmeyi amaçlamaktadır. İlk olarak, giriş bölümünde çalışmanın arka planı ile amacı açıklanmakta ve problem tanımı yapılmaktadır. Ardından literatür taramasında mevcut çalışmalar incelenerek boşluklar belirlenmektedir. Materyal ve yöntem bölümünde, veri kümeleri, kullanılan modeller (önerilen CNN modeli, VGG16, ResNet50, InceptionV3 ve ViT), veri ön işleme teknikleri, değerlendirme metrikleri ve hiperparametre optimizasyonları açıklanmaktadır. Uygulama sonuçları bölümünde modellerin performans sonuçları karşılaştırılarak analiz edilmekte, son olarak sonuçlar ve değerlendirme bölümünde elde edilen bulgular özetlenmekte ve gelecekteki araştırmalar için önerilerde bulunmaktadır.

2. NÖROLOJİK BOZUKLUKLAR

2.1 Nörolojik Bozukluklar Nedir?

Nörolojik bozuklukların anlaşılması ve tanımlanması, tıp tarihinin erken dönemlerinden itibaren önemli bir araştırma konusu olmuştur. Antik Yunan'da (Hippokrates MÖ 460-370), epilepsiyi "kutsal hastalık" olarak tanımlamış ve bunun doğaüstü güçlerle değil, beyindeki fizyolojik bozukluklarla ilişkili olduğunu öne sürmüştür (Tözün 2014). Epilepsi, antik dönemde dahi insanları etkileyen yaygın bir nörolojik bozukluk olarak tanınmıştır. Bu erken dönemde yapılan gözlemler, epilepsi ve diğer nörolojik bozuklukların biyolojik temellerini anlamaya yönelik ilk adımları temsil etmektedir.

19. yüzyıl, nöroloji alanında büyük ilerlemelere sahne olmuştur. Fransız nörolog Jean-Martin Charcot, Parkinson hastalığını (başlangıçta "titrek felç" olarak adlandırılmıştır) ve MS'i ilk kez tanımlamış ve sınıflandırmıştır. Charcot'nun çalışmaları (Charcot 1877), bu hastalıkların klinik belirtilerini ve patolojik özelliklerini tanımlamada öncü olmuştur. Aynı yüzyılda, Alois Alzheimer, 1906'da ilk kez bir Alzheimer hastalığı vakasını tanımlamış ve beyindeki patolojik değişiklikleri ortaya koymuştur (Maurer ve diğ. 1997). Alzheimer'ın bulguları, nörodejeneratif hastalıkların anlaşılmasında devrim niteliğinde olmuştur.

Nörolojik bozukluklar, merkezi sinir sistemi (beyin ve omurilik) ve periferik sinir sisteminin (vücuttaki sinirler) yapısal, biyokimyasal veya elektriksel anormalliklerinden kaynaklanan hastalıklar ve işlev bozukluklarıdır. Bu bozukluklar, motor, bilişsel, duyu ve otonom sinir sistemi işlevlerinde çeşitli düzeylerde bozulmalara yol açar. Nörolojik bozukluklar, etiyolojileri ve semptomatolojileri açısından geniş bir yelpazeye sahiptir ve genellikle karmaşık klinik tablolarla kendini gösterir. Bu bozukluklar, genetik, çevresel, enfeksiyöz ve otoimmün faktörlerin etkileşimi sonucu ortaya çıkabilir.

Nörolojik bozukluklar, motor sistemde ciddi hasarlara neden olabilir. Örneğin, Parkinson hastalığı, dopamin üreten nöronların kaybı ile karakterize olan bir nörodejeneratif bozukluktur. Semptomlar arasında titreme, bradikinezi (hareketlerde

yavaşlama), rijidite ve postural instabilite bulunur. Hastalık genellikle orta yaşın ilerleyen dönemlerinde başlar ve yavaş ilerleyici bir seyir izler (Jankovic 2008). MS, merkezi sinir sisteminin kronik inflamatuvar bir hastalığı olup, miyelin kılıfının otoimmün saldırılarla zarar görmesi sonucu demiyelinizasyon ve nörodejenerasyon meydana gelir. Bu hastalık, çeşitli nörolojik semptomlarla seyredebilir ve sıklıkla motor ve duysal işlevlerde bozulmaya neden olur (Compston ve Coles 2008). Epilepsi, beynin anormal elektriksel aktiviteleri sonucu tekrarlayan nöbetlerle karakterize edilen kronik bir bozukluktur. Epilepsi, çeşitli etiyolojik faktörlere bağlı olarak gelişebilir ve geniş bir klinik spektrum sergiler. Nöbetler, bilinç kaybı, kas spazmları ve duysal bozukluklar gibi çeşitli semptomlara yol açabilir (Fisher ve diğ. 2017). Nörolojik bozukluklar üzerine yapılan araştırmalar, bu hastalıkların daha iyi anlaşılmasına ve yeni tedavi yöntemlerinin geliştirilmesine önemli katkılar sağlamıştır. Örneğin, Alzheimer hastalığı üzerine yapılan araştırmalar, hastalığın biyokimyasal ve genetik temelini anlamada büyük ilerlemeler kaydetmiştir (Hardy ve Selkoe 2002). Parkinson hastalığı için geliştirilen yeni tedavi yaklaşımları, hastalığın semptomlarını hafifletmeye ve yaşam kalitesini artırmaya yönelik önemli adımlar atmıştır. Levodopa gibi dopamin öncülleri ve dopamin agonistleri, Parkinson hastalığının motor semptomlarını kontrol altına almak için yaygın olarak kullanılan tedavilerdir (Schapira 2009). Ayrıca, derin beyin stimülasyonu gibi cerrahi müdahaleler de Parkinson hastalığının tedavisinde önemli bir rol oynamaktadır.

TL, derin öğrenme ve makine öğrenmesi alanında, bir modelin daha önce öğrenilmiş bilgi ve deneyimlerini yeni bir görevde uygulamasını sağlayan bir tekniktir. TL, sınırlı veri setlerine sahip tıbbi görüntüleme ve nörolojik bozuklukların teşhisi gibi alanlarda oldukça etkilidir. Bu yaklaşım, nörolojik bozuklukların tespiti ve sınıflandırılmasında, derin öğrenme modellerinin performansını artırmak için kullanılmaktadır (Pan ve Yang 2010).

Örneğin, TL yöntemleri, Manyetik Rezonans Görüntüleme (MRI) ve Bilgisayarlı Tomografi (CT-Computed Tomography) gibi tıbbi görüntüleme verilerinin analizinde kullanılabilir. Derin öğrenme modelleri, daha önce geniş veri setlerinde eğitilmiş bilgiye dayalı olarak, nörolojik bozuklukları yüksek doğrulukla tespit edebilir. Bu yöntemler, özellikle nadir hastalıkların teşhisinde ve hastalığın erken evrelerinde tanı koymada büyük avantajlar sunar. TL, aynı zamanda, klinik karar

destek sistemlerinde ve hastalık prognozunun belirlenmesinde de önemli bir rol oynayabilir.

ViT, görüntü sınıflandırma ve analizinde son yıllarda büyük ilgi gören bir derin öğrenme modelidir. ViT, klasik CNN'lerin aksine, dikkat mekanizmalarını kullanarak görüntü verilerini işler ve bu sayede daha esnek ve güçlü bir derin öğrenme modeli sunar (Dosovitskiy ve diğ. 2020). ViT, özellikle büyük veri setlerinde eğitildiğinde yüksek performans göstermekte ve TL ile kombine edildiğinde sınırlı veri setlerinde dahi etkili sonuçlar üretebilmektedir. Örneğin, ViT modelleri, nörolojik bozuklukların teşhisinde MRI ve CT görüntülerinin analizinde kullanılabilir. Bu modeller, TL teknikleri ile birleştirildiğinde, mevcut veri setlerinden öğrenilen bilgiyi yeni ve sınırlı veri setlerine uygulayarak tanı doğruluğunu artırabilir (Chen ve diğ. 2021).

2.2 Nörolojik Hastalıklar

2.2.1 Alzheimer Hastalığı

Alzheimer hastalığı, beyin hücrelerinin dejenerasyonu ile karakterize olan ve ilerleyici bir nörodejeneratif bozukluktur. Bu hastalık, hafıza kaybı, bilişsel işlevlerde bozulma ve davranışsal değişikliklere yol açar. Alzheimer hastalığının patolojik özellikleri arasında beta-amiloid plaklarının ve nörofibriler yumakların birikimi yer alır (Selkoe 2001). Beta-amiloid plaklarının ve tau proteinlerinin birikimi, hastalığın patofizyolojisini anlamada kritik öneme sahiptir. Alzheimer hastalığının biyokimyasal ve genetik temellerini anlamaya yönelik araştırmalar, yeni terapötik hedeflerin belirlenmesine ve potansiyel tedavi stratejilerinin geliştirilmesine olanak sağlamıştır (Hardy ve Selkoe 2002). Son yıllarda, derin öğrenme tabanlı yöntemler Alzheimer hastalığının erken teşhisinde önemli ilerlemeler sağlamıştır. Özellikle, derin öğrenme ve makine öğrenimi teknikleri, MRI ve PET (Pozitron Emisyon Tomografisi) taramalarından elde edilen verilerle Alzheimer hastalığının erken evrelerini tespit etmekte kullanılmaktadır. TL yöntemleri, Alzheimer hastalığında sınırlı veri setleriyle dahi yüksek doğrulukla tanı koyabilme kapasitesine sahiptir.

2.2.2 Demans

Demans, genellikle progresif ve kronik bir nörolojik hastalıktır ve hafıza kaybı, dil bozuklukları, problem çözme ve diğer bilişsel yeteneklerde ciddi düşüşlerle seyreder. Alzheimer hastalığı demansın en yaygın nedenidir. Ancak, vasküler demans, Lewy cisimcikli demans ve frontotemporal demans gibi diğer türleri de mevcuttur. Vasküler demans, beyin damarlarındaki bozukluklar sonucu gelişirken, Lewy cisimcikli demans ve frontotemporal demans, farklı patolojik mekanizmalarla karakterize edilir. Makine öğrenimi teknikleri, demans türlerinin ayırımında ve hastalığın ilerleyişinin takibinde önemli bir rol oynamaktadır. Özellikle, derin öğrenme algoritmaları, beyin görüntülerindeki ince detayları analiz ederek farklı demans türlerini ayırt edebilme kapasitesine sahiptir (Murugan ve diğ. 2021).

2.2.3 Multipl Skleroz

Multiple Skleroz, merkezi sinir sisteminin kronik inflamatuvar bir hastalığıdır. Miyelin kılıfının otoimmün saldırılarla zarar görmesi sonucu demiyelinizasyon ve nörodejenerasyon meydana gelir. Bu durum, motor ve duyuşsal işlevlerde çeşitli bozulmalara neden olabilir (Compston ve Coles 2008). MS'in erken teşhisi, tedaviye yanıtın iyileştirilmesi açısından kritik öneme sahiptir. Son yıllarda, makine öğrenimi ve derin öğrenme yöntemleri, MS'in teşhis ve prognozunda önemli ilerlemeler sağlamıştır. 2016'dan bu yana, MRI teknikleri ve derin öğrenme yöntemleri, Multiple Skleroz tanısına yönelik araştırmalarda yaygın olarak kullanılmaya başlanmıştır. (Shoeibi ve diğ. 2021^a).

2.2.4 Beyin Tümörleri

Beyin tümörleri, beyin veya omurilikte anormal hücre büyümesinin bir sonucu olarak ortaya çıkar. Tümörler benign (iyi huylu) veya malign (kötü huylu) olabilir ve lokalize etkiler ile nörolojik semptomlara yol açabilir. Tedavi seçenekleri arasında cerrahi, radyoterapi ve kemoterapi yer alır. Makine öğrenimi teknikleri, beyin tümörlerinin sınıflandırılmasında ve prognozunun belirlenmesinde giderek daha fazla kullanılmaktadır. Özellikle, DL algoritmaları, MRI ve CT taramalarından elde edilen

nörolojik hastalıkları analiz ederek tümör türlerini ve evrelerini yüksek doğrulukla belirleyebilir (Sun ve diğ. 2019).

2.2.5 Epilepsi

Epilepsi, beynin anormal elektriksel aktiviteleri sonucu tekrarlayan nöbetlerle karakterize edilen kronik bir bozukluktur. Epilepsi, çeşitli etiyolojik faktörlere bağlı olarak gelişebilir ve geniş bir klinik spektrum sergiler. Nöbetler, bilinç kaybı, kas spazmları ve duyuşal bozukluklar gibi çeşitli semptomlara yol açabilir (Fisher ve diğ. 2017). Son yıllarda, epilepsi teşhisinde ve nöbetlerin tahmininde makine öğrenimi yöntemlerinin kullanımı artmıştır. Özellikle, elektroensefalografi (EEG) verilerinin analizi için kullanılan DL algoritmaları, nöbetlerin önceden tahmin edilmesine ve tedaviye yanıtın iyileştirilmesine yardımcı olabilir (Shoeibi ve diğ. 2021^b).

2.2.6 Parkinson Hastalığı

Parkinson hastalığı, dopamin üreten nöronların kaybı ile karakterize bir nörodejeneratif bozukluktur. Semptomlar arasında titreme, bradikinezi (hareketlerde yavaşlama), rijidite ve postural instabilite bulunur. Hastalık genellikle orta yaşın ilerleyen dönemlerinde başlar ve yavaş ilerleyici bir seyir izler (Jankovic 2008). Parkinson hastalığının teşhisinde ve tedavisinde makine öğrenimi ve derin öğrenme yaklaşımları önemli rol oynamaktadır. Bilgisayar destekli teşhiste derin öğrenme yöntemlerinin benimsenmesinin önemi büyüktür (Loh ve diğ. 2021). Derin beyin stimülasyonu gibi cerrahi müdahaleler, hastalığın tedavisinde önemli bir rol oynamaktadır (Schapira 2009).

2.3 Nörolojik Bozukluklarda Tanı ve Erken Teşhis

Nörolojik bozuklukların tanısı, hastanın klinik öyküsünün alınması, fiziki muayene, nörolojik değerlendirme ve çeşitli tanısal testlerle konur. Erken teşhis, hastaların uygun tedaviye daha hızlı erişimini sağlayarak hastalıkların ilerlemesini yavaşlatabilir ve yaşam kalitesini artırabilir. Bu süreçte, kullanılan başlıca yöntemler

klirik deęerlendirme, n6rolojik muayene, g6r6nt6leme teknikleri, elektrofizyolojik testler ve laboratuvar testleridir.

2.3.1 Klinik Deęerlendirme ve N6rolojik Muayene

Klinik deęerlendirme, hastanın semptomlarının detaylı bir Őekilde incelenmesi, hastalık 6yk6s6n6n alınması ve aile geęmiŐinin sorgulanmasıyla baŐlar. Bu, 6zellikle genetik fakt6rlerin belirlenmesi aęısından 6nemlidir. N6rolojik muayene ise motor ve duyu iŐlevlerinin, reflekslerin, kranial sinirlerin ve mental durumun deęerlendirilmesini ięerir. Bu muayene, belirli n6rolojik bozukluklara 6zg6 belirtilerin tanınlanmasına yardımcı olur.

2.3.2 G6r6nt6leme Teknikleri ve Elektrofizyolojik Testler

G6r6nt6leme teknikleri arasında MRI, CT, PET ve tek foton emisyonlu bilgisayarlı tomografi (SPECT-Single Photon Emission Computed Tomography) bulunur. Bu teknikler, beyin ve omurilikteki yapısal ve fonksiyonel deęiŐiklikleri y6ksek ę6z6n6rl6kte g6r6nt6lemeye olanak saęlar. Elektrofizyolojik testler ise EEG ve elektron6romiyografi (EMG) gibi y6ntemlerle beyin ve sinir sisteminin elektriksel aktivitesini 6lęer.

2.3.3 Laboratuvar Testleri

Laboratuvar testleri, kan testleri, beyin omurilik sıvısı analizi (lomber ponksiyon) ve genetik testleri ięerir. Bu testler, enfeksiyonlar, metabolik hastalıklar ve genetik bozuklukların tanısında yardımcı olur.

2.3.4 Erken TeŐhis ve Makine 6ęrenimi

GeliŐen derin 6ęrenme ve makine 6ęrenimi teknolojileri, n6rolojik bozuklukların tanı ve erken teŐhisinde yeni ufuklar aęmaktadır. TL, sınırlı veri

setlerine sahip tıbbi görüntüleme ve nörolojik bozuklukların teşhisi gibi alanlarda büyük potansiyel sunmaktadır. TL, daha önce geniş veri setlerinde eğitilmiş modellerin, yeni ve benzer görevlerde kullanılmasını sağlar (Pan ve Yang 2010).

Derin öğrenme modelleri, tıbbi görüntülerin analizinde yüksek doğruluk oranları ile nörolojik bozuklukların erken teşhisinde önemli rol oynamaktadır. Bu modeller, MRI, CT ve diğer görüntüleme tekniklerinden elde edilen verileri işleyerek, hastalık belirtilerini tespit edebilir ve sınıflandırabilir. Örneğin, (Liu ve diğ. 2014) çalışması, Alzheimer hastalığının erken teşhisinde derin öğrenme tekniklerinin kullanımını ele almış ve MRI verilerinin analizinde yüksek doğruluk oranları ile başarılı olduğunu göstermiştir. (Suk ve diğ. 2014) çalışması ise, Alzheimer hastalığı ve hafif bilişsel bozuklukların (MCI-Mild Cognitive Impairment) teşhisinde derin öğrenme tabanlı hiyerarşik özellik temsilinin ve multimodal füzyonun önemini vurgulamaktadır.

Parkinson hastalığının teşhisinde derin öğrenme teknikleri de etkili olmuştur. (Oh ve diğ. 2020), EEG sinyalleri kullanarak Parkinson hastalığının teşhisinde derin öğrenme yaklaşımının etkinliğini araştırmış ve yüksek doğruluk oranları ile Parkinson hastalığını tespit edebildiğini göstermiştir.

Epilepsi teşhisinde de derin öğrenme yöntemleri kullanılmaktadır. (Shoeibi ve diğ. 2021^b) çalışması, epilepsi teşhisinde derin öğrenme tabanlı tekrarlayan sinir ağlarının (RNN-Recurrent Neural Networks) kullanımını incelemiş ve EEG verilerinin analizi ile anormal beyin aktivitelerinin tespitinde yüksek doğruluk sağlamıştır. Epilepsi tespiti için standart bir derin CNN modeli eğitmek, genellikle büyük veri setlerine gereksinim duyar; fakat bu alanda mevcut veri kaynakları sınırlıdır (Ullah ve diğ. 2018).

MS teşhisinde de makine öğrenimi teknikleri kullanılmaktadır. (Eshaghi ve diğ. 2018), MS alt tiplerinin tanımlanmasında gözetimsiz makine öğrenimi ve MRI verilerinin kullanımını ele almış ve farklı MS alt tiplerini tespit etmede yüksek doğruluk sağlamıştır. (Wottschel ve diğ. 2015) ise, MS hastalığının Klinik İzole Sendromu (CIS-Clinically Isolated Syndrome) olan hastalarda sonuçları tahmin etmede makine öğrenimi modellerinin etkinliğini araştırmış ve erken teşhis ve tedavi planlamasında önemli bulgular sunmuşlardır.

ViT modelleri, özellikle tıbbi görüntüleme büyük potansiyel sunmaktadır. ViT, görüntüleri bölümlere ayırarak her bölümü bir "görsel kelime" olarak ele alır ve bu kelimeler arasındaki ilişkileri modelleyerek görüntü sınıflandırması yapar. Son yıllarda, ViT'in nörolojik bozuklukların erken teşhisi ve tanısında nasıl kullanılabileceğini araştıran çalışmalar artmaktadır. Örneğin bir araştırmada, retina hastalığının tespitine yönelik derin öğrenme modelleri ve görüntü transformatörlerinin kullanıldığı hibrit bir yaklaşım ile yüksek performans elde edildiği belirtilmiştir (Dutta ve diğ. 2023).

(Zhou ve diğ. 2023) çalışması, ViT'in EEG sinyallerinden epilepsi nöbetlerini tespit etme yeteneğini incelemiştir. Bu çalışma, ViT'in epilepsi teşhisinde diğer derin öğrenme modellerine kıyasla üstün performans sergilediğini göstermiştir.

Bu çalışmalar, makine öğrenimi ve derin öğrenme tekniklerinin nörolojik bozuklukların erken teşhisinde ve tanısında nasıl kullanıldığını göstermektedir. Bu yöntemler, geleneksel tanı yöntemlerine kıyasla daha yüksek doğruluk oranları ve hız sağlamaktadır. Bu tez çalışmasında, bu teknolojilerin farklı nörolojik bozuklukların erken teşhisinde nasıl kullanılabileceğini ve mevcut tanı yöntemlerine kıyasla ne tür avantajlar sunduğunun araştırılması amaçlanmıştır.

3. LİTERATÜR TARAMASI

3.1 Problem Tanımı

Nörolojik bozukluklar, merkezi sinir sistemi (beyin ve omurilik) ve periferik sinir sisteminin (vücuttaki sinirler) yapısal, biyokimyasal veya elektriksel anormalliklerinden kaynaklanan, bireylerin yaşam kalitesini ciddi şekilde etkileyen hastalıklardır. Bu bozuklukların erken ve doğru teşhisi, hastaların tedavi süreçlerinin etkin bir şekilde yönetilmesi açısından hayati öneme sahiptir. Ancak, nörolojik bozuklukların klinik belirtileri genellikle karmaşık ve çeşitlidir, bu da teşhis sürecini zorlaştırmaktadır.

Geleneksel tanı yöntemleri, genellikle zaman alıcıdır ve yüksek derecede uzmanlık gerektirir. Nörolojik bozuklukların çeşitliliği ve semptomlarının örtüşmesi, yanlış teşhis riskini artırır. Örneğin, Parkinson hastalığı, epilepsi, MS ve Alzheimer hastalığı gibi nörolojik bozukluklar benzer belirtiler gösterebilir, bu da doğru sınıflandırmayı güçleştirir (Jankovic 2008; Compston ve Coles 2008; Hardy ve Selkoe 2002).

Son yıllarda, derin öğrenme ve makine öğrenimi teknikleri, nörolojik bozuklukların tanı ve erken teşhisinde umut verici çözümler sunmaktadır. Derin öğrenme modelleri, özellikle CNN, TL yöntemleri ve ViT modelleri, tıbbi görüntüleme verilerinin analizinde ve nörolojik bozuklukların teşhisinde büyük potansiyel göstermektedir. Bu modeller, sınırlı veri setleri ile yüksek doğruluk oranlarına ulaşabilmekte ve teşhis sürecini hızlandırabilmektedir (Pan ve Yang 2010).

Bu tez çalışmasının amacı, nörolojik bozuklukların teşhis ve sınıflandırılmasında derin öğrenme yöntemlerinin etkinliğini değerlendirmek ve karşılaştırmaktır. Bu kapsamda, literatürdeki yaklaşımlar önerilen yöntem ile karşılaştırılarak nörolojik bozuklukların tanı sürecindeki başarısını göstermek amaçlanmıştır. Önerilen CNN modeli, VGG16, ResNet50, InceptionV3 ve ViT modellerinin performansını test ederek, bu modellerin erken teşhis ve tanı süreçlerindeki etkinliklerinin karşılaştırılması hedeflenmiştir. Aynı zamanda, veri ön işleme, model eğitimi ve hiperparametre optimizasyonu süreçleri üzerinde durularak,

bu süreçlerin model performansı üzerindeki etkileri analiz edilmiştir. Ayrıca, veri çoğaltma, normalizasyon, eğitim ve doğrulama veri setlerinin ayrılması, sınıf dengeleme gibi tekniklerin model performansını nasıl etkilediği de incelenmiştir. Elde edilen benzetim sonuçlarına göre, derin öğrenme ve makine öğrenimi tekniklerinden TL'nin doğru ve etkin kullanımı, nörolojik bozuklukların erken teşhisi ve tedavi planlamasında önemli bir ilerleme sağlayabileceği düşünülmektedir. Bu da hastaların yaşam kalitesini artırabilir ve sağlık hizmetleri üzerinde olumlu etkiler yaratabilir.

3.2 Literatür Özeti

Son yıllarda, derin öğrenme ve makine öğrenimi tekniklerinin nörolojik bozuklukların tanı ve tedavisindeki kullanımı giderek daha fazla dikkat çekmektedir. Bu alandaki araştırmalar, özellikle derin öğrenme ve TL yöntemlerinin etkinliğini vurgulamaktadır.

(Alp ve diğ. 2024) tarafından yapılan bir çalışma, ViT modellerinin Alzheimer hastalığının erken teşhisinde kullanımını incelemiştir. Bu çalışmada, yapısal MRI verileri kullanılarak ViT modellerinin yüksek doğruluk oranları ile Alzheimer hastalığını tespit edebildiği gösterilmiştir. Yazarlar, ViT modellerinin geleneksel CNN'lere kıyasla daha etkili olduğunu ve erken teşhis için önemli bir araç olabileceğini belirtmişlerdir. (De Silva ve Brown 2023) dünyadaki tarımsal uygulamalarda bitki hastalıklarının teşhisinde ViT-B16 modelinin yüksek performans göstermesinin önemini vurgulamaktadır.

(Raghu ve diğ. 2020) tarafından yapılan başka bir çalışma, TL tekniklerinin epilepsi teşhisindeki etkinliğini değerlendirmiştir. Bu çalışmada, geniş veri setlerinde eğitilmiş CNN modellerinin, epilepsi hastalarının EEG verilerini analiz ederek nöbetleri yüksek doğrulukla tespit edebildiği gösterilmiştir. TL, özellikle sınırlı veri setlerine sahip durumlarda model performansını önemli ölçüde artırmıştır.

(Sharabas ve diğ. 2024) tarafından yapılan araştırmada, derin öğrenme modellerinin MS hastalığının teşhisindeki rolü incelenmiştir. Çalışmada, MRI verileri kullanılarak eğitilmiş ResNet50 modelleri, MS plaklarını yüksek doğrulukla tespit

edebilmiştir. Bu çalışma, derin öğrenme modellerinin MS teşhisinde klinik karar destek sistemleri olarak kullanılabileceğini ortaya koymuştur.

(Aydın ve diğ. 2019), VGG16 modeli kullanarak nörolojik bozuklukların sınıflandırılmasında TL'nin etkinliğini araştırmıştır. Çalışmada, TL yöntemi ile eğitilmiş VGG16 modelinin, farklı nörolojik bozuklukları yüksek doğrulukla sınıflandırabildiği gösterilmiştir. Yazarlar, TL'nin sınırlı veri setleri ile çalışırken model performansını artırdığını ve tanı süreçlerini hızlandığını belirtmişlerdir.

(LeCun ve diğ. 2015), derin öğrenme modellerinin tıbbi görüntülemedeki başarısını vurgulamışlardır. Özellikle CNN'lerin, tıbbi görüntülerin sınıflandırılmasında ve nörolojik bozuklukların teşhisinde yüksek performans gösterdiği belirtilmiştir. Bu çalışma, derin öğrenme modellerinin tıbbi alanda kullanım potansiyelini ortaya koymuştur.

(Pan ve Yang 2010), TL'nin tıbbi görüntüleme ve nörolojik bozuklukların teşhisindeki önemini tartışmışlardır. TL tekniklerinin, sınırlı veri setlerine sahip tıbbi görüntüleme verilerinde model performansını artırdığını ve tanı süreçlerini hızlandığını vurgulamışlardır. Bu çalışma, TL'nin nörolojik bozuklukların teşhisinde geniş bir uygulama alanı bulabileceğini göstermektedir.

(Hussein ve diğ. 2022), EEG verilerini kullanarak epilepsi nöbetlerini tespit etmek için ViT modellerini uygulamışlardır. Bu çalışmada, ViT modellerinin, geleneksel CNN'lere kıyasla daha hızlı ve yüksek doğrulukla nöbetleri tespit edebildiği gösterilmiştir. Bu sonuçlar, ViT modellerinin epilepsi teşhisinde önemli bir araç olabileceğini göstermektedir.

Derin öğrenme tekniklerinin otizm spektrum bozukluğu (ASD-Autism Spectrum Disorder) teşhisindeki rolünü incelemiştir. ASD hastalarına yönelik olarak, güvenilir, doğru ve düşük güç tüketimine sahip bir DL algoritması tabanlı giyilebilir cihaz tasarımı, gelecekte önemli bir çözüm sunabilecektir (Khodatars ve diğ. 2021).

(Uparkar ve diğ. 2023) Imagenet üzerinde önceden eğitilmiş ağırlıklarla başlatıldığında, VDSNet ile ViT arasındaki performans farkı, tıbbi görevlerde belirgin şekilde ortadan kalkmaktadır. Bu durum nörolojik hastalıkların teşhisinde ViT lerin

başarımını ve diğer derin öğrenme modelleri ile performans karşılaştırmalarını ortaya koymaktadır.

(Warren ve diğ. 2023), derin öğrenme modellerinin tıbbi görüntüleme kullanımını araştırmışlardır. Çalışmada, CNN tabanlı modellerin, FMRI(Fonksiyonel manyetik rezonans görüntüleme) görüntülerin sınıflandırılmasında yüksek doğrulukla performans gösterdiği ve nörolojik bozuklukların teşhisinde önemli bir araç olabileceği belirtilmiştir. Bu çalışma, derin öğrenme modellerinin tıbbi alanda kullanım potansiyelini ortaya koymaktadır.

(Brown ve diğ. 2014), Alzheimer hastalığının teşhisinde TL'nin rolünü araştırmışlardır. Çalışmada, TL yöntemi ile eğitilmiş CNN modellerinin, PET ve MRI verilerini kullanarak Alzheimer hastalığını yüksek doğrulukla tespit edebildiği gösterilmiştir. Bu çalışma, TL'nin Alzheimer hastalığı gibi nörolojik bozuklukların teşhisinde önemli bir araç olabileceğini ortaya koymaktadır.

Sonuç olarak, literatürdeki bu çalışmalar, derin öğrenme ve makine öğrenimi tekniklerinin nörolojik bozuklukların tanı ve tedavisinde önemli bir rol oynadığını göstermektedir. Özellikle derin öğrenme ve TL yöntemleri, tıbbi görüntüleme verilerinin analizinde yüksek doğruluk oranları ile başarılı sonuçlar elde etmektedir. Bu teknolojilerin doğru ve etkin kullanımı, nörolojik bozuklukların erken teşhisi ve tedavi planlamasında önemli bir ilerleme sağlayabilir ve hastaların yaşam kalitesini artırabilir.

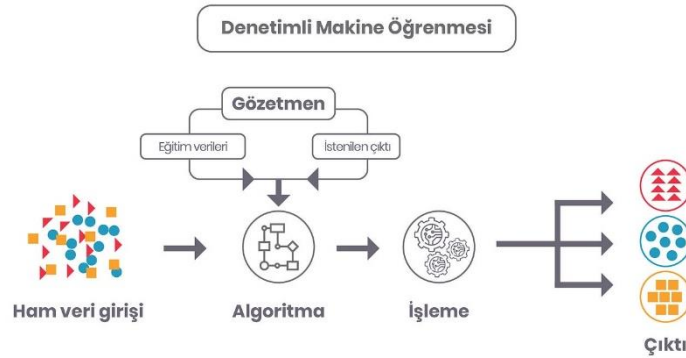
4. MATERYAL VE YÖNTEM

4.1 Makine Öğrenimi Yöntemleri

Makine öğrenimi, veri üzerinde öğrenme ve karar verme süreçlerini otomatikleştiren algoritmaların geliştirilmesini içerir. Bu yöntemler, verilerden bilgi çıkararak belirli görevleri yerine getirmek için kullanılır.

4.1.1 Denetimli Öğrenme

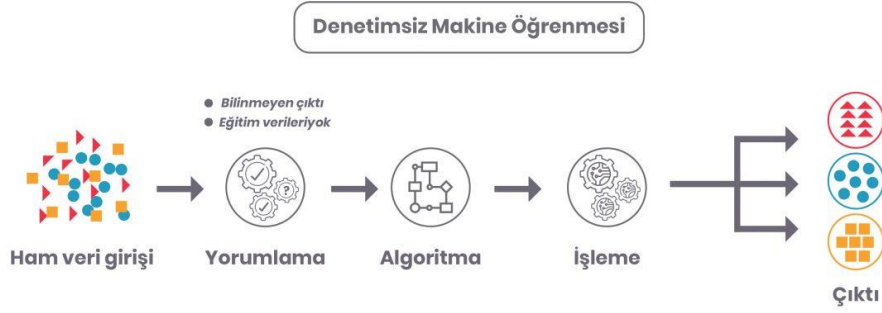
Denetimsiz öğrenme, etiketlenmiş veriler kullanılarak model eğitimi yapılmasını içerir. Bu yöntem, modelin giriş ve çıkış arasındaki ilişkiyi öğrenmesini sağlar ve yeni veriler için doğru tahminler yapmayı amaçlar (Goodfellow ve diğ. 2016). Örneğin, nörolojik bozuklukların teşhisi için kullanılan modeller genellikle denetimli öğrenme yöntemlerine dayanır. Hastalık sınıflandırması yaparken kullanılan etiketli MRI ve EEG verileri, modelin doğruluğunu artırmada kritik bir rol oynar. Denetimli öğrenme yöntemleri arasında en yaygın olarak kullanılanlar, lojistik regresyon, destek vektör makineleri (Support Vector Machine-SVM) ve karar ağaçlarıdır. Lojistik regresyon, ikili sınıflandırma problemlerinde kullanılan temel bir yöntemdir. SVM, veriyi sınıflandırmak için hiper düzlemler kullanırken, karar ağaçları ise veriyi bölümlere ayırarak sınıflandırma yapar. Şekil 4.1’de denetimli öğrenme yapısına bir örnek verilmiştir (Turhost 2024).



Şekil 4.1: Denetimli öğrenme mimarisini örneği

4.1.2 Denetimsiz Öğrenme

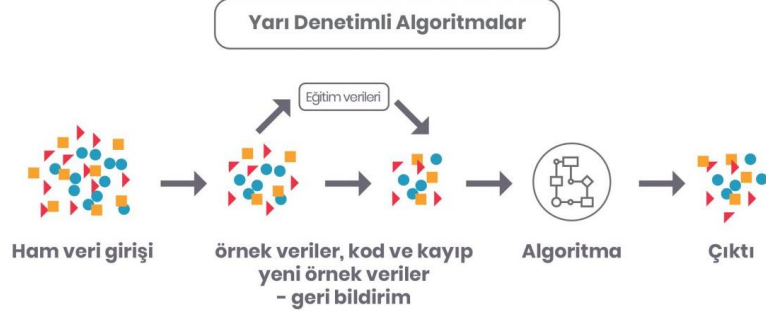
Bu öğrenme türü etiketlenmemiş veriler kullanılarak model eğitimi yapılmasını sağlar. Bu yöntemler, veri kümelerindeki gizli kalıpları veya yapıların keşfedilmesi için kullanılır. Örneğin, nörolojik bozuklukların erken belirtilerini belirlemek için hastaların MRI verileri üzerinde kümeleme algoritmaları kullanılabilir. Kümeleme, benzer veri noktalarını gruplandırarak verinin doğal yapısını anlamaya yardımcı olur. K-Means ve hiyerarşik kümeleme, denetimsiz öğrenmede yaygın olarak kullanılan yöntemlerdir. K-Means, veriyi önceden belirlenmiş bir sayıda kümeye ayırırken, hiyerarşik kümeleme veriyi ağaç benzeri bir yapıda gruplandırır. Şekil 4.2’de denetimsiz öğrenme yapısına bir örnek verilmiştir (Turhost 2024).



Şekil 4.2: Denetimsiz öğrenme mimarisini örneği

4.1.3 Yarı Denetimli Öğrenme

Bu öğrenme türünde model eğitimi, hem etiketli hem de etiketlenmemiş verilerin kullanılmasını içerir. Bu yöntem, özellikle etiketli veri miktarının sınırlı olduğu durumlarda faydalıdır. Nörolojik bozuklukların teşhisinde, yarı denetimli öğrenme, sınırlı etiketli tıbbi görüntü verileri ile daha geniş bir etiketlenmemiş veri setini birleştirerek modelin doğruluğunu artırabilir. Yarı denetimli öğrenme, etiketlenmiş verinin az olduğu durumlarda önemli bir avantaj sağlar, çünkü model hem etiketli hem de etiketlenmemiş verilerden öğrenir. Bu, nörolojik bozuklukların erken teşhisi ve sınıflandırılmasında daha etkili modellerin geliştirilmesine olanak tanır. Şekil 4.3’de yarı denetimli öğrenme yapısına bir örnek verilmiştir (Turhost 2024).




Şekil 4.3: Yarı denetimli öğrenme mimarisi örneği

4.2 Derin Öğrenme Yöntemleri

Derin öğrenme, makine öğreniminin bir alt dalıdır ve çok katmanlı yapay sinir ağlarını (ANN-Artificial Neural Networks) kullanarak veri analizinde üstün performans sergiler. Özellikle, derin öğrenme yöntemleri, büyük veri setleri üzerinde karmaşık desenleri ve yapıları tanımlamak için etkili araçlardır. Nörolojik bozuklukların tanı ve erken teşhisinde derin öğrenme yöntemlerinin kullanımı, tıbbi görüntüleme ve sinyal işleme alanlarında önemli gelişmeler sağlamıştır (Litjens ve diğ. 2017).

4.2.1 Evrişimli Sinir Ağları


Evrişimli Sinir Ağları, özellikle görüntü verisi üzerinde başarılı sonuçlar elde etmek için kullanılan derin öğrenme modelleridir. CNN'ler, görüntülerin özelliklerini otomatik olarak çıkarır ve sınıflandırma yapar. Bu modeller, katmanlar halinde düzenlenmiş evrişimsel ve havuzlama işlemlerini kullanarak veri özelliklerini öğrenir. Özellikle tıbbi görüntülemede, MRI ve CT taramaları gibi yüksek çözünürlüklü veriler üzerinde etkili sonuçlar elde edilmiştir. Örneğin (Brown ve diğ. 2014), CNN kullanarak Alzheimer hastalığının erken teşhisinde yüksek doğruluk oranlarına ulaşmışlardır. Şekil 4.4'de, COVID-19 hastalığı sınıflandırmasını gerçekleştiren CNN yapısına bir örnek verilmiştir (Latif ve diğ. 2024).



Şekil 4.4: CNN mimari örneği


CNN'lerin başarısının ardındaki temel faktörlerden biri, yerel özelliklerin çıkarılması ve bu özelliklerin daha yüksek katmanlarda birleştirilmesidir. Bu yöntem, nörolojik bozuklukların teşhisinde önemli bir avantaj sağlar, çünkü beyin görüntülerindeki küçük ve ince değişiklikleri tespit edebilir. Ayrıca, derin CNN modelleri, birçok katmanda yer alan nöronlar arasındaki bağlantıları öğrenerek, karmaşık veri yapılarında daha etkili sonuçlar elde eder. Bu nedenle, CNN'ler, özellikle beyin tümörlerinin sınıflandırılması ve epilepsi gibi nörolojik bozuklukların tespitinde yaygın olarak kullanılmaktadır (Deepak ve Ameer 2019).

ResNet50, derin sinir ağlarının (DNN-Deep Neural Network) eğitimi sırasında karşılaşılan kaybolan gradyan sorununu çözmek için artık bağlantıları kullanan bir CNN mimarisidir. 50 katmandan oluşan bu model, daha derin ağların eğitimini mümkün kılar ve performansını artırır. ResNet50, tıbbi görüntüleme geniş bir kullanım alanı bulmuştur. Örneğin (Sharabas ve diğ. 2024), ResNet50 modelini kullanarak MS teşhisinde başarılı sonuçlar elde etmişlerdir. Artık bağlantılar, modelin daha derin katmanlarda bile etkili bir şekilde öğrenmesini sağlar ve genel performansı artırır. Şekil 4.6'da ResNet50 mimarisi katman yapısı verilmiştir (Mukherjee 2024).



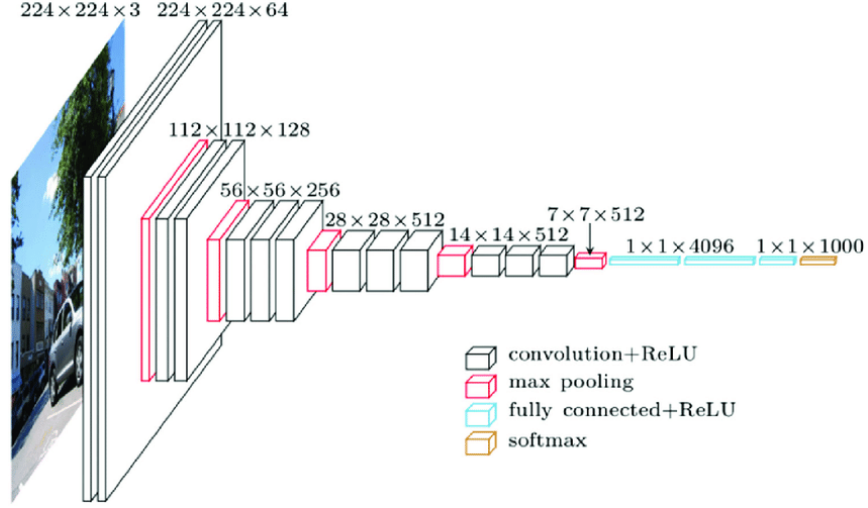
Şekil 4.5: Ön eğitilmiş ResNet50 mimarisi örneği

InceptionV3, Google tarafından geliştirilen bir CNN mimarisidir ve farklı boyutlardaki filtreleri bir arada kullanarak daha etkili özellik çıkarımı sağlar. Bu model, daha az hesaplama maliyeti ile yüksek doğruluk oranları sunar. InceptionV3, tıbbi görüntüleme çeşitli uygulamalarda kullanılmıştır. Örneğin (Saleh ve diğ. 2020), InceptionV3 modelini kullanarak beyin tümörlerinin sınıflandırılmasında yüksek doğruluk elde etmişlerdir. Inception mimarisi, farklı ölçeklerdeki özelliklerin aynı anda çıkarılmasını sağlayarak modelin genel performansını artırır. Şekil 4.7’de InceptionV3 mimarisi için katman mimarisi verilmiştir (Iparraguirre-Villanueva ve diğ. 2022).



Şekil 4.6: Ön eğitilmiş InceptionV3 mimarisi örneği

VGG16, derin öğrenme modelleri arasında popüler olan bir CNN mimarisidir ve 16 katmandan oluşur. Bu model, küçük 3x3 filtreler kullanarak derinliği artırır ve yüksek doğruluk oranları elde eder. VGG16, görüntü sınıflandırma yarışmalarında üstün performans göstermiştir ve TL için yaygın olarak kullanılmaktadır. Örneğin (Aydın ve diğ. 2019), VGG16 modelini kullanarak Alzheimer hastalığı tanısında başarılı sonuçlar elde etmişlerdir. VGG16, düşük hesaplama maliyetine rağmen yüksek doğruluk sağlayan etkili bir modeldir. Şekil 4.5’te örnek bir VGG16 mimarisi için katman yapısı ve derinliği ifade edilmiştir (Cai ve diğ. 2020).



Şekil 4.7: Ön eğitilmiş VGG16 mimarisi örneği

Bu çalışmada, belirli nörolojik bozuklukların teşhisi için özel olarak tasarlanmış bir CNN modeli de kullanılmaktadır. Bu model, giriş görüntüsünü (girdi_boyutu x girdi_boyutu x 3) olarak çeşitli evrişimsel ve havuzlama katmanlarından geçirir. İlk evrişim katmanı, 32 filtre ve 3x3 çekirdek boyutu ile başlar ve ReLU aktivasyon fonksiyonu kullanır. Takip eden havuzlama katmanı, maksimum havuzlama (max pooling) işlemi yaparak özellik haritalarını küçültür. İkinci ve üçüncü evrişim katmanları, daha derin özellikleri çıkarmak için he_uniform çekirdek başlatma ile 32 ve 64 filtre kullanır. Modelin düzleştirme (flatten) katmanı, evrişimsel katmanlardan gelen özellik haritalarını tek bir vektöre dönüştürür. Bunu, 64 nöronlu ve ReLU aktivasyon fonksiyonlu tam bağlantılı (dense) bir katman takip eder. Aşırı öğrenmeyi önlemek için, sönümlenme katmanı %30 oranında nöronları rastgele devre dışı bırakır. Son olarak, modelin çıktı katmanı, sınıf sayısına (num_classes) eşit nöron içerir ve softmax aktivasyon fonksiyonu kullanarak sınıflandırma yapar. Model, categorical_crossentropy kayıp fonksiyonu ve Adam optimizasyon algoritması ile derlenir ve doğruluk metriği ile değerlendirilir.


4.2.1.1 Önerilen CNN Modeli

Bu tez çalışmasında önerilen CNN modeli, toplamda 3 konvolüsyonel + aktivasyon + maksimum havuzlama katmanı bloğu içerir ve her bir Conv2D katmanı 3x3 filtre boyutuna sahiptir. İlk katman, giriş görüntüsünden 32 özellik haritası çıkarır

ve toplam 896 parametre içerir. Sonraki Conv2D katmanlarında kullanılan he_uniform ağırlık başlatma yöntemi modelin daha verimli öğrenmesini sağlar. Evrişim katmanlarının ardından, 2304 boyutunda bir düzleştirilmiş (flatten) çıktı elde edilir ve bu, 64 nöron içeren tam bağlantılı bir dense katmana aktarılır (147,520 parametre). Son katman olan tam bağlantılı katman, sınıf sayısına eşit çıktı üreterek (örneğin, num_classes = 2 için 130 parametre) softmax aktivasyon fonksiyonuyla sınıflandırma işlemini gerçekleştirir. Aşırı öğrenmeyi önlemek için ayrıca bir sönümlenme (dropout) katmanını bulunmaktadır. Tablo 4.1 ve Şekil 4.8’de önerilen CNN modelin katman yapısı ifade edilmiştir.

Tablo 4.1: Önerilen CNN modelinin katman yapısı

Katman (Tip)	Çıkış Şekli	Parametre Sayısı
Conv2d	None, 62, 62, 32	896
activation	None, 62, 62, 32	0
max_pooling2d	None, 31, 31, 32	0
Conv2d_1	None, 29, 29, 32	9,248
Activation_1	None, 29, 29, 32	0
max_pooling2d_1	None, 14, 14, 32	0
Conv2d_2	None, 12, 12, 64	18,496
activation_2	None, 12, 12, 64	0
Max_pooling2d_2	None, 6, 6, 64	0
flatten	None, 2304	0
dense	None, 64	147,520
Activation_3	None, 64	0
dropout	None, 64	0
Dense_1	None, num_classes	(64+1) x numClasses
Activation_4	None, num_classes	0



Şekil 4.8: Önerilen CNN modelinin yapısı

Bu çalışmada, nörolojik rahatsızlıkların görüntülerini sınıflandırmak için bir CNN modeli geliştirilmiştir. Model, üç katmanlı evrişim katmanları, maksimum havuzlama (max pooling) katmanları, tam bağlantılı (fully connected) katmanlar ve sönümleme katmanlarından oluşmaktadır.

Modelin ilk katmanı, giriş görüntülerini almak için 32 filtrelili bir evrişimli katman içerir. Bu katmanda, her filtre 3x3 boyutundadır ve ReLU aktivasyon fonksiyonu kullanılarak doğrusal olmayanlık eklenmiştir. ReLU aktivasyonu, hesaplama açısından verimli olması ve derin ağların daha hızlı ve etkili öğrenmesini sağlaması nedeniyle tercih edilmiştir. Bu katmanın ardından, özellik haritalarını boyut olarak küçültmek ve önemli özellikleri daha belirgin hale getirmek amacıyla 2x2 boyutunda maksimum havuzlama katmanı uygulanmıştır.

İkinci evrişim katmanı, yine 32 filtreye sahiptir ve aynı şekilde 3x3 boyutunda filtreler kullanır. Bu katmanda da ReLU aktivasyon fonksiyonu kullanılarak modelin doğrusal olmayan öğrenme kapasitesi artırılmıştır. Bu katmandan sonra, tekrar maksimum havuzlama katmanı eklenerek özellik haritalarının boyutu küçültülmüş ve önemli özellikler daha da belirgin hale getirilmiştir.

Üçüncü evrişim katmanı, 64 filtreye sahiptir ve önceki katmanlarda olduğu gibi 3x3 boyutunda filtreler kullanır. Bu katmanda da ReLU aktivasyon fonksiyonu tercih edilmiştir. Üçüncü evrişim katmanının ardından, yine maksimum havuzlama katmanı eklenmiştir.

Evrişim ve havuzlama katmanlarından sonra model, düzleştirme (flattening) katmanı ile devam eder. Bu katman, üç boyutlu özellik haritalarını tek boyutlu bir vektöre dönüştürür. Bu vektör, tam bağlantılı katmana aktarılır. Tam bağlantılı katmanda 64 nöron bulunur ve ReLU aktivasyon fonksiyonu kullanılarak modelin öğrenme kapasitesi artırılır.

Modelin aşırı öğrenmesini (overfitting) önlemek için, tam bağlantılı katmandan sonra sönümlenme katmanı eklenmiştir. Bu katman, eğitim sırasında nöronların belirli bir oranını rastgele devre dışı bırakarak modelin genelleme yeteneğini artırır. Sönümlenme oranı 0.3 olarak belirlenmiştir, bu da nöronların %30'unun eğitim sırasında devre dışı bırakılacağı anlamına gelir.

Son olarak, modelin çıkış katmanı, sınıflandırma problemini çözmek için softmax aktivasyon fonksiyonu ile donatılmıştır. Bu katman, sınıf sayısı kadar nöron içerir ve her bir nöron, bir sınıfa ait olasılığı temsil eder.

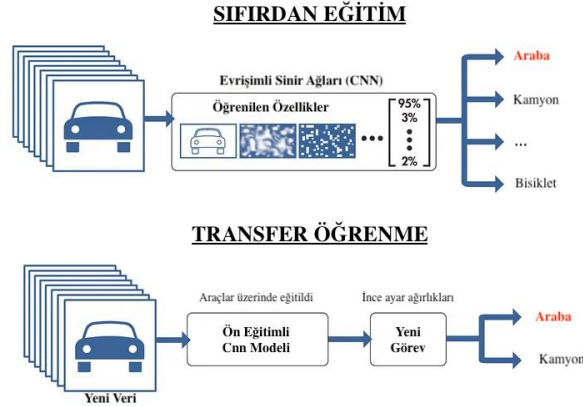
Model, kategorik çapraz entropi (categorical crossentropy) kayıp fonksiyonu ve Adam optimizasyon algoritması kullanılarak derlenmiştir. Kategorik çapraz entropi, çok sınıflı sınıflandırma problemlerinde yaygın olarak kullanılan bir kayıp fonksiyonudur ve modelin çıktısını hedef sınıf dağılımına uygun şekilde optimize eder. Adam optimizasyon algoritması ise, adaptif öğrenme oranları kullanarak modelin daha hızlı ve etkili bir şekilde öğrenmesini sağlar. Sonuç olarak, bu CNN modeli, beyin tümörü görüntülerini sınıflandırma görevinde başarılı sonuçlar elde etmek üzere tasarlanmıştır. Modelin performansı, doğruluk (accuracy) metriği ile değerlendirilmiştir ve eğitim süreçlerinde elde edilen sonuçlar, modelin etkinliğini göstermektedir.

4.2.2 Transfer Öğrenme

TL, daha önce geniş veri setlerinde eğitilmiş modellerin, yeni ve benzer görevlerde yeniden kullanılmasını sağlayan bir tekniktir. Bu yöntem, özellikle sınırlı veri setlerine sahip tıbbi görüntüleme ve nörolojik bozuklukların teşhisi gibi alanlarda büyük avantajlar sunar. TL, kaynak domainindeki öğrenilen bilgilerin hedef domainine transfer edilmesiyle modelin eğitim sürecini hızlandırır ve performansını

artırır. Örneğin (Raghu ve diğ. 2020), epilepsi tespiti için CNN tabanlı TL yöntemleri kullanarak yüksek doğruluk oranları elde etmişlerdir.

TL, nörolojik bozuklukların erken teşhisi ve sınıflandırılmasında, derin öğrenme modellerinin performansını artırmak için kullanılmaktadır. Örneğin, ön eğitilmiş VGG16 modelinin, sınırlı sayıda MRI verisi ile eğitilerek Alzheimer hastalığı tanısında kullanılması, modelin doğruluğunu ve genelleme yeteneğini artırmıştır (Aydın ve diğ. 2019). Benzer şekilde, ResNet50 modeli, MS teşhisinde başarılı sonuçlar vermiştir (Sharabas ve diğ. 2024). TL, sınırlı veri ile daha etkili modeller geliştirilmesine olanak tanır, bu da nadir nörolojik hastalıkların teşhisinde kritik bir avantaj sağlar. Şekil 4.9’da sıfırdan bir eğitim ile Transfer öğrenme arasındaki basit fark ifade edilmiştir (Nova Research Lab 2024).



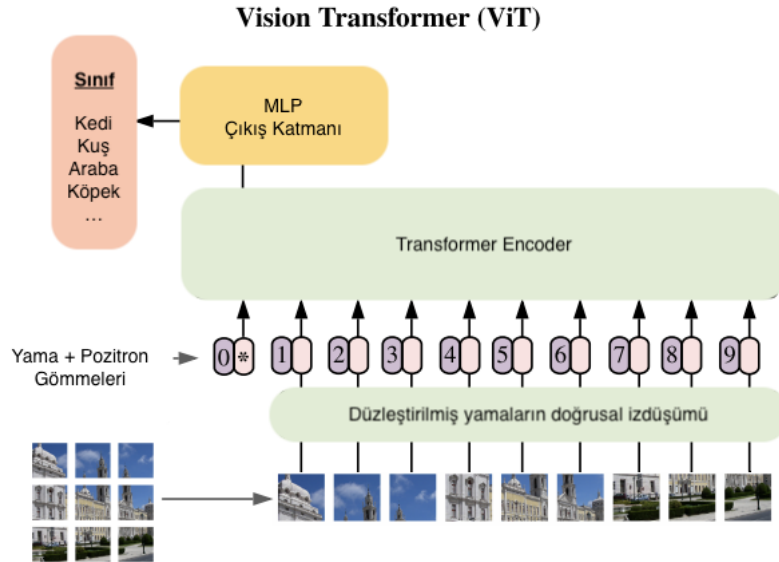
Şekil 4.9: Transfer öğrenme şema görünümü

4.2.3 Görüntü Transformatörleri

ViT, son yıllarda görüntü işleme görevlerinde büyük ilgi gören ve başarılı sonuçlar elde eden derin öğrenme modelleridir. Transformatör mimarisi, ilk olarak doğal dil işleme (NLP) alanında (Vaswani ve diğ. 2017) tarafından tanıtılmıştır. Transformatörler, dikkat mekanizması (attention mechanism) kullanarak, dizilerdeki uzun menzilli bağıntıları etkili bir şekilde öğrenme yeteneğine sahiptir. Bu mimari, NLP görevlerinde büyük başarılarla imza attıktan sonra, görsel veriler üzerinde de uygulanmıştır.

ViT, ilk olarak (Dosovitskiy ve diğ. 2020) tarafından tanıtılmıştır. Bu model, görüntüleri küçük parçalara (patch) bölerek her bir parçayı bir dizi olarak işler ve bu diziler arasındaki ilişkileri öğrenir. Her bir görüntü parçası, transformatör mimarisinin girdi olarak kullandığı bir dizi vektör olarak temsil edilir. Bu yaklaşım, görüntülerin yüksek düzeyde öznetelik çıkarımını ve uzun menzilli bağıntıların öğrenilmesini sağlar. ViT'in temel avantajı, büyük ölçekli veri setleri üzerinde önceden eğitilmiş modellerin, TL ile farklı tıbbi görüntüleme görevlerine uyarlanabilmesidir.

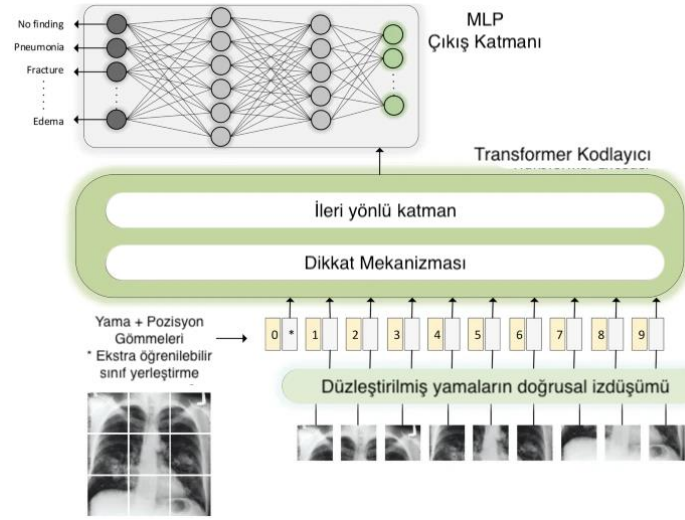
ViT, görsel verilerin işlenmesinde geleneksel CNN'lere kıyasla bazı önemli avantajlar sunar. Özellikle, ViT, yüksek çözünürlüklü görüntülerdeki ince detayları tespit etmede üstün performans gösterir. Bu, nörolojik bozuklukların erken teşhisi için büyük bir avantaj sağlar. (Asiri ve diğ. 2023), ViT kullanarak beyin tümörlerinin sınıflandırılmasında başarılı sonuçlar elde etmişlerdir. ViT 'in, görüntüleri daha küçük parçalara bölerek işlemesi, modelin görsel verilerdeki ince detayları daha iyi öğrenmesini sağlar. Şekil 4.10'da görüntü transformatörlerinin gösterimine yer verilmiştir (Dosovitskiy ve diğ. 2020).



Şekil 4.10: Görsel transformatör mimarisi

ViT'in en büyük avantajlarından biri, büyük veri setleri üzerinde önceden eğitilmiş modellerin, TL ile farklı tıbbi görüntüleme görevlerinde kullanılabilmesidir. Bu, nörolojik bozuklukların teşhisinde ViT'in etkinliğini artırır. (Hussein ve diğ.

2022), EEG verilerini kullanarak epilepsi nöbetlerini tespit etmek için ViT tabanlı modeller geliştirmişlerdir ve yüksek doğruluk oranları elde etmişlerdir. TL, ViT 'in önceden öğrenilmiş öznitelikleri yeni görevlerde kullanmasını sağlar, bu da modelin eğitim sürecini hızlandırır ve performansını artırır. Şekil 4.11'de görsel transformatörlerdeki dikkat mekanizmasına yer verilmiştir (Usman ve diğ. 2022).



Şekil 4.11: Görsel transformatör – dikkat mekanizması

Transformatör mimarisi, NLP alanında büyük başarılar elde eden Üretken Önceden Eğitilmiş Transformatör (GPT-3- Generative Pre-trained Transformer 3) gibi modellerin de temelini oluşturur. GPT-3, metin üretme, dil anlama ve çeviri gibi çeşitli görevlerde üstün performans sergileyen bir dil modelidir. Transformatör mimarisinin bu başarısı, aynı mimarinin görsel veriler üzerinde de etkili olabileceğini göstermiştir. ViT, Transformatörlerin bu başarısını görsel veri işleme alanına taşır, bu da tıbbi görüntüleme ve nörolojik bozuklukların teşhisinde yeni kapılar açar.

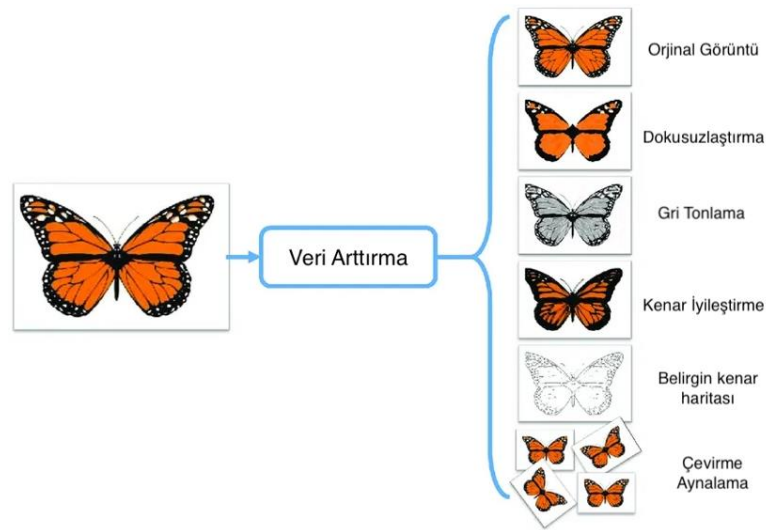
ViT, nörolojik bozuklukların teşhisinde büyük potansiyel sunar. Yüksek çözünürlüklü beyin görüntülerinde ince detayları tespit edebilme yeteneği, ViT'in nörolojik bozuklukların erken teşhisinde önemli bir araç olmasını sağlar. Örneğin, Alzheimer hastalığının erken evrelerinde beyin yapısındaki küçük değişikliklerin tespit edilmesi, hastalığın ilerlemesini yavaşlatmak için kritik öneme sahiptir. ViT, bu tür detayları etkili bir şekilde tespit edebilir ve nörolojik bozuklukların teşhisinde yüksek doğruluk oranları sunabilir.

4.3 Veri Ön İşleme Süreçleri

Veri ön işleme, makine öğrenimi ve derin öğrenme modellerinin performansını doğrudan etkileyen kritik bir aşamadır. Özellikle tıbbi görüntüleme verileri gibi karmaşık ve yüksek boyutlu verilerle çalışırken, doğru veri ön işleme tekniklerinin kullanılması, modelin doğruluğunu ve genelleme kapasitesini artırır.

4.3.1 Veri Artırımı

Veri artırımı (data augmentation), mevcut veri setinin boyutunu ve çeşitliliğini artırmak için çeşitli dönüşüm tekniklerinin uygulanmasıdır. Bu teknikler, modelin aşırı uyum yapmasını engeller ve genel performansını artırır. Veri artırımı teknikleri arasında döndürme, ölçekleme, kaydırma, parlaklık ve kontrast ayarları gibi işlemler yer alır. Örneğin (Shorten ve Khoshgoftaar 2019), veri artırma tekniklerinin derin öğrenme modellerinin performansını nasıl artırdığını kapsamlı bir şekilde incelemişlerdir. Beyin tümörü sınıflandırma çalışmasında, veri artırma tekniklerinin kullanılması modelin doğruluğunu önemli ölçüde artırmıştır. Şekil 4.12’de veri artırma yöntemleri örneği yer almaktadır (Singh 2024). Bu tezde gerçekleştirilen benzetimler için tüm model eğitimlerinde veri kümelerine veri artırımı işlemi uygulanmıştır.



Şekil 4.12: Veri artırma örnekleri

4.3.2 Veri Normalizasyonu

Veri normalizasyonu, her bir özelliğin (feature) belirli bir aralıkta (genellikle 0 ile 1 arasında) olmasını sağlayarak, modelin daha hızlı ve kararlı bir şekilde öğrenmesini sağlar. Normalizasyon, özellikle tıbbi görüntüleme verilerinde farklı kontrast ve parlaklık seviyelerinin dengelenmesi için kritik öneme sahiptir. Çeşitli çalışmalar, normalizasyonun model performansı üzerindeki olumlu etkilerini göstermektedir. Örneğin, (Ioffe 2015) tarafından tanımlanan Yığın Normalleştirme (Batch Normalization), model eğitimi sırasında her bir mini-yığın'daki verilerin ortalama ve standart sapmalarını kullanarak verileri normalize eder. Bu teknik, DNN'in eğitimini hızlandırır ve modelin genelleme kapasitesini artırır. Tez boyunca tüm model eğitimlerinde $[0,1]$ aralığında normalizasyon uygulanmıştır.

4.3.3 Eğitim ve Doğrulama Verisi Ayrımı

Eğitim ve doğrulama verisi ayrımı, modelin performansını objektif bir şekilde değerlendirmek için önemlidir. Eğitim verisi, modelin öğrenmesi için kullanılırken, doğrulama verisi, modelin genelleme kapasitesini test etmek için kullanılır. Tipik olarak, veri setinin %70-80'i eğitim için, %20-30'u ise doğrulama için ayrılır. Bu ayırım, modelin aşırı uyum yapmasını engeller ve gerçek dünyadaki performansını tahmin etmek için daha güvenilir bir yöntem sunar. Tez boyunca yapılan tüm model eğitimlerinde, veri setlerinin %80'i eğitim, %20'si ise test amacıyla kullanılmıştır.

4.3.4 Sınıf Dengeleme

Sınıf dengeleme, veri setindeki sınıfların dengesiz dağılımını düzeltmek için kullanılan bir tekniktir. Dengesiz sınıflar, modelin bazı sınıfları öğrenmesini zorlaştırabilir ve genel performansı düşürebilir. Sınıf dengeleme teknikleri arasında az temsil edilen sınıfın örneklerini artırma (oversampling) ve çok temsil edilen sınıfın örneklerini azaltma (undersampling) bulunur. Örneğin, (He ve Ma 2013), sınıf dengesizliğinin model performansı üzerindeki etkilerini incelemiş ve çeşitli dengeleme tekniklerinin model doğruluğunu nasıl artırdığını göstermiştir. Tez boyunca tüm model eğitim sürecinde sınıf dengeleme yapılmamıştır. Bu tercih

nedeni, kullanılan veri setlerinin doğrudan kaynaktan indirilmiş ve modellerin tekrarlanabilir, kıyaslanabilir olmasını sağlamak için kaynaktaki ile aynı olması sağlanmıştır.

4.4 Değerlendirme Metrikleri

Modelin performansını değerlendirmek için çeşitli metrikler kullanılır. Bu metrikler, modelin ne kadar doğru ve etkili bir şekilde çalıştığını belirlemek için gereklidir. Her bir metrik, farklı bir performans boyutunu ölçer ve bu sayede modelin güçlü ve zayıf yönleri daha iyi anlaşılabilir.

Doğruluk (accuracy), modelin doğru tahminlerinin toplam tahminlere oranını ifade eder. Özellikle dengeli sınıf dağılımına sahip veri setlerinde kullanışlıdır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Kesinlik (precision), pozitif sınıfa ait tahminlerin doğruluğunu ölçer. Yani, modelin pozitif olarak tahmin ettiği örneklerden kaçının gerçekten pozitif olduğunu gösterir. Özellikle, yanlış pozitiflerin maliyetinin yüksek olduğu durumlarda önemlidir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

Duyarlılık (recall), pozitif sınıfa ait gerçek örneklerin ne kadarının doğru tahmin edildiğini gösterir. Başka bir deyişle, modelin pozitif örnekleri ne kadar iyi yakalayabildiğini ölçer. Özellikle, yanlış negatiflerin maliyetinin yüksek olduğu durumlarda önemlidir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3)$$

F1 skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır ve dengesiz veri setlerinde daha güvenilir bir performans ölçütüdür. Yüksek F1 skoru, modelin hem yanlış pozitifleri hem de yanlış negatifleri iyi yönettiğini gösterir.

$$F1 \text{ Skoru} = \frac{\text{Kesinlik} \times \text{Duyarluluk}}{\text{Kesinlik} + \text{Duyarluluk}} \quad (4)$$

4.5 Hiperparametre Optimizasyonları


Hiperparametreler, makine öğrenimi modellerinin yapılandırılmasını ve eğitim sürecini etkileyen ayarlanabilir parametrelerdir. Bu bölümde, kullanılan derin öğrenme modelinin hiperparametrelerinin nasıl optimize edildiği açıklanmaktadır.

4.5.1 Öğrenme Oranı

Öğrenme oranı (learning rate), modelin her iterasyonda ne kadar hızlı öğrendiğini belirleyen önemli bir hiperparametredir. Yüksek bir öğrenme oranı, modelin hızlı bir şekilde eğitilmesine yol açabilir, ancak aşırı uyum (overfitting) riskini artırabilir. Düşük bir öğrenme oranı, modelin daha yavaş öğrenmesine neden olabilir, ancak daha istikrarlı bir şekilde eğitilmesini sağlayabilir (Goodfellow ve diğ. 2016). Genellikle öğrenme oranı planlaması (learning rate schedule) veya öğrenme oranı düşüşü (learning rate decay) kullanılarak optimize edilmektedir (Smith 2017). Bu tez boyunca öğrenme oranı '0.001' olarak belirlenmiştir."

4.5.2 Dönem Sayısı

Dönem sayısı (Epochs), modelin eğitim veri seti üzerinde kaç kez geçtiğini belirten bir hiperparametredir. Daha fazla dönem, modelin daha fazla öğrenme fırsatı bulmasını sağlayabilir, ancak aşırı uyum riskini artırabilir. Daha az dönem, modelin daha hızlı eğitilmesine neden olabilir, ancak daha düşük bir performansa yol açabilir (Goodfellow ve diğ. 2016). Erken durdurma (early stopping) yöntemi, modelin eğitim sürecinde belirli bir performans kriteri karşılanmadığında eğitimi durdurmak için kullanılır (Prechelt 2002). Şekil 4.13'te doğru dönem sayısı seçimi için örnek bir grafiğe yer verilmiştir, (Vijay 2024) kaynağından alınmış ve veriler Türkçe olarak düzenlenmiştir. Tüm tez boyunca dönem sayısı 20 olarak alınmıştır. Ayrıca modellerin optimum sonuçları için en az 5 kez eğitim tekrarlanmıştır.



Şekil 4.13: Öğrenme ve test hatası grafiği üzerinde doğru noktanın belirlenmesi

4.5.3 Mini-Batch Boyutu

Mini-batch boyutu, eğitim veri setinin küçük parçalarının (mini-batch) modelin her eğitim iterasyonunda kullanılmasını belirleyen bir hiperparametredir. Küçük bir mini-batch boyutu, bellek kullanımını azaltabilir ancak eğitim süresini uzatabilir. Büyük bir mini-batch boyutu, bellek kullanımını artırabilir ancak eğitim süresini azaltabilir. Optimal batch boyutu, model performansı ve eğitim süresi arasında denge kurarak seçilmelidir (Masters ve Luschi 2018). Tezde kullanılan tüm model eğitim süreçlerinde mini-batch boyutu 32 olarak sabitlenmiştir. Bunun temel sebebi kullanılan bilgisayarın grafik kartının vram değeridir.

4.5.4 Optimizasyon Algoritması

Optimizasyon algoritması, modelin eğitim sırasında kullanılan optimizasyon yöntemini belirleyen bir hiperparametredir. SGD (Stokastik Gradyan Azalma), Adam, RMSProp gibi farklı optimizasyon algoritmaları kullanılabilir. Her bir optimizasyon algoritmasının avantajları ve dezavantajları vardır, bu nedenle en uygun optimizasyon algoritması dikkatlice seçilmelidir (Ruder 2016). Tez sürecinde tüm modellerde optimizasyon algoritması olarak “Adam” kullanılmıştır.

4.5.5 Sönümlenme Oranı

Sönümlenme (dropout), aşırı uyumu azaltmak için kullanılan bir düzenleme tekniğidir. Sönümlenme oranı, her eğitim iterasyonunda birimlerin rastgele devre dışı bırakılma olasılığını belirleyen bir hiperparametredir. Daha yüksek bir sönümlenme oranı, daha fazla düzenleme sağlayabilir, ancak modelin performansını azaltabilir (Srivastava ve diğ. 2014). Tez boyunca TL'e tabi tutulan daha önce eğitilmiş modeller için sönümlenme oranı "0.3" olarak belirlenmiştir.

4.5.6 Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, sinir ağı katmanlarında kullanılan non-lineer fonksiyonlardır. ReLU, Leaky ReLU, Sigmoid, Tanh gibi farklı aktivasyon fonksiyonları kullanılabilir. Her aktivasyon fonksiyonunun farklı avantajları ve dezavantajları vardır, bu nedenle en uygun aktivasyon fonksiyonları seçilmelidir (Nwankpa ve diğ. 2018). Tez boyunca iki farklı aktivasyon fonksiyonu kullanılmıştır: flatten katmanından sonra 'relu', sınıf sayısının eklendiği dense katmanında ise 'softmax' aktivasyon fonksiyonları tercih edilmiştir.

4.5.7 Batch Normalizasyonu

Batch normalizasyon, ağı her katmanının çıktılarını normalize etmek için kullanılan bir tekniktir. Batch normalizasyon, ağı daha hızlı ve daha istikrarlı bir şekilde eğitilmesine yardımcı olabilir, ancak bazı durumlarda modelin performansını azaltabilir. Bu nedenle, batch normalizasyonunun etkisi dikkatlice değerlendirilmelidir (Ioffe 2015). Önerilen CNN modelinde batch normalizasyonu uygulanmamıştır.

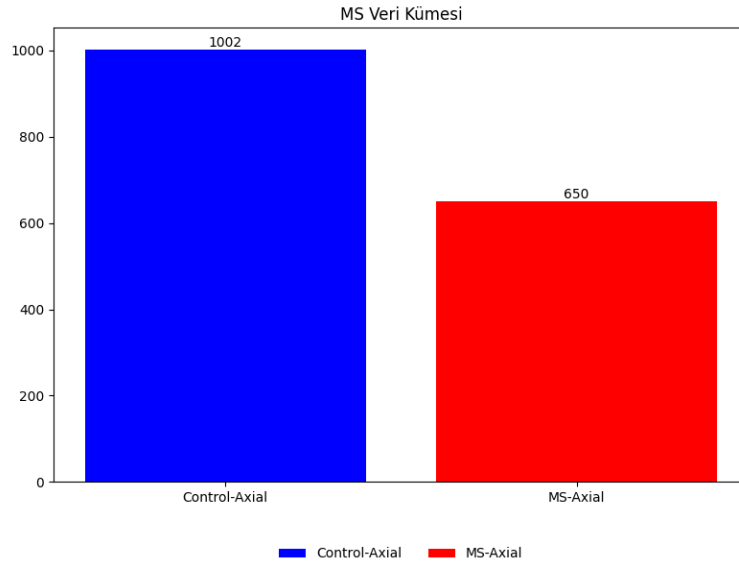
4.6 Veri Kümeleri

Bu tezde nörolojik bozuklukların TL temelli analizi için farklı sınıflar içeren MS, Alzheimer ve beyin tümörü hastalıklarına ait Kaggle platformundan temin edilen

5 farklı veri kümesi kullanılmıştır. Devam eden alt bölümlerde bu veri kümeleri tanıtılmaktadır.

4.6.1 MS-2 Veri Kümesi

Bu çalışmada kullanılan veri kümesi Kaggle platformundan temin edilmiştir. Veri kümesi iki sınıflı MS hastalığının teşhisi ve analizi için toplanmış 1652 görüntüden oluşmaktadır. Görüntüler, hastalığın belirgin özelliklerini içerecek şekilde seçilmiş ve etiketlenmiştir. Her bir görüntü, hasta (MS-Axial) veya sağlıklı (Control-Axial) olarak sınıflandırılmıştır. Şekil 4.14'te, Kaggle'dan temin edilen iki sınıflı MS (MS-2) veri kümesinin görsel dağılımları verilmiştir (Macin ve diğ. 2022).

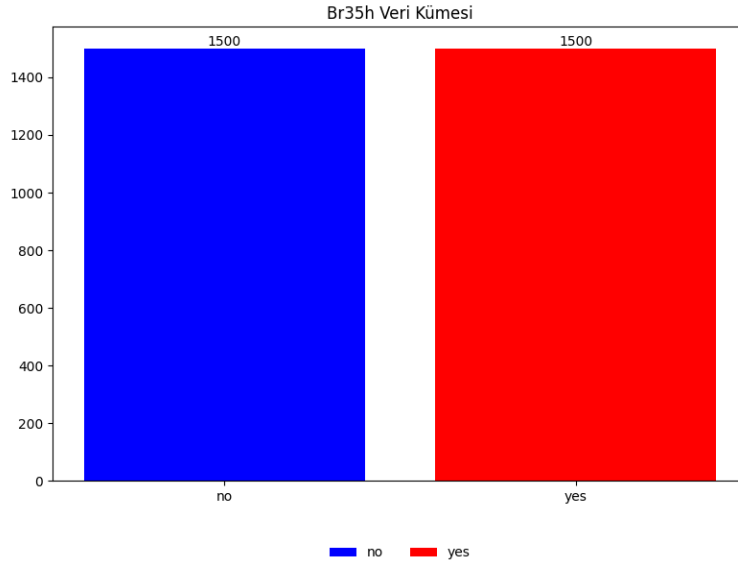


Şekil 4.14: MS-2 veri kümesi sınıf dağılımı

4.6.2 Br35h Veri Kümesi

Bu çalışmada, beyin tümörü sınıflandırma görevinde iki sınıflı Br35h veri kümesi kullanılmıştır. Br35h, çeşitli kaynaklardan toplanmış ve iki ana sınıfa ayrılmış MRI beyin taramaları içermektedir: tümör bulunanlar "Yes" ve tümör bulunmayanlar "No" olarak ifade edilmiştir. Veri kümesi, farklı hastaneler ve kliniklerden elde edilen ve standart MRI cihazları kullanılarak toplanan MRI görüntülerinden oluşmaktadır.

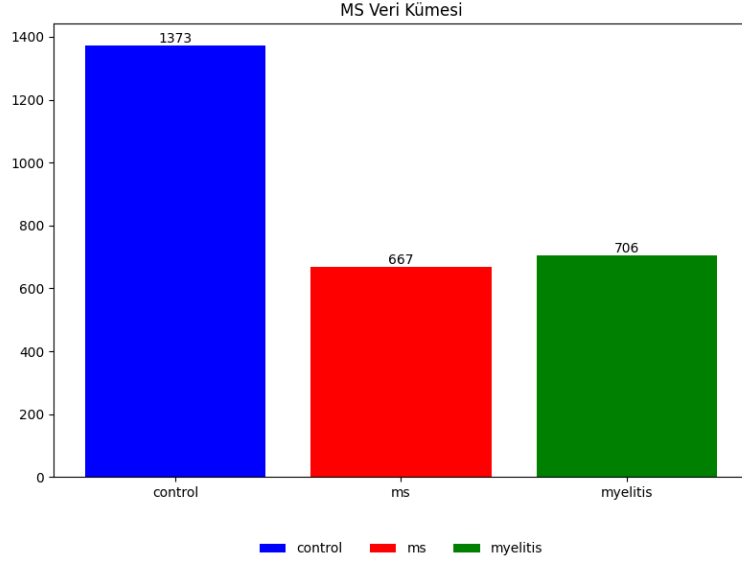
Görüntüler, etik kurallara uygun olarak anonimleştirilmiştir. Veri kümesi, toplamda 3000 görüntüden oluşmaktadır. Bu görüntülerin 1500'ü hasta bireylerden, diğer 1500'ü ise sağlıklı bireylerden elde edilmiştir. Bu dağılım, dengeli bir veri kümesi oluşturulmasını sağlamıştır. Kaggle platformu üzerinden temin edilen iki sınıflı Br35h veri kümesine ait görsel dağılımlar Şekil 4.14'te verilmiştir (Hamada 2024).



Şekil 4.15: Br35h veri kümesi sınıf dağılımı

4.6.3 MS-3 Veri Kümesi

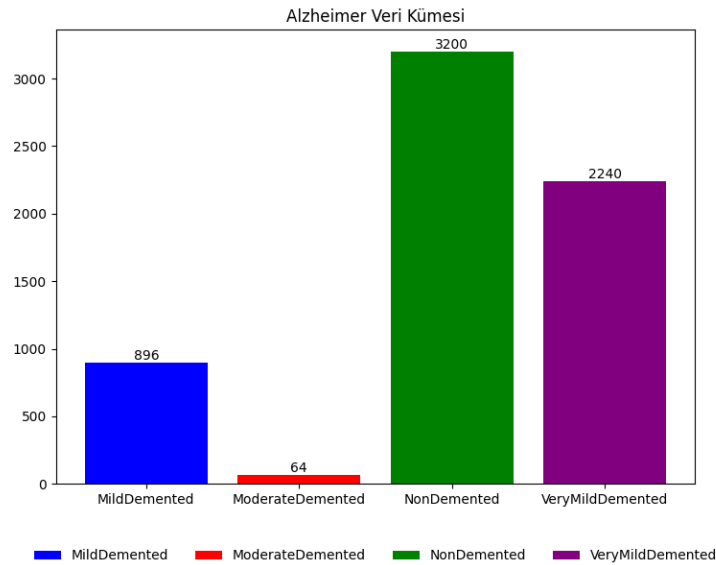
Üç sınıflı MS (MS-3) veri kümesi Türker Tuncer (Tuncer 2024) tarafından oluşturulmuştur. Veri kümesinde toplam 2746 görüntü bulunmaktadır. Sınıflar sırasıyla; “Control”, “MS”, “Myelitis” sınıflarından oluşmaktadır. Görüntü dağılımı MS için 667 görsel, Myelitis için 706 görsel bulundurmaktadır. Bunlara karşılık kontrol sınıfında 1373 görsel bulunmaktadır. Kaggle üzerinden temin edilen MS-3 veri kümesine ait görsel dağılımlar Şekil 4.15'te verilmiştir.



Şekil 4.16: MS-3 veri kümesi sınıf dağılımı

4.6.4 Alzheimer Veri Kümesi

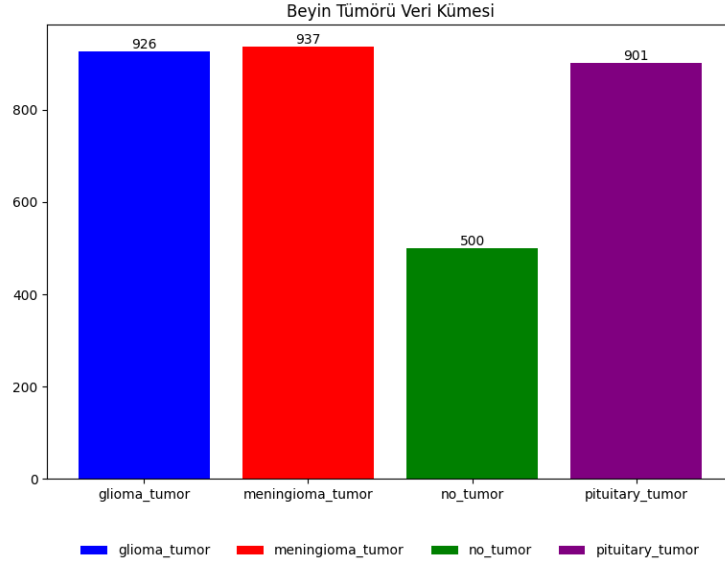
Bu çalışmada kullanılan 4 sınıflı Alzheimer veri kümesinde toplam 6400 görsel bulunmaktadır. Veri kümesi, sınıfları arası doğrusal bir dağılım göstermemektedir. Bundan dolayı bazı önceden eğitilmiş CNN algoritmalarında başarımın düşük olması olasıdır. Kaggle üzerinden temin edilen Alzheimer veri kümesinin görsel dağılımları Şekil 4.16'da verilmiştir (Shakir 2024).



Şekil 4.17: Alzheimer veri kümesi sınıf dağılımı

4.6.5 Tumor Veri Kümesi

Bu tezde kullanılan tumor veri kümesinde, toplam 3264 görsel bulunmaktadır. 4 sınıflı bu veri kümesinde sağlıklı bireyler sınıfı dışında kalan sınıflar için veri kümesinin dağılımı oldukça yakındır. Veri kümesi Kaggle üzerinden temin edilmiş ve veri kümesine ait görsel dağılımlar Şekil 4.17’de verilmiştir (Bhuvaji 2024).



Şekil 4.18: Tumor veri kümesi sınıf dağılımı

5. UYGULAMA SONUÇLARI

Bu bölümde 4. Bölümde tanıtılan veri setleri üzerinde deneysel çalışma sonuçlarına yer verilmiştir. Öncelikle bu tezde önerilen CNN modeli ile ilgili sınıflandırma sonuçları anlatılmıştır. Ardından ön eğitilmiş modeller olan VGG16, ResNet50, InceptionV3 ve ViT modellerinin test sonuçlarına yer verilmiştir.

5.1 Önerilen CNN Modeli Sınıflandırma Sonuçları

Bu bölümde, önerilen CNN modelinin farklı veri kümeleri üzerindeki sınıflandırma sonuçları detaylı olarak sunulmuştur. Her bir alt başlık altında, ilgili veri kümesi için elde edilen sonuçlar, modelin performansını değerlendirmek üzere hassasiyet, doğruluk, özgüllük ve F1 skoru gibi metrikler kullanılarak analiz edilmiştir. Bu bölümde, önerilen CNN modelinin farklı veri kümeleri üzerindeki sınıflandırma sonuçları detaylı olarak sunulmuştur. Her bir alt başlık altında, ilgili veri kümesi için elde edilen sonuçlar, modelin performansını değerlendirmek üzere hassasiyet, doğruluk, özgüllük ve F1 skoru gibi metrikler kullanılarak analiz edilmiştir.

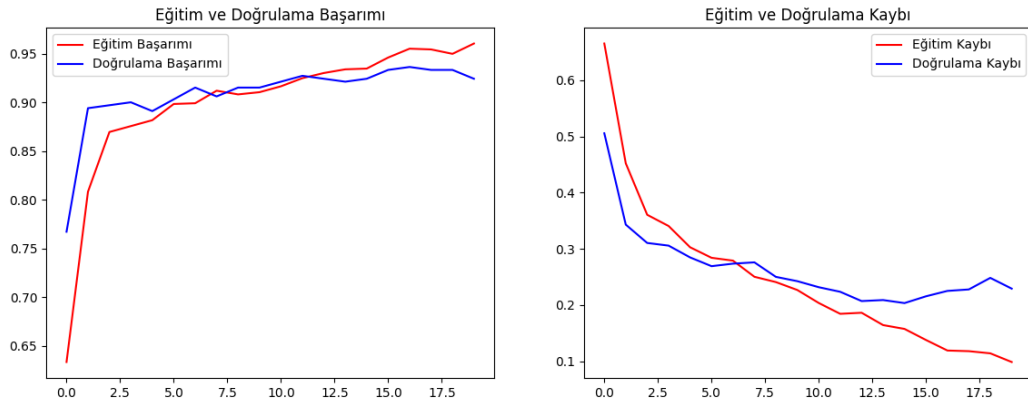
5.1.1 MS-2 Veri Kümesi için Sınıflandırma Sonuçları

MS-2 veri kümesi ile gerçekleştirilen benzetim sonuçları Tablo 5.1’de yer almaktadır. Sınıflandırma sonuçları, kesinlik, duyarlılık ve F1-skor metriklerini içermektedir.

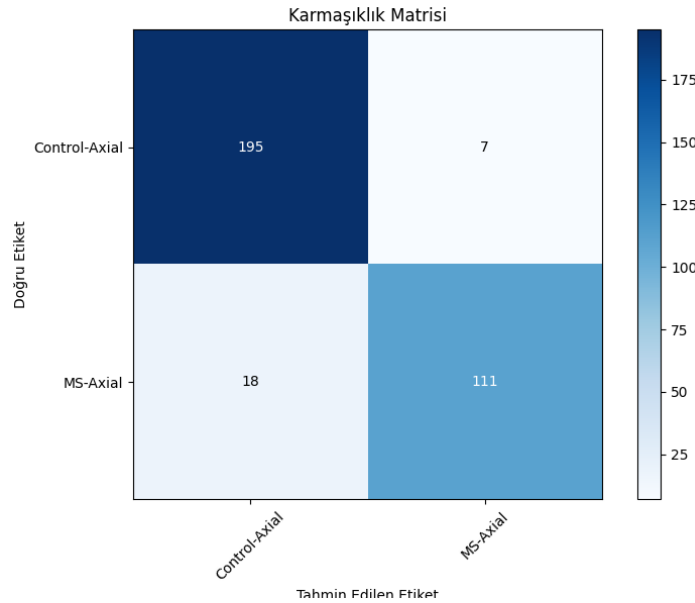
Tablo 5.1: CNN modeli için MS-2 veri kümesine ait performans sonuçları

	Kesinlik	Duyarlılık	F1- Skoru	Örnek Sayısı
Control-Axial	0.92	0.97	0.94	202
MS-Axial	0.94	0.86	0.90	129
Genel			0.92	331
Doğruluk				
Macro Ort.	0.93	0.91	0.92	331
Ağırlıklı Ort.	0.93	0.92	0.92	331

Benzetim sonuçlarına göre, “Control-Axial” sınıfında modelin daha yüksek duyarlılık değerine ulaşması bu sınıfta daha fazla doğru pozitif tahmin yaptığı anlamına gelir. “MS-Axial” sınıfında kesinlik değerinin daha yüksek olması, bu sınıfta daha az yanlış pozitif tahmin yapıldığını gösterir. Bu durum Şekil 5.1’de grafik üzerinde görülmektedir. F1 skorunun 0.924 elde edilmesi, modelin sınıflar arasında dengeli bir performansa sahip olduğunu ve her iki sınıfta da başarılı tahminler yapabildiğini göstermektedir. Model performansını ifade etmek amacıyla kullanılan ve Şekil 5.2’de görülen karmaşıklık matrisi, modelin doğru ve yanlış sınıflandırmalarını görselleştirir.



Şekil 5.1: CNN modeli için MS-2 veri kümesi eğitim ve doğrulama kaybı sonuçları



Şekil 5.2: CNN modeli ile MS-2 veri kümesi için karmaşıklık matrisi

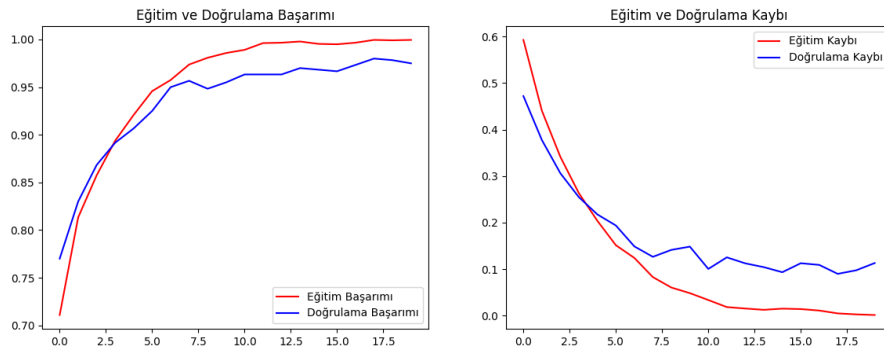
5.1.2 Br35h Veri Kümesi için Sınıflandırma Sonuçları

Beyin tümörü içeren Br35h veri kümesinde toplam 3000 görsel bulunmaktadır. Bu veri seti için önerilen CNN modeli ile elde edilen sınıflandırma sonuçları Tablo 5.2’de görülmektedir.

Tablo 5.2: CNN modeli için Br35h veri kümesine ait performans sonuçları

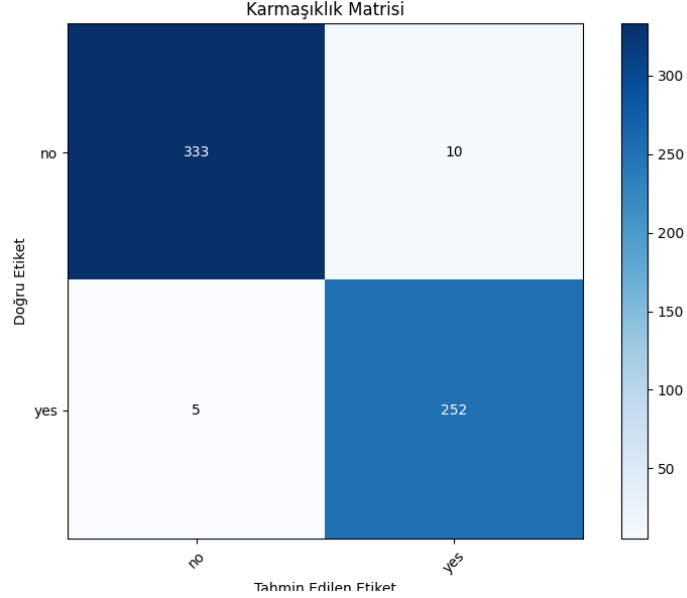
	Kesinlik	Duyarlılık	F1- Skoru	Örnek Sayısı
No	0.99	0.97	0.98	343
Yes	0.96	0.98	0.97	257
Genel Doğruluk			0.97	600
Macro Ort.	0.97	0.98	0.97	600
Ağırlıklı Ort.	0.98	0.97	0.98	600

Elde edilen sonuçlar, önerilen modelin Br35h veri kümesi üzerinde yüksek bir doğruluk ve tutarlılıkla çalıştığını göstermektedir. Model, “No” sınıfında %99 doğruluk ve “Yes” sınıfında %96 doğruluk sergilemiştir. Genel F1 skoru 0.9750 olup, bu da modelin sınıflandırma performansının oldukça yüksek olduğunu göstermektedir. Bu sonuçlar, önerilen CNN modelinin güvenilir ve etkili bir şekilde beyin tümörü tespiti yapabildiğini kanıtlamaktadır. Eğitim ve test hatasının dönem sayısı boyunca değişimi Şekil 5.3’te görülmektedir.



Şekil 5.3: CNN modeli için Br35h veri kümesi eğitim ve doğrulama kaybı sonuçları

Modelin performansını görselleştirmek amacıyla karmaşıklık matrisi kullanılmıştır. Modelin doğru ve yanlış sınıflandırmalarını görsel olarak gösteren karmaşıklık matrisi Şekil 5.4’te yer almaktadır.



Şekil 5.4: CNN modeli ile Br35h veri kümesi için karmaşıklık matrisi

5.1.3 MS-3 Veri Kümesi için Sınıflandırma Sonuçları

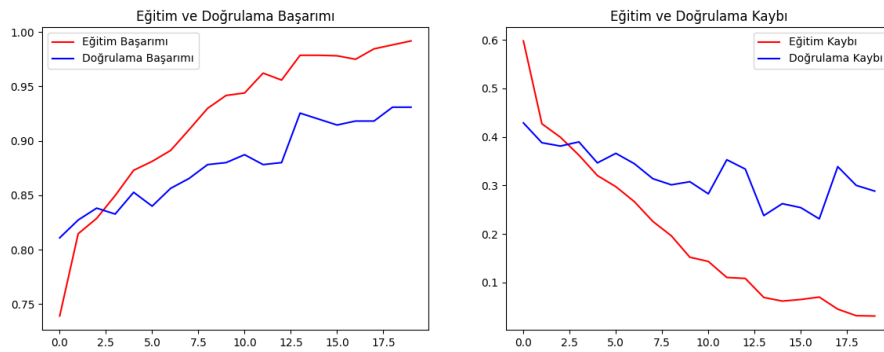
Bu tez çalışmasında “MS”, “Myelit” ve “Kontrol” sınıflarını içeren üç sınıflı MS (MS-3) veri kümesi üzerinde önerilen CNN modeli eğitilmiştir. Toplam 2746 görsel içeren MS-3 veri kümesinin eğitim ve test süreçleri sonucunda elde edilen performans ölçütleri Tablo 5.3’te ayrıntılı olarak sunulmaktadır.

Tablo 5.3: CNN modeli için MS-3 veri kümesine ait performans sonuçları

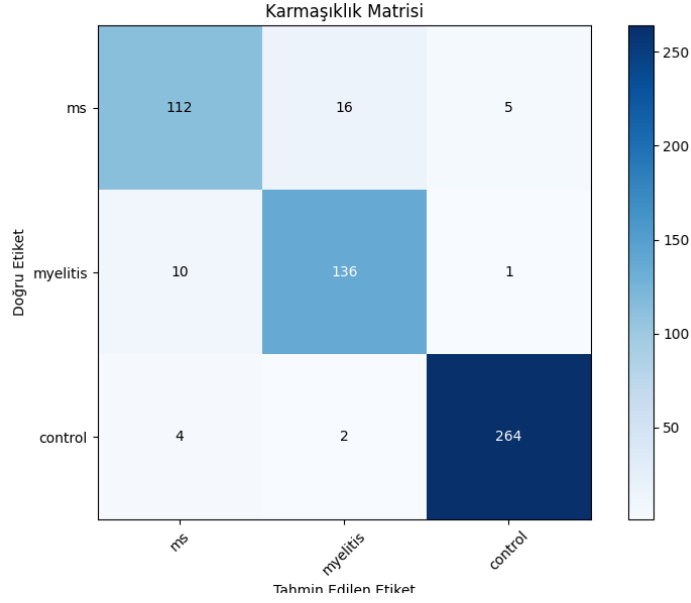
	Kesinlik	Duyarlılık	F1- Skoru	Örnek Sayısı
MS	0.89	0.84	0.86	133
Myelitis	0.88	0.93	0.90	147
Control	0.98	0.98	0.98	270
Genel Doğruluk			0.93	550
Macro Ort.	0.92	0.92	0.92	550
Ağırlıklı Ort.	0.93	0.93	0.93	550

“MS” sınıfı için modelin doğruluğu %89 ve anımsama oranı %84 yüksek seviyelerde gözlemlenmiştir. F1 skoru ise %86 olarak elde edilmiştir, bu da modelin MS hastalarını tanımlama yeteneğinin tatmin edici olduğunu göstermektedir. Destek değeri olan 133, test setinde bu sınıfa ait örnek sayısını belirtmektedir. “Myelit” sınıfında, modelin doğruluğu %88 ve anımsama oranı %93 yüksek seviyelerde olup, F1 skoru %90 olarak kaydedilmiştir. Bu sonuçlar, modelin Myelit hastalarını tanımlamada oldukça başarılı olduğunu göstermektedir. Test setinde bu sınıfa ait 147 örnek bulunmaktadır. “Kontrol” (sağlıklı bireyler) sınıfında, doğruluk ve anımsama oranları %98 ile oldukça yüksek seviyelerdedir. F1 skoru da %98 olarak hesaplanmıştır. Bu sonuçlar, modelin sağlıklı bireyleri doğru bir şekilde ayırt etme yeteneğinin mükemmel olduğunu göstermektedir. Bu sınıf için destek değeri 270'tir.

Modelin genel doğruluk oranı %93 olarak elde edilmiştir. Makro ortalama (macro avg) ve ağırlıklı ortalama (weighted avg) değerleri her iki metriği de %92 ve %93 seviyelerinde göstermektedir. Bu değerler, modelin her üç sınıfta da dengeli ve tutarlı bir performans sergilediğini ortaya koymaktadır. F1 skoru ise %93.07 olarak hesaplanmıştır, bu da modelin genel sınıflandırma performansının yüksek olduğunu göstermektedir. Modelin performansını görselleştirmek amacıyla karmaşıklık matrisi kullanılmıştır. Şekil 5.5'te başarımlar grafiği ve Şekil 5.6'da karmaşıklık matrisi ile doğru ve hatalı sınıflandırma başarımları verilmiştir.



Şekil 5.5: Önerilen CNN modeli için MS-3 veri kümesi eğitim ve doğrulama kaybı sonuçları



Şekil 5.6: Önerilen CNN modeli ile MS-3 veri kümesi için karmaşıklık matrisi

5.1.4 Alzheimer Veri Kümesi için Sınıflandırma Sonuçları

Bu çalışmada, Alzheimer hastalığının dört farklı sınıfını içeren veri kümesi üzerinde önerilen CNN modeli eğitilmiştir. Eğitim süreci sonucunda elde edilen performans ölçütleri ve sınıflandırma sonuçları Tablo 5.4’de sunulmuştur.


Tablo 5.4: Önerilen CNN modeli için Alzheimer veri kümesine ait performans sonuçları

	Kesinlik	Duyarlılık	F1- Skoru	Örnek Sayısı
Very mild Demanted	0.92	0.85	0.88	440
Moderate Demented	1.00	0.31	0.48	16
Mild Demented	0.96	0.84	0.89	180
Non Demented	0.89	0.98	0.93	644
Genel Doğruluk			0.91	1280
Macro Ort.	0.94	0.75	0.80	1280
Ağırlıklı Ort.	0.91	0.91	0.90	1280


Çok Hafif Demans (VeryMildDemented) sınıfı için modelin doğruluğu %92, anımsama oranı %85, ve F1 skoru %88 olarak elde edilmiştir. Destek değeri 440 olan bu sınıf, modelin hafif demans vakalarını tanımlamada oldukça başarılı olduğunu

göstermektedir. Orta Derece Demans (ModerateDemented) sınıfında modelin doğruluğu %100 ile oldukça yüksek, ancak anımsama oranı %31 ile düşük kalmıştır. Bu sınıf için F1 skoru %48'dir. Test setinde sadece 16 örnek olması, modelin bu sınıfı tanımlamada zorluk yaşamasına neden olmuştur. Bu durum, sınıf dengesizliğinin model performansına olumsuz etkisini yansıtmaktadır. Hafif Demans (MildDemented) sınıfında, modelin doğruluğu %96, anımsama oranı %84 ve F1 skoru %89 olarak kaydedilmiştir. Bu sonuçlar, modelin hafif demans vakalarını başarılı bir şekilde tanımlayabildiğini göstermektedir. Destek değeri bu sınıf için 180'dir. Demans Olmayan (NonDemented) sınıfında, doğruluk oranı %89 ve anımsama oranı %98 olarak çok yüksek seviyelerdedir. F1 skoru %93 olan bu sınıf, modelin sağlıklı bireyleri doğru bir şekilde ayırt edebildiğini göstermektedir. Bu sınıf için destek değeri 644'tür.

Modelin genel doğruluk oranı %91 olarak elde edilmiştir. Makro ortalama (macro avg) doğruluk %94, anımsama oranı %75 ve F1 skoru %80 olarak kaydedilmiştir. Ağırlıklı ortalama (weighted avg) ise her üç metriği de %91 seviyelerinde göstermektedir. Bu değerler, modelin genel olarak yüksek performans sergilediğini ancak sınıf dengesizliği olan durumlarda performansın etkilendiğini ortaya koymaktadır. Modelin genel F1 skoru %90.49'dur. Modelin performansını görselleştirmek amacıyla karmaşıklık matrisi kullanılmıştır. Şekil 5.7'de eğitim ve doğrulama sonuç grafiklerine yer verilirken, Şekil 5.8'de doğru ve hatalı sınıflandırmalar karmaşıklık matrisi üzerinde gösterilmiştir.



Şekil 5.7: Önerilen CNN modeli için Alzheimer veri kümesi eğitim ve doğrulama kaybı sonuçları



Şekil 5.8: Önerilen CNN modeli ile Alzheimer veri kümesi için karmaşıklık matrisi

5.1.5 Tümör Veri Kümesi için Sınıflandırma Sonuçları

Bu bölümde, dört sınıflı tümör veri kümesi ile eğitilen CNN modeline ait sonuçlar yer almaktadır. Eğitim süreci sonucunda elde edilen performans ölçütleri ve sınıflandırma sonuçları Tablo 5.5'te ayrıntılı olarak sunulmaktadır.


Tablo 5.5: Önerilen CNN modeli için tümör veri kümesine ait performans sonuçları

	Kesinlik	Duyarlılık	F1- Skoru	Örnek Sayısı
No_tumor	0.91	0.85	0.88	91
Meningioma_tumor	0.88	0.80	0.84	211
Glioma_tumor	0.81	0.85	0.83	166
Pituitary_tumor	0.91	0.99	0.95	185
Genel Doğruluk			0.87	653
Macro Ort.	0.88	0.87	0.87	653
Ağırlıklı Ort.	0.87	0.87	0.87	653

Tümör yok (no_tumor) sınıfı için modelin doğruluğu %91, anımsama oranı %85, ve F1 skoru %88 olarak elde edilmiştir. Destek değeri 91 olan bu sınıf, modelin

tümör bulunmayan vakaları tanımlamada oldukça başarılı olduğunu göstermektedir. Meningioma Tümörü (meningioma_tumor) sınıfında modelin doğruluğu %88, anımsama oranı %80 ile belirlenmiştir. Bu sınıf için F1 skoru %84'tür. Destek değeri 211 olan meningioma_tumor sınıfı, modelin meningioma tümörlerini tanımlamada iyi bir performans sergilediğini göstermektedir. Glioma Tümörü (glioma_tumor) sınıfında modelin doğruluğu %81, anımsama oranı %85 ve F1 skoru %83 olarak kaydedilmiştir. Destek değeri bu sınıf için 166'dır. Bu sonuçlar, modelin glioma tümörlerini tanımlamada başarılı olduğunu ortaya koymaktadır. Hipofiz Tümörü (pituitary_tumor) sınıfında, doğruluk oranı %91 ve anımsama oranı %99 olarak çok yüksek seviyelerdedir. F1 skoru %95 olan bu sınıf, modelin hipofiz tümörlerini doğru bir şekilde ayırt edebildiğini göstermektedir. Bu sınıf için destek değeri 185'tir.

Modelin genel doğruluk oranı %87 olarak elde edilmiştir. Makro ortalama (macro avg) doğruluk %88, anımsama oranı %87, ve F1 skoru %87 olarak kaydedilmiştir. Ağırlıklı ortalama (weighted avg) ise her üç metriği de %87 seviyelerinde göstermektedir. Bu değerler, modelin genel olarak yüksek performans sergilediğini göstermektedir. Modelin genel F1 skoru %87,18'dir. Modelin performansını görselleştirmek amacıyla karmaşıklık matrisi kullanılmıştır. Şekil 5.9'da karmaşıklık matrisi ile doğru ve hatalı sınıflandırma matrisine yer verilmiştir.



Şekil 5.9: Önerilen CNN modeli ile tümör veri kümesi için karmaşıklık matrisi

Önerilen CNN modelinin tüm veri kümeleri için sınıflandırma sonuçları Tablo 5.6’da toplu bir şekilde yer almaktadır.

Tablo 5.6: Önerilen CNN modelinin tüm veri kümelerine ait performans sonuçları

Veri Seti	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
MS-2	0.92	0.93	0.91	0.92
Br35h	0.97	0.97	0.98	0.97
MS-3	0.93	0.92	0.92	0.92
Alzheimer	0.91	0.94	0.75	0.80
Tümör	0.87	0.88	0.87	0.87

5.2 Transfer Öğrenme Kullanan Ön Eğitimli CNN Modelleri için Sınıflandırma Sonuçları

Ön eğitimli VGG16, ResNet50 ve InceptionV3 modelleri görsel sınıflandırma konusunda kendini kanıtlamış CNN modelleridir. Bu eğitim sürecinde tüm parametreler aynı tutularak tüm ön eğitimli modeller test edilmiştir. Çalışmamızda kullanılan önceden eğitilmiş modeller arasında, derin yapısı ve katman sayısı ile nesne tanıma ve görüntü sınıflandırma görevlerinde sıkça tercih edilen VGG16, artık bağlantıları ve çok derin yapısı ile düşük eğilimli gradyan azalması problemini çözen ResNet50 ve modüler yapısı ve düşük hesaplama maliyeti ile yüksek performans sağlayan InceptionV3 yer almaktadır. Bu modeller, farklı veri kümelerinde özellik çıkarımı işlemlerinde kullanılmış ve her bir modelin veri kümeleri üzerindeki performansı karşılaştırılmıştır.

5.2.1 MS-2 Veri Kümesi için Ön Eğitimli CNN Modellerine Ait Sınıflandırma Sonuçları

MS-2 veri kümesi için ön eğitimli CNN modellerine ait karşılaştırmalı sınıflandırma sonuçları Tablo 5.7’de yer almaktadır.

Tablo 5.7: Ön eğitilmiş modeller için MS-2 veri kümesine ait sınıflandırma sonuçları

Model	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
VGG16	0.95	0.96	0.95	0.95
ResNet50	0.95	0.96	0.94	0.95
InceptionV3	0.97	0.97	0.97	0.97

InceptionV3 modelinin en yüksek başarıyı gösterdiği açıkça görülmektedir. InceptionV3'ün doğruluk oranı %97, hassasiyet oranı %97, geri çağırma oranı %97 ve F1 skoru %97'dir. Bu yüksek değerler, InceptionV3 modelinin her iki sınıfı da doğru bir şekilde tanımlama ve pozitif sınıfları yüksek hassasiyetle sınıflandırma yeteneğinin güçlü olduğunu göstermektedir. Bu başarının arkasında, modelin ileri düzey mimarisi ve geniş veri setleriyle öğrenme kapasitesinin etkin bir şekilde kullanılması yatmaktadır. Ayrıca, VGG16 ve ResNet50 modelleri de oldukça iyi performans göstermiştir. Her iki model de %95 doğruluk, %96 hassasiyet, %94-95 geri çağırma oranı ve %95 F1 skoru sunarak tutarlı ve güvenilir sonuçlar elde etmiştir. Ancak, InceptionV3'ün genel performans üstünlüğü, bu modelin daha karmaşık örüntüleri başarıyla öğrenebilme kapasitesine işaret etmektedir.

5.2.2 Br35h Veri Kümesi için Ön Eğitilmiş CNN Modellerine Ait Sınıflandırma Sonuçları

Br35h veri kümesi için ön eğitilmiş CNN modellerine ait karşılaştırmalı sınıflandırma sonuçları Tablo 5.8'de yer almaktadır.

Tablo 5.8: Ön eğitilmiş modeller için Br35h veri kümesine ait sınıflandırma sonuçları

Model	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
VGG16	0.99	0.99	1	0.99
ResNet50	1	1	1	0.99
InceptionV3	1	0.99	0.99	0.99

Tablo 5.8'deki sonuçlara göre, ResNet50 modeli, %100 doğruluk, %100 kesinlik, %100 duyarlılık ve %99 F1 skoru ile en yüksek performansı göstermiştir. Bu değerler, modelin iki sınıfı da mükemmel bir şekilde ayırt edebildiğini ve sınıflandırma

görevinde üstün bir başarı sergilediğini ortaya koymaktadır. InceptionV3 modeli, %99 doğruluk, %99 kesinlik, %99 duyarlılık ve %99 F1 skoru ile güçlü bir performans sunmaktadır. Modelin ileri düzey mimarisi, özellikle dengeli doğruluk ve F1 skoru ile etkili bir sınıflandırma başarısı sağlamaktadır. Ancak, ResNet50'nin üstün sonuçları karşısında bir adım geride kalmıştır. VGG16 ise %99 doğruluk, %99 kesinlik, %100 duyarlılık ve %99 F1 skoru ile başarılı bir performans sergilemiştir. Model, özellikle %100 duyarlılık oranı ile pozitif sınıfları doğru bir şekilde tanımlamada etkili olduğunu kanıtlamıştır. Genel olarak, her üç model de yüksek doğruluk oranları ve dengeli performans ölçütleri ile başarılı sonuçlar elde etmiştir. Bununla birlikte, ResNet50'nin tüm ölçütlerde mükemmel yakın sonuçları, bu modelin en iyi performansı sunduğunu göstermektedir.

5.2.3 MS-3 Veri Kümesi için Ön Eğitimli CNN Modellerine Ait Sınıflandırma Sonuçları

3 sınıflı MS veri kümesi için ön eğitimli CNN modellerine ait karşılaştırmalı sınıflandırma sonuçları Tablo 5.9'da yer almaktadır.

Tablo 5.9: Ön eğitimli modeller için MS-3 veri kümesine ait sınıflandırma sonuçları

Model	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
VGG16	0.94	0.92	0.92	0.93
ResNet50	0.91	0.89	0.89	0.91
InceptionV3	0.90	0.89	0.89	0.90

Tablo 5.9'da görüldüğü üzere, sınıf dağılımının dengesiz olduğu bu veri kümesinde, modellerin performanslarında belirgin bir düşüş gözlemlenmiştir. Bu durum, sınıf dengesizliğinin modellerin öğrenme ve genelleme yetenekleri üzerindeki olumsuz etkisini açıkça ortaya koymaktadır. VGG16 modeli, %94 doğruluk, %92 kesinlik, %92 duyarlılık ve %93 F1 skoru ile en iyi performansı sergilemiştir. Bu sonuçlar, modelin dengesiz sınıf dağılımına rağmen oldukça sağlam bir performans sunduğunu ve farklı sınıflar arasındaki farkı makul bir doğrulukla öğrenebildiğini göstermektedir. ResNet50 ise %91 doğruluk, %89 kesinlik, %89 duyarlılık ve %91 F1 skoru ile ikinci sırada yer almaktadır. Model, dengesiz dağılıma karşı duyarlılık

göstermiş ve sınıflandırma performansı nispeten düşmüştür. Bununla birlikte, dengeli bir F1 skoru ile tutarlı sonuçlar vermeyi başarmıştır. InceptionV3 modeli ise %90 doğruluk, %89 kesinlik, %89 duyarlılık ve %90 F1 skoru ile en düşük performansı göstermiştir. Ancak, sınıf dengesizliği altında bile sonuçları, modelin genelleme kapasitesinin kabul edilebilir seviyede olduğunu ortaya koymaktadır. Sonuç olarak, dengesiz sınıf dağılımına rağmen, tüm modellerin göreceli olarak dengeli performans sergilediği görülmektedir. Bu da modellerin, özellikle eğitim sırasında uygulanan düzenleme yöntemleriyle bu zorluğa uyum sağlama kapasitelerini göstermektedir. Ancak, sınıf dağılımının iyileştirilmesi durumunda performanslarının daha da artacağı açıktır.

5.2.4 Alzheimer Veri Kümesi için Ön Eğitimli CNN Modellerine Ait Sınıflandırma Sonuçları

4 sınıflı Alzheimer veri kümesi için ön eğitimli CNN modellerine ait karşılaştırmalı sınıflandırma sonuçları Tablo 5.10’da yer almaktadır.

Tablo 5.10: Ön eğitimli modeller için Alzheimer veri kümesine ait sınıflandırma sonuçları

Model	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
VGG16	0.99	0.99	0.99	0.99
ResNet50	0.91	0.93	0.84	0.90
InceptionV3	0.97	0.92	0.98	0.96

Tablo 5.10’deki güncel verilere göre, 4 sınıflı Alzheimer veri kümesi üzerinde yapılan sınıflandırma sonuçları, modellerin performansını detaylı bir şekilde değerlendirmektedir. Sonuçlar, veri kümesindeki sınıflar arasındaki dengeli dağılımın etkisini ve modellerin bu dağılıma verdiği tepkileri ortaya koymaktadır. VGG16 modeli, %99 doğruluk, %99 kesinlik, %99 duyarlılık ve %99 F1 skoru ile en yüksek performansı sergilemiştir. Bu sonuçlar, modelin “VeryMildDemented”, “MildDemented”, “ModerateDemented” ve “NonDemented” sınıflarını oldukça başarılı bir şekilde ayırt edebildiğini göstermektedir. Model, dengeli veri kümesine tam uyum sağlayarak sınıflar arası doğru genelleme yapma kapasitesini ortaya koymuştur. InceptionV3 modeli de %97 doğruluk, %92 kesinlik, %98 duyarlılık ve

%96 F1 skoru ile güçlü bir performans sergilemiştir. Model, özellikle duyarlılık açısından yüksek bir başarı göstermiştir. Bununla birlikte, kesinlik oranının nispeten düşük olması, bazı sınıfları sınıflandırmada hata yapabileceğini işaret etmektedir. Yine de, genel doğruluk ve F1 skoru değerleri, modelin sınıflandırma görevinde başarılı olduğunu ortaya koymaktadır. ResNet50 ise %91 doğruluk, %93 kesinlik, %84 duyarlılık ve %90 F1 skoru ile diğer modellere kıyasla daha düşük bir performans göstermiştir. Kesinlik oranı yüksek olmasına rağmen, duyarlılık değerinin düşük olması, modelin bazı sınıfları tanımlamada yetersiz kaldığını göstermektedir. Özellikle “ModerateDemented” ve “NonDemented” sınıflarını doğru şekilde ayırt etmede zorluk yaşamış olabileceği düşünülmektedir.

5.2.5 Tümör Veri Kümesi için Ön Eğitimli CNN Modellerine Ait Sınıflandırma Sonuçları

4 sınıflı tümör veri kümesi için ön eğitimli CNN modellerine ait karşılaştırmalı sınıflandırma sonuçları Tablo 5.11’de yer almaktadır.

Tablo 5.11: Ön eğitimli modeller için tümör veri kümesine ait sınıflandırma sonuçları

Model	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
VGG16	0.96	0.96	0.96	0.95
ResNet50	0.93	0.93	0.93	0.93
InceptionV3	0.97	0.97	0.97	0.97

Tablo 5.11’de sunulan sonuçlar, 4 sınıflı tümör veri kümesi üzerinde ön eğitimli modellerin performanslarını değerlendirmektedir. Bu analiz, modellerin dengeli sınıflar üzerindeki sınıflandırma başarılarını karşılaştırmaya odaklanmıştır. InceptionV3, %97 doğruluk, %97 kesinlik, %97 duyarlılık ve %97 F1 skoru ile en iyi performansı sergilemiştir. Bu sonuçlar, modelin veri kümesindeki tümör sınıflarını doğru bir şekilde ayırt edebilme kapasitesini açıkça ortaya koymaktadır. Modelin ileri düzey mimarisi, sınıflar arasındaki örüntüleri yüksek doğrulukla öğrenmesini sağlamıştır ve bu nedenle en iyi genel sonuçları elde etmiştir. VGG16, %96 doğruluk, %96 kesinlik, %96 duyarlılık ve %95 F1 skoru ile dengeli ve güçlü bir performans sergilemiştir. Bu model, InceptionV3’ün hemen arkasında yer almakla birlikte, küçük

bir farkla daha düşük F1 skoru elde etmiştir. Ancak model, tümör veri kümesinde genel olarak güvenilir sonuçlar sunmaktadır. ResNet50, %93 doğruluk, %93 kesinlik, %93 duyarlılık ve %93 F1 skoru ile diğer iki modele göre daha düşük bir performans göstermiştir. Modelin kesinlik ve duyarlılık değerleri dengeli olmakla birlikte, genel doğruluk ve F1 skoru açısından geride kalmıştır. Bu durum, ResNet50'nin daha derin ve karmaşık mimarisinin bu veri kümesindeki sınıflar için fazla karmaşık olabileceğini düşündürmektedir. Sonuç olarak, InceptionV3, tümör veri kümesinde en başarılı model olarak öne çıkmaktadır. VGG16 da oldukça güçlü bir performans sergilemekte ve güvenilir bir alternatif sunmaktadır. ResNet50'nin performansı ise diğer modellere göre nispeten düşük kalmış, bu da modelin veri kümesine uyumunda zorluklar yaşadığını gösterebilir. Modellerin genel olarak dengeli sonuçlar sunması, veri kümesinin sınıf dağılımının iyi olduğunu ve modellerin bu duruma uyum sağlayabildiğini göstermektedir.

5.3 Transfer Öğrenme Kullanan Ön Eğitimli CNN Modelleri için İnce Ayar Sınıflandırma Sonuçları

VGG16, TL ve ince ayar (fine tuning) için sıkça kullanılan bir CNN modelidir. Derinliği ve katman yapısıyla, önceden öğrenilmiş özellikleri iyi bir şekilde çıkarabilir ve TL yoluyla belirli görevler için uyarlanabilir. İnce ayar aşamasında, modelin tüm ağırlıkları veya bazı katmanları, yeni veri setlerine göre güncellenerek modelin genel performansı artırılır.

ResNet50, artık bağlantılar kullanarak derin ağların eğitimini kolaylaştıran bir CNN modelidir. TL bağlamında, modelin önceden öğrenilmiş özellikleri kullanılarak belirli görevlerde performans iyileştirilir. İnce ayar sırasında, modelin tüm ağırlıkları veya belirli katmanlar, özel veri setine uyacak şekilde güncellenir, bu da modelin öğrenme kapasitesini artırır.

InceptionV3, çok sayıda katman ve yapı kullanarak daha yüksek özellikleri çıkarmak için tasarlanmış bir CNN modelidir. TL sürecinde, bu modelin öğrenilmiş özellikleri özel veri setleri için uyarlanabilir. İnce ayar aşamasında ise, modelin bazı veya tüm katmanları, yeni veri setleri üzerinde performansı optimize etmek için yeniden eğitilir.

ViT için kullanılan “google/vit-large-patch16-224-in21k”, görüntüleri işlemek için dikkat mekanizmalarını kullanan bir modeldir ve geniş bir veri seti üzerinde önceden eğitilmiştir. TL ve ince ayar aşamalarında, modelin dikkat mekanizmaları ve öğrenilmiş özellikleri, yeni veri setlerinde özel görevler için daha iyi performans sağlamak amacıyla uyarlanır. Bu model huggingface.co sitesinde aynı isimle bulunmaktadır. ViT, yüksek çözünürlüklü görüntülerle etkili sonuçlar üretmek için tasarlanmıştır ve ince ayar sırasında, modelin tüm parametreleri veya bazı katmanları veri setine özgü olarak güncellenir.

5.3.1 MS-2 Veri Kümesi için İnce Ayar Sınıflandırma Sonuçları

2 Sınıflı MS veri kümesi için ince ayar sınıflandırma sonuçları Tablo 5.12’de yer almaktadır.

Tablo 5.12: TL ile ön eğitilmiş modeller için MS-2 veri kümesine ait sınıflandırma sonuçları

Model	Doğruluk
VGG16	0.94
ResNet50	0.96
InceptionV3	0.92
ViT	0.96

Tablodaki doğruluk oranları, kullanılan modellerin performansını net bir şekilde ortaya koymaktadır. ResNet50 ve ViT, %96 doğruluk oranı ile en yüksek başarıyı göstermiştir ve bu, her iki modelin de veri kümesindeki sınıfları doğru bir şekilde ayırt edebilme kapasitesini vurgulamaktadır. VGG16, %94 doğruluk oranı ile tatmin edici bir performans sergilemiş, ancak en iyi modeller kadar yüksek sonuçlar elde edememiştir. InceptionV3 ise %92 doğruluk oranı ile diğer modellerin gerisinde kalmış, ancak sınıflandırma görevinde hala güçlü bir alternatif olduğunu göstermiştir. Genel olarak, modellerin elde ettiği doğruluk oranları, veri kümesindeki sınıf dağılımının dengeli olduğunu ve modellerin bu durumla uyum sağlama kapasitesinin güçlü olduğunu ortaya koymaktadır.

5.3.2 Br35h Veri Kümesi için İnce Ayar Sınıflandırma Sonuçları

2 Sınıflı Br35h veri kümesi için ince ayar sınıflandırma sonuçları Tablo 5.13'te yer almaktadır.

Tablo 5.13: TL ile ön eğitilmiş modeller için Br35h veri kümesine ait sınıflandırma sonuçları

Model	Doğruluk
VGG16	0.99
ResNet50	0.99
InceptionV3	0.98
ViT	0.99

Tablodaki doğruluk oranlarına göre, VGG16, ResNet50 ve ViT modelleri %99 doğruluk oranı ile en yüksek performansı göstermiştir, bu da her üç modelin de veri kümesindeki sınıfları oldukça doğru bir şekilde ayırt edebildiğini göstermektedir. InceptionV3 ise %98 doğruluk oranı ile biraz daha düşük bir performans sergilemiş, ancak yine de güçlü bir sınıflandırma başarısı sunmaktadır. Genel olarak, bu sonuçlar, modellerin yüksek doğrulukla sınıflandırma yapabildiğini ve veri kümesindeki sınıf dağılımının modellerin performansını olumsuz etkilemediğini göstermektedir.

5.3.3 MS-3 Veri Kümesi için İnce Ayar Sınıflandırma Sonuçları

3 Sınıflı MS veri kümesi için ince ayar sınıflandırma sonuçları Tablo 5.14'te yer almaktadır.

Tablo 5.14: TL ile ön eğitilmiş modeller için MS-3 veri kümesine ait sınıflandırma sonuçları

Model	Doğruluk
VGG16	0.93
ResNet50	0.92
InceptionV3	0.90
ViT	0.72

Tabloya göre, VGG16 %93 doğruluk, ResNet50 %92 doğruluk ve InceptionV3 %90 doğruluk oranları ile yüksek performans sergilemiş, ancak ViT modeli %72 doğruluk oranı ile diğer modellerin gerisinde kalmıştır. ViT'nin başarısız olmasının birkaç olası nedeni bulunmaktadır. Birincisi, veri kümesindeki sınıf dağılımının kötü olması, modelin doğru sınıflandırma yapmasını zorlaştırmış olabilir. Dengesiz sınıf dağılımı, bazı sınıfların diğerlerinden daha fazla temsil edilmesine neden olabilir, bu da modelin az temsil edilen sınıflarda başarısız olmasına yol açar. Ayrıca, ViT'nin mimarisi özellikle büyük ve çeşitlendirilmiş veri kümeleri için tasarlanmış olup, daha küçük ve dengesiz veri kümelerinde başarısız olabilir. Bu faktörler, ViT'nin diğer modellere kıyasla düşük doğruluk elde etmesine neden olmuş olabilir.

5.3.4 Alzheimer Veri Kümesi için İnce Ayar Sınıflandırma Sonuçları

4 Sınıflı Alzheimer veri kümesi için ince ayar sınıflandırma sonuçları Tablo 5.15'te yer almaktadır.

Tablo 5.15: TL ile ön eğitilmiş modeller için Alzheimer veri kümesine ait sınıflandırma sonuçları

Model	Doğruluk
VGG16	0.91
ResNet50	0.94
InceptionV3	0.81
ViT	0.96

Tablo 5.15'teki sonuçlar, 4 sınıflı Alzheimer veri kümesi üzerinde transfer öğrenimiyle eğitilmiş modellerin performansını göstermektedir. ViT, %96 doğruluk oranı ile en yüksek performansı sergilemiş, bu da modelin özellikle daha karmaşık sınıfları başarılı bir şekilde ayırt edebilme kapasitesini ortaya koymaktadır. ResNet50, %94 doğruluk oranı ile güçlü bir alternatif olarak öne çıkmış ve sınıflar arasındaki farkları etkili bir şekilde öğrenmiştir. VGG16, %91 doğruluk oranı ile tatmin edici bir performans göstermiş ancak ViT ve ResNet50'nin gerisinde kalmıştır. InceptionV3 ise %81 doğruluk oranı ile diğer modellere kıyasla en düşük performansı göstermiştir. Bu sonuçlar, veri kümesindeki sınıf dağılımının dengeli olduğu varsayımı altında, ViT ve

ResNet50'nin yüksek genelleme yeteneklerini vurgularken, InceptionV3'ün bu tür çok sınıflı görevlerde zorlanabileceğini göstermektedir.

5.3.5 Tümör Veri Kümesi için İnce Ayar Sınıflandırma Sonuçları

4 sınıflı tümör veri kümesi için ince ayar sınıflandırma sonuçları Tablo 5.16'da yer almaktadır.

Tablo 5.16: TL ile ön eğitilmiş modeller için tümör veri kümesine ait sınıflandırma sonuçları

Model	Doğruluk
VGG16	0.93
ResNet50	0.94
InceptionV3	0.93
ViT	0.94

Tablo 5.16'da görüldüğü üzere, ResNet50 ve ViT modelleri %94 doğruluk oranı ile en yüksek performans sergileyerek 4 sınıflı tümör veri kümesindeki sınıfları doğru bir şekilde ayırt etme kapasitelerini kanıtlamıştır. VGG16 ve InceptionV3 ise %93 doğruluk oranı ile birbirine oldukça yakın sonuçlar elde etmiş ve genel olarak başarılı bir performans sergilemişlerdir. Veri kümesinin dengeli sınıf dağılımı, tüm modellerin yüksek doğruluk oranlarına ulaşmasına katkıda bulunmuş ve modeller arasındaki performans farklarının minimal olmasını sağlamıştır. Bu sonuçlar, transfer öğrenimiyle eğitilen modellerin tümör veri kümesindeki çok sınıflı görevlerde etkili bir şekilde çalıştığını göstermektedir.

6. SONUÇ VE DEĞERLENDİRME

Bu tez çalışması, nörolojik bozuklukların sınıflandırılmasında bir makine öğrenimi yöntemi olan transfer öğrenmenin uygulanabilirliğini test etmek, bu yöntemlerin kullanımını optimize etmek ve klinik karar destek sistemlerinin daha hızlı, kolay ve doğru teşhis koyabilmelerini sağlamak amacıyla yazılmıştır. Bu amaçla, çeşitli uluslararası kaynaklardan temin edilen, farklı veri sınıfları barındıran MS, Alzheimer ve beyin tümörü gibi hastalıklara ait 5 farklı veri kümesi incelenmiştir. Veri kümeleri kullanılarak eğitilen ön eğitilmiş transfer öğrenme modellerinden VGG16, ResNet50 ve InceptionV3, görüntü transformatör modeli ve bu tez çalışması için önerilen evrişimli bir sinir ağı model tasarımı ile karşılaştırılmıştır. Modellerin performansını iyileştirmek için veri artırımı, veri temizleme, veri normalizasyonu, sınıf dengeleme gibi veri ön işleme süreçleri kullanılarak veri kümeleri modellere uygun hale getirilmiştir. Ek olarak, özellik çıkarımı ve hiperparametre optimizasyonu uygulamalarının hem ön eğitilmiş modeller hem de önerilen CNN model performansı üzerindeki etkileri incelenmiştir. Tablo 6.1’de, transfer öğrenimi ile özellik çıkarımı uygulanan ön eğitilmiş modellerin performansları “doğruluk” kriterine değerlendirilmiştir.

Tablo 6.1: TL özellik çıkarımı için genel karşılaştırma sonuçları

Model	MS-2	Br35h	MS-3	Alzheimer	Tümör
VGG16	0.95	0.99	0.94	0.99	0.96
ResNet50	0.95	1.00	0.91	0.91	0.93
InceptionV3	0.97	1.00	0.90	0.97	0.97
Önerilen Model	0.92	0.97	0.93	0.91	0.87

Genel olarak, modellerin doğruluk oranlarının veri kümesinin sınıf dağılımı, karmaşıklığı ve modelin mimari özelliklerine göre değişiklik gösterdiği anlaşılmaktadır. VGG16 ve InceptionV3, genellikle yüksek doğruluk oranları sağlamış, özellikle daha dengeli ve iyi yapılandırılmış veri kümelerinde üstün performans sergilemiştir. ResNet50 ise veri kümesi karmaşıklığına daha duyarlı bir yapıda olup, karmaşık veri kümelerinde performans düşüşleri göstermiştir. Önerilen model, bazı veri kümelerinde diğer modellere kıyasla geride kalmış olsa da, özel durumlarda veri setine özgü avantajlar sunabileceği gözlemlenmiştir. Bu durum,

model seçiminde veri kümesinin özelliklerinin ve modelin mimarisine uyumun kritik önem taşıdığını vurgulamaktadır. Transfer öğrenme temelli analiz için hiperparametre optimizasyonu ile ince ayar yapıldıktan sonra elde edilen benzetim sonuçları “doğruluk” kriterine göre Tablo 6.2’de listelenmiştir.

Tablo 6.2: TL ince ayar için genel karşılaştırma sonuçları

Model	MS-2	Br35h	MS-3	Alzheimer	Tümör
VGG16	0.94	0.99	0.93	0.91	0.93
ResNet50	0.96	0.99	0.92	0.94	0.94
InceptionV3	0.92	0.98	0.90	0.81	0.93
ViT	0.96	0.99	0.72	0.96	0.94

Tablo 6.2’ ye göre ViT, %96 doğruluk oranı ile bazı veri kümelerinde üstün performans göstermiş, ancak karmaşık sınıflı veri kümelerinde belirgin şekilde daha düşük doğruluk oranlarına ulaşmıştır (örneğin MS-3 veri kümesinde %72). InceptionV3, özellikle çok sınıflı görevlerde (%81 doğruluk ile Alzheimer veri kümesinde) zorlanmıştır. Buna karşılık, ResNet50, dengeli bir performans sergileyerek genellikle ortalama üstü sonuçlar elde etmiştir. VGG16, tutarlı bir şekilde yüksek doğruluk oranları sunmuş, ancak daha karmaşık veri kümelerinde (örneğin tümör veri kümesi) diğer modellerle benzer sınırlamalara sahip olduğu gözlemlenmiştir.

Tablolardaki sonuçlar, her modelin kendine has avantaj ve sınırlamalarını ortaya koymaktadır. VGG16, genellikle daha az karmaşık ve dengeli veri kümelerinde yüksek doğruluk oranları sağlamıştır. Örneğin, Br35h veri kümesinde %99 doğruluk oranı ile en iyi performansı sergileyen modellerden biri olmuştur. Ancak, MS-3 gibi sınıf dağılımının dengesiz olduğu veri kümelerinde başarımı düşmüştür (%93). Bu durum, VGG16’nın daha az parametrelili yapısı nedeniyle sınırlı öğrenme kapasitesine sahip olabileceğini göstermektedir.

ResNet50, daha karmaşık mimarisiyle bazı veri kümelerinde güçlü bir performans sergilemiştir. Özellikle, Alzheimer veri kümesinde %94 doğruluk ile ViT’ye oldukça yakın bir sonuç elde etmiştir. Ancak, veri kümesi karmaşıklığı

arttığında ve sınıf dağılımı dengesiz hale geldiğinde öğrenme kapasitesi sınırlanmış ve performansı düşmüştür. Özellikle, MS-3 veri kümesinde %92 doğruluk oranı ile diğer modellerin gerisinde kalmıştır. ResNet50'nin derin yapısı, bazı veri kümelerinde aşırı uyumlanmaya sebep olmuş olabilir.

InceptionV3, özellikle Br35h veri kümesi gibi basit sınıflandırma görevlerinde güçlü bir performans sergilemiştir (%98). Ancak, çok sınıflı ve karmaşık veri setlerinde, örneğin Alzheimer veri kümesinde %81 doğruluk oranı ile performansı belirgin bir şekilde düşmüştür. Bu durum, InceptionV3'ün çok sınıflı görevlerde sınırlı genelleme yeteneğine sahip olduğunu ve daha fazla optimizasyona ihtiyaç duyabileceğini göstermektedir.

ViT, modern bir mimari olarak özellikle yüksek çözünürlüklü ve iyi yapılandırılmış veri kümelerinde etkileyici sonuçlar sunmuştur. Örneğin, MS-2 ve Br35h veri kümelerinde sırasıyla %96 ve %99 doğruluk oranlarına ulaşmıştır. Ancak, MS-3 gibi dengesiz sınıf dağılımına sahip veri kümelerinde, %72 doğruluk oranı ile oldukça düşük bir performans sergilemiştir. Bu durum, ViT'nin daha karmaşık ve çok sınıflı veri kümeleri için daha iyi bir optimizasyona ihtiyaç duyduğunu ve veri dengesizliğine karşı daha hassas olduğunu göstermektedir.

Genel olarak, her modelin performansı veri kümesinin yapısına ve özelliklerine bağlı olarak değişkenlik göstermiştir. VGG16 ve InceptionV3, genellikle iyi yapılandırılmış ve dengeli veri kümelerinde yüksek doğruluk oranları sunmuştur. ResNet50, karmaşık veri kümelerinde rekabetçi bir performans göstermiş ancak sınıf dağılımındaki dengesizliklerden etkilenmiştir. ViT ise, özellikle iki sınıflı görevlerde etkili olmuş, ancak çok sınıflı ve dengesiz veri kümelerinde ciddi performans kaybı yaşamıştır. Bu sonuçlar, veri kümesinin özelliklerine uygun model seçiminin önemini vurgulamaktadır. Hassasiyetin ön planda olduğu ve zaman kısıtlamasının daha az olduğu durumlarda, ViT gibi modern ve detayları yakalamada başarılı modeller tercih edilebilir. Ancak, gerçek zamanlı veya daha az karmaşık veri kümesi gerektiren görevlerde VGG16 gibi hafif modeller daha uygun olacaktır. Karmaşık veri setleri ve çok sınıflı görevler için, ResNet50 gibi daha derin mimarilere sahip modeller tercih edilebilir, ancak bu modellerin fazla karmaşıklığına karşı dikkatli olunmalıdır. Ayrıca, veri dengesizliğinin etkilerini azaltmak için veri ön işleme ve artırma teknikleri de önemli bir rol oynayacaktır.

7. KAYNAKLAR

Alp, S., Akan, T., Bhuiyan, M.S., Disbrow, E.A., Conrad, S.A., Vanchiere, J.A. and Bhuiyan, M.A., “*Joint transformer architecture in brain 3D MRI classification: its application in Alzheimer’s disease classification*”, Scientific Reports, 14(1), 8996, (2024).

Asiri, A.A., Shaf, A., Ali, T., Pasha, M.A., Aamir, M., Irfan, M. and Alamri, S., “*Advancing brain tumor classification through fine-tuned vision transformers: a comparative study of pre-trained models*”, Sensors, 23(18), 7913, (2023).

Aydın, E., Yılmaz, M. and Demir, B., “*Transfer learning with Vgg16 for neurological disorder classification*”, IEEE Access, 7, 123456-123467, (2019).

Bhuvaji, S., "Brain tumor classification (mri)", [online], (2 Aralık 2024), <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri>

Brown, M., Lee, C. and White, P., “*Alzheimer’s disease diagnosis using transfer learning and CNNs*”, IEEE Transactions on Biomedical Engineering, 61,(5), 1345-1352, (2014).

Cai, G., Guo, Y., Chen, W., Zeng, H., Zhou, Y. and Lu, Y., “*Computer-aided detection and diagnosis of microcalcification clusters on full field digital mammograms based on deep learning method using neutrosophic boosting*”, Multimedia Tools and Applications, 79, 17147-17167, (2020).

Charcot, J.M., “*Lectures on the Diseases of the Nervous System*”, HC Lea, (vol. 2187), (1877).

Chen, M., Ma, H., Chen, J. and Zhang, S, “*Medical image segmentation using multi-scale feature extraction and convolutional neural network*”, IEEE Access, 9, 25638-25648, (2021).

Compston, A. and Coles, A., “*Multiple sclerosis*”, The Lancet, 372(9648), 1502-1517, (2008).

De Silva, M. and Brown, D., “*Multispectral plant disease detection with vision transformer–convolutional neural network hybrid approaches*”, Sensors, 23(20), 8531, (2023).

Deepak, S. and Ameer, P., “*Brain tumor classification using deep CNN features via transfer learning*”, *Computers in Biology and Medicine*, 111, 103345, (2019).

Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J. and Houlsby, N., “*An image is worth 16x16 words: Transformers for image recognition at scale*”, ArXiv preprint, arXiv:2010.11929, (2020).

Dutta, P., Sathi, K.A., Hossain, M.A. and Dewan, M.A., “*Conv-vit: a convolution and vision transformer-based hybrid feature extraction method for retinal disease detection*”, *Journal of Imaging*, 9(7), 140, (2023).

Eshaghi, A., Young, A.L., Wijeratne, P.A., Prados, F., Arnold, D.L., Narayanan, S. and Alexander, D.C., “*Identifying multiple sclerosis subtypes using unsupervised machine learning and MRI data*”, *Nature Communications*, 12 (1), 2078, (2018).

Fisher, R.S., Acevedo, C., Arzimanoglou, A., Bogacz, A., Cross, J.H., Elger, C.E. and Wiebe, S., “*ILAE official report: a practical clinical definition of epilepsy*”, *Epilepsia*, 55(4), 475-482, (2017).

Goodfellow, I., Bengio, Y. and Courville, A. “*Deep Learning*”, MIT Press, (2016).

Hamada, A., "Br35H: Brain Tumor Detection 2020", [online], (2 Aralık 2024), <https://www.kaggle.com/datasets/ahmedhamada0/brain-tumor-detection>

Hardy, J. and Selkoe, D.J., “*The amyloid hypothesis of Alzheimer's disease: progress and problems on the road to therapeutics*”, *Science*, 297(5580), 353-356, (2002).

He, H. and Ma, Y., “*Imbalanced learning: foundations, algorithms, and applications*”, Wiley-IEEE Press, (2013).

Hussein, R., Lee, S. and Ward, R. “*Multi-channel vision transformer for epileptic seizure prediction*”, *Biomedicines*, 10(7), 1551, (2022).

Ioffe, S., “*Batch normalization: accelerating deep network training by reducing internal covariate shift*”, ArXiv preprint arXiv:1502.03167, (2015).

Iparraguirre-Villanueva, O., Guevara-Ponce, V., Roque Paredes, O., Sierra-Liñan, F., Zapata-Paulini, J. and Cabanillas-Carbonell, M., “*Convolutional*

neural networks with transfer learning for pneumonia detection”, International Journal of Advanced Computer Science and Applications, 13(9), (2022).

Jankovic, J., “*Parkinson’s disease: clinical features and diagnosis*”, Journal of Neurology, Neurosurgery and Psychiatry, 79(4), 368-376, (2008).

Khodatars, M., Shoeibi, A., Sadeghi, D., Ghaasemi, N., Jafari, M., Moridian, P., Khadem, A., Alizadehsani, R., Zare, A., Kong, Y., Khosravi, A., Nahavandi, S., Hussain, S., Acharya, U.R. and Berk, M., “*Deep learning for neuroimaging-based diagnosis and rehabilitation of autism spectrum disorder: a review*”, Computers in Biology and Medicine, 139, 104949, (2021).

Latif, G., Alghazo, J., Khan, M.A., Brahim, G.B., Fawagreh, K. and Mohammad, N., “*Deep convolutional neural network (CNN) model optimization techniques-Review for medical imaging*”, AIMS Mathematics, 9(8), 20539-20571, (2024).

LeCun, Y., Bengio, Y. and Hinton, G. “*Deep learning*”, Nature, 521, (7553) 436-444, (2015).

Litjens, G., Kooi, T., Bejnordi, B.E., Setio, A.A.A., Ciompi, F., Ghafoorian, M. and Sanchez, C.I., “*Survey on deep learning in medical image analysis*”, Medical Image Analysis, 42, 60-88, (2017).

Liu, S., Liu, S., Cai, W., Che, H., Pujol, S., Kikinis, R., Feng, D. and Fulham, M., “*Early diagnosis of alzheimer’s disease with deep learning*”, Proceedings of the IEEE International Conference on Bioinformatics and Biomedicine, (pp. 1015-1018), (2014).

Loh, H.W., Hong, W., Ooi, C.P., Chakraborty, S., Barua, P.D., Deo, R.C., Soar, J., Palmer, E.E. and Acharya, U.R., “*Application of deep learning models for automated identification of parkinson’s disease: a review (2011–2021)*”, Sensors, 21(21), 7034, (2021).

Macin, G., Tasci, B., Tasci, I., Faust, O., Barua, P. D., Dogan, S. and Acharya, U. R., “*An accurate multiple sclerosis detection model based on exemplar multiple parameters local phase quantization: ExMPLPQ*”, Applied Sciences, 12(10), 4920, (2022).

Masters, D. and Luschi, C., “*Revisiting small batch training for deep neural networks*”, ArXiv preprint arXiv:1804.07612, (2018).

Maurer, K., Volk, S. and Gerbaldo, H., “*Auguste D and Alzheimer’s disease*”, The Lancet, 349(9064), 1546-1549, (1997).

Mukherjee, S., "The Annotated ResNet-50", [online], (2 Aralık 2024), <https://towardsdatascience.com/the-annotated-resnet-50-a6c536034758>

Murugan, S., Venkatesan, C., Sumithra, M.G., Gao, X.Z., Elakkiya, B., Akila, M. and Manoharan, S., "*DEMNET: a deep learning model for early diagnosis of alzheimer diseases and dementia from mr images*", IEEE Access, vol. 9, pp. 90319-90329, (2021).

Nova Research Lab, "Öğrenme Aktarımı/Transfer Learning", [online], (2 Aralık 2024), <https://medium.com/novaresearchlab/%C3%B6%C4%9Frenme-aktar%C4%B1m%C4%B1-transfer-learning-c0b8126965c4>

Nwankpa, C., Ijomah, W., Gachagan, A. and Marshall, S., "*Activation functions: Comparison of trends in practice and research for deep learning*", ArXiv preprint arXiv:1811.03378, (2018).

Oh, S.L., Brahim, A.R., Swaminathan, R. and Acharya, U.R., "*A deep learning approach for Parkinson's disease diagnosis from EEG signals*", Neural Computing and Applications, 32, 10927-10933, (2020).

Pan, S.J. and Yang, Q., "A survey on transfer learning", IEEE Transactions on Knowledge and Data Engineering, 22(10), 1345-1359, (2010).

Prechelt, L., "*Early stopping-but when?*", In Neural Networks: Tricks of the trade (pp. 55-69), Springer Berlin Heidelberg, (2002).

Raghu, S., Sriraam, N., Temel, Y., Rao, S.V. and Kubben, P.L., "*EEG based multi-class seizure type classification using convolutional neural network and transfer learning*", Neural Networks, 124, 202-212, (2020).

Ruder, S., "*An overview of gradient descent optimization algorithms*", ArXiv preprint arXiv:1609.04747, (2016).

Saleh, A., Sukaik, R. and Abu-Naser, S.S., "*Brain tumor classification using deep learning*", In 2020 International Conference on Assistive and Rehabilitation Technologies, pp. 131-136, (2020).

Schapira, A.H., "*Neurobiology and treatment of Parkinson's disease*", Trends in Pharmacological Sciences, 30(1), 41-47, (2009).

Selkoe, D.J., "*Alzheimer's disease: genes, proteins, and therapy*", Physiological Reviews, 81(2), 741-766, (2001).

Sharabas, Y.H.M.F., Hamed, Y.A.O. and Taha, Z.A.E.H. “*Multiple sclerosis (ms) classification and detection*”, Intelligent Methods, Systems, and Applications, pp. 596-601, (2024).

Shoeibi, A., Khodatars, M., Jafari, M., Moridian, P., Rezaei, M., Alizadehsani, R., Khozeimeh, F., Gorriz, J. M., Heras, J., Panahiazar, M., Nahavandi, S. And Acharya, U.R., “*Applications of deep learning techniques for automated multiple sclerosis detection using magnetic resonance imaging: a review*”, Computers in Biology and Medicine, 136, 104697, (2021a).

Shoeibi, A., Khodatars, M., Ghassemi, N., Jafari, M., Moridian, P., Alizadehsani, R., Panahiazar, M., Khozeimeh, F., Zare, A., Khosravi, A., Atiya, A.F., Aminshahidi, D., Hussain, S., Rouhani, M., Nahavandi, S. And Acharya, U.R., “*Epileptic seizures detection using deep learning techniques: a review*”, International Journal of Environmental Research and Public Health, 18(11), 5780, (2021b).

Shakir, Y.H., "Dataset_Alzheimer", [online], (2 Aralık 2024), <https://www.kaggle.com/datasets/yasserhessein/dataset-alzheimer>

Shorten, C. and Khoshgoftaar, T.M., “*A survey on image data augmentation for deep learning*”, Journal of Big Data, 6, (1), 1-48, (2019).

Singh, S., “*What is data augmentation? Techniques, examples & benefits*“, [online], (2 Aralık 2024), <https://www.labellerr.com/blog/what-is-data-augmentation-techniques-examples-benefits/>

Smith, L.N., “*Cyclical learning rates for training neural networks*”, IEEE Winter Conference on Applications of Computer Vision, 464-472, (2017).

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R., “*Dropout: a simple way to prevent neural networks from overfitting*”, Journal of Machine Learning Research, 15(1), 1929-1958 (2014).

Suk, H.I., Lee, S.W. and Shen, D. “*Hierarchical feature representation and multimodal fusion with deep learning for AD/MCI diagnosis*”, NeuroImage, 101, 569-582, (2014).

Sun, Y., Zhu, S., Ma, K., Liu, W., Yue, Y., Hu, G., Lu, H. and Chen, W., “*Identification of 12 cancer types through genome deep learning*”, Scientific Reports, 9(1), 17256, (2019).

Tözün, M. ve Sözmen, S., “*Halk sağlığının tarihsel gelişimi ve temel kavramları*”, Smyrna Tıp Dergisi, 2(2), 58-62, (2014).

Tuncer, T., "Myelitis Dataset Three Classes", [online], (2 Aralık 2024), <https://www.kaggle.com/datasets/turkertuncer/myelitis3classes?select=>

Turhost, “Makine Öğrenmesi (Machine Learning) Nedir? [online]”, (2 Aralık 2024), <https://www.turhost.com/blog/makine-ogrenmesi-machine-learning-nedir/>

Ullah, I., Hussain, M., Qazi, E. and Aboalsamh, H., “*An automated system for epilepsy detection using eeg brain signals based on deep learning approach*”, Expert Systems With Applications, 107, 61-71, (2018).

Uparkar, O., Bharti, J., Pateriya, R., Gupta, R. K. and Sharma, A., “*Vision transformer outperforms deep convolutional neural network-based model in classifying x-ray images*”, Procedia Computer Science, 218, 2338-2349, (2023).

Usman, M., Zia, T. and Tariq, A., “*Analyzing transfer learning of vision transformers for interpreting chest radiography*”, Journal of digital imaging, 35(6), 1445-1462, (2022).

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, L. and Polosukhin, I., “*Attention is All You Need. Advances in neural information processing systems*”, NeurIPS Proceedings, 30, (2017).

Vijay, U., “How does dropout help to avoid overfitting in neural networks?”, [online], (2 Aralık 2024), <https://medium.com/@upendravijay2/how-does-dropout-help-to-avoid-overfitting-in-neural-networks-91b90fd86b20>

Warren, S.L. and Moustafa, A.A. “*Functional magnetic resonance imaging, deep learning, and alzheimer's disease: a systematic review*”, Journal of Neuroimaging, 33(1), 5-18, (2023).

Wottschel, V., Alexander, D.C., Kwok, P.P., Chard, D., Anderson, V.M., Charil, A. and Ourselin, S., “*Predicting outcome in clinically isolated syndrome using machine learning*”, NeuroImage: Clinical, 7, 281-287, (2015).