

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**FUNDUS GÖRÜNTÜLERİNİN SINIFLANDIRILARAK
DİYABETİK RETİNOPATİ HASTALIĞININ DERİN
ÖĞRENME İLE TESPİTİ**

Yüksek Lisans Tezi

Tezi Hazırlayan
Halil İbrahim ŞAHİN

İstanbul, 2024

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**FUNDUS GÖRÜNTÜLERİNİN SINIFLANDIRILARAK
DİYABETİK RETİNOPATİ HASTALIĞININ DERİN
ÖĞRENME İLE TESPİTİ**
Yüksek Lisans Tezi

Tezi Hazırlayan
Halil İbrahim ŞAHİN

Öğrenci No
2120003073

ORCID ID
0000-0003-3829-7041

Danışman
Dr. Öğr.Üyesi Talat FİRLAR

İstanbul, 2024

YEMİN METNİ

Yüksek Lisans Tezi olarak sunduğum **Fundus Görüntülerinin Sınıflandırılarak Diyabetik Retinopati Hastalığının Derin Öğrenme İle Tespiti** başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere uygun şekilde tarafımdan yazıldığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, yararlandığım eserlerin tamamının kaynaklarda gösterildiğini ve çalışmamın içinde kullanıldıkları her yerde bunlara atıf yapıldığını, patent ve telif haklarını ihlal edici bir davranışımın olmadığını belirtir ve bunu onurumla doğrularım. . 11.06.2024

Halil İbrahim ŞAHİN

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜ
TEZLİ YÜKSEK LİSANS SINAV TUTANAĞI

11.06.2024

Enstitümüz *Bilgisayar Mühendisliği* Anabilim Dalı *Bilgisayar Mühendisliği* Programı yüksek lisans öğrencilerinden 2120003073 numaralı *Halil İbrahim ŞAHİN*'in "*İstanbul Beykent Üniversitesi Lisansüstü Eğitim – Öğretim Yönetmeliği*"nin ilgili maddesine göre hazırlayarak, Enstitümüze teslim ettiği "*Fundus Görüntülerinin Sınıflandırılarak Diyabetik Retinopati Hastalığının Derin Öğrenme İle Tespiti*" konulu tezini, Yönetim Kurulumuzun 21/05/2024 tarih ve 2024/23 sayılı toplantısında seçilen ve On-Line toplanan biz jüri üyeleri huzurunda, İstanbul Beykent Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 29. maddesinin 3. fıkrası gereğince 45 dakika süre ile Zoom programı aracılığıyla on-line olarak aday tarafından savunulmuş ve sonuçta adayın tezi hakkında "*OYBİRLİĞİ*" ile "*KABUL*" kararı verilmiştir.

İşbu tutanak, 2 nüsha olarak hazırlanmış ve Enstitü Müdürlüğü'ne sunulmak üzere tarafımızdan düzenlenmiştir.

DANIŞMAN
Dr. Öğr. Üyesi Ta*** Fİ***
(İstanbul Beykent Üniversitesi)

ÜYE
Dr. Öğr. Üyesi Ke*** Gö*** NA***
(İstanbul Beykent Üniversitesi)

ÜYE
Dr. Öğr. Üyesi Ke*** ŞA***
(İstanbul Medipol Üniversitesi)

Adı ve Soyadı : Halil İbrahim ŞAHİN
Danışmanı : Dr. Öğretim Üyesi Talat FİRLAR
Derecesi ve Tarihi : Yüksek Lisans (Tezli), 2024
Alanı : Bilgisayar Mühendisliği
Anahtar Kelimeler : Derin Öğrenme, Görüntü İşleme, Yapay Zeka, Diyabetik Retinopati, Konvolüsyonel Sinir Ağları, EfficientNet

ÖZ

FUNDUS GÖRÜNTÜLENİNİN SINIFLANDIRILARAK DİYABETİK RETİNOPATİ HASTALIĞININ DERİN ÖĞRENME İLE TESPİTİ

Günümüz yaygın hastalıklarından olan şeker hastalığının yan etkilerine bağlı olan diyabetik retinopati dünya üzerinde ciddi hastalıkların başında gelir.

Diyabetik retinopati(DR), gözün retina ağ tabakasında yer alan kan damarlarında diyabete bağlı olarak oluşan hasarlanmalardır. Şeker hastalığına bağlı olarak gelişir. Diyabetik retinopati teşhisi genellikle fundus görüntülerinin uzmanlar tarafından incelenmesine dayanır. İnceleme sürecinin sadece uzman temelli olması , hastalık teşhisini zorlaştırmaktadır. Sadece uzmanların bu süreci yönetmesi, hastalığın teşhisini ve tedavi sürecini uzatabilmektedir.

Diyabetik retinopatinin erken aşamalarda teşhis edilip tedavi edilmesi, diyabet hastalarının görme yeteneklerini korumak ve retinopatinin ilerlemesini yavaşlatmak için hayati önem taşımaktadır.

Bu çalışmanın amacı derin öğrenme modeli kullanılarak doktorların fundus görüntülerinin inceleyerek teşhis ettiği diyabetik retinopati hastalığının sınıflandırılmasını, saptanması araştırmaktır. Araştırmada görüntüsü iyileştirme , veri çoğaltma gibi teknikler kullanılarak modelin performansının artırılması hedeflenmiştir.

Name and Surname : Halil İbrahim ŞAHİN
Supervisor : Asst. Prof. Dr. Talat FİRLAR
Degree and Date : Master's (Thesis), 2024
Major : Computer Engineering
Keywords : Deep Learning, Image Processing, Artificial Intelligence,
Diabetic Retinopathy, Convolutional Neural Networks,
EfficientNet

ABSTRACT

DETECTION OF DIABETIC RETINOPATHY DISEASE BY CLASSIFYING FUNDUS IMAGES USING DEEP LEARNING

Diabetic retinopathy, which is due to the side effects of diabetes, one of today's common diseases, is one of the most serious diseases in the world.

Diabetic retinopathy (DR) is diabetes-related damage to the blood vessels in the retina of the eye. It develops due to diabetes. Diabetic retinopathy diagnosis is usually based on expert examination of fundus images. The fact that the examination process is only expert-based makes disease diagnosis difficult. Only experts managing this process can prolong the diagnosis and treatment process of the disease.

Diagnosing and treating diabetic retinopathy in the early stages is vital to preserve the vision of diabetic patients and slow the progression of retinopathy.

The aim of this study is to investigate the classification and detection of diabetic retinopathy, which doctors diagnose by examining fundus images, using a deep learning model. The research aimed to increase the performance of the model by using techniques such as image enhancement and data augmentation.

İÇİNDEKİLER

Sayfa No.

ÖZ

ABSTRACT

TABLolar LİSTESİ	iii
ŞEKİLLER LİSTESİ	iv
KISALTMALAR	vi
SÖZLÜK.....	viii
GİRİŞ	1

1. LİTERATÜR ÇALIŞMASI

2. RETİNANIN YAPISI VE DİYABETİK RETİNOPATİ HASTALIĞI

2.1. Göz Ve Retina.....	10
2.2. Diyabet	12
2.2.1. Diyabetin Sınıflandırması	14
2.3 Diyabetik Retinopati.....	14
2.3.1. Diyabetik Retinopati Evreleri	16
2.3.1.1. Non-Proliferatif Diyabetik Retinopati	17
2.3.1.2. Proliferatif Diyabetik Retinopati.....	20
2.3.2. Mikroanevrizmalar	21
2.3.3. Kanamalar	21
2.3.4. Eksüdalar.....	21

3. MATERYAL VE YÖNTEM

3.1. DR Veriseti	24
3.2. Ön İşlem Adımları	25
3.3. Derin Öğrenme Modellerinin Oluşturulması Ve Eğitimi	27
3.4. Makine Öğrenmesi.....	27
3.5. Yapay Sinir Ağları.....	28
3.6. Biyolojik Sinir Ağı ve Nöron	28
3.7. Derin Öğrenme.....	29
3.8. Evrişimli Sinir Ağları	32

3.8.1. Evrişimli Sinir Ağlarını Oluşturan Katmanlar	34
3.8.1.1. Giriş Katmanı	34
3.8.1.2. Evrişim Katmanı	34
3.8.1.3. Aktivasyon Katmanı	36
3.8.1.4. Ortaklama Katmanı	38
3.8.1.5. Tam Bağlantılı Katman	39
3.8.1.6. Seyreltme Katmanı	40
3.8.1.7. Sınıflandırma Katmanı	41
3.9. Hiper-Parametreler	42
3.9.1. Aktivasyon Fonksiyonları	43
3.9.2. Mini-batch Boyutu	45
3.9.3. Öğrenme Oranı	46
3.9.4. Eğitim Tur (Epok) Sayısı	47
3.9.5. Momentum Katsayısı	48
3.9.6. L2 Düzenleme	49
3.9.7. Optimizasyon Yöntemleri	49
3.10. Transfer Öğrenme (Transfer Learning)	52
3.10.1. Görsel Grup Geometri Ağı (VGG)	54
3.10.2. Xception	56
3.10.3. InceptionV3	57
3.10.4. ResNet 101	57
3.10.5. EfficientNet	57
3.10.6. K Kat Çapraz Doğrulama	59
3.11. Performans Metrikleri	60
SONUÇ	66
KAYNAKÇA	68

TABLÖLAR LİSTESİ

	Sayfa No.
Tablo 1. DR Yok (ilk satır), Hafif NPDR (ikinci satır), Orta NPDR (üçüncü satır), Şiddetli.....	25
Tablo 2. Derin öğrenme zaman tablosu	31
Tablo 3. VggNet mimarisinin ImageNet veri kümesi sınıflandırma performansı	56

ŞEKİLLER LİSTESİ

Sayfa No.

Şekil 1. İnsan gözünün anatomisi	10
Şekil 2. Avrupa Ülkelerinde Karşılaştırılabilir Diyabet Prevalansı Oranları	13
Şekil 3. Sağlıklı Retina Görüntüsü	14
Şekil 4. Diyabetik Retinopati Görüntüsü.....	15
Şekil 5. Solda: Sağlıklı bir bireyin görüşü. Sağda: DR hastalığına sahip bireyin görüşü	15
Şekil 6. Diyabetik Retinopati Aşaması.....	17
Şekil 7. Fundus Floresein Anjiyografi (FFA) tekniği ile elde edilen retina görüntüsünde mikroanevrizma lezyonu	18
Şekil 8. Gözün Retina Tabakasındaki Kanama ve Sert Eksuda Lezyonları	18
Şekil 9. Retina görüntüsündeki yumuşak eksuda	19
Şekil 10. Gözün retina tabakasında venöz boğumlanma ve IRMA (intraretinal mikrovasküler anormallikler) lezyonları	20
Şekil 11. Yumuşak Ve Sert Eksüda.....	22
Şekil 12. Çalışmanın Akış Diyagramı	23
Şekil 13. Verisetindeki DR ‘nin Dağılımı	24
Şekil 14. Ön İşleme uygulanmış fundus görüntüleri	26
Şekil 15. AI, ML ve DL Arasındaki İlişkisi	27
Şekil 16. Biyolojik Nöron Hücresi	29
Şekil 17. Evrişimli sinir ağına ait temel yapı taşları.....	33
Şekil 18. Evrişim katmanlarının özelleşmiş filtreleri aracılığıyla görsel veriden özgün özellik haritası	35
Şekil 19. 6×6 boyutunda giriş görüntüsüne uygulanan padding işlemi.....	36
Şekil 20. Yapay Nöronda girdi, ağırlıklar, net fonksiyonu, aktivasyon fonksiyonu ve çıktı.....	37
Şekil 21. ReLu katmanının çıkış verisi üzerinde gösterdiği etki	38
Şekil 22. Maksimum ve Ortalama katmanlarının şematik gösterimi	39
Şekil 23. Tam bağlı katman	40

Şekil 24. Seyreltme işlemi (a) orijinal ESA (b) seyreltme işlemi uygulanan ESA ...	42
Şekil 25. Aktivasyon Fonksiyonları	43
Şekil 26. Öğrenme oranı seçilmesi (a) Büyük öğrenme oranı seçimi (b) Küçük öğrenme oranı seçimi.	47
Şekil 27. MNIST veri seti kullanılarak bazı optimizasyon yöntemlerinin karşılaştırılması	52
Şekil 28. Transfer öğrenme tekniği blok diyagramı	53
Şekil 29. VGG-19 mimarisi.....	55
Şekil 30. EfficientNet modellerinin diğer modellerle karşılaştırılması.....	59
Şekil 31. Doğrulama Grafiği	61
Şekil 32. Eğitim Ve Doğrulama Kayıp Grafiği	61
Şekil 33. Overfitting Grafiği.....	62
Şekil 34. Çok Sınıflı ROC Eğrisi.....	63
Şekil 35. Her Sınıf İçin F1 Skoru	64
Şekil 36. Karışıklık (Confusion Matrix) Matrisi	65

KISALTMALAR

APTOS	: Asia Pacific Tele-Ophthalmology Society (Asya Pasifik Tele-Oftalmoloji Topluluğu)
CLAHE	: Contrast Limited Adaptive Histogram Equalization (Kontrast Sınırlı Adaptif Histogram Eşitleme)
CNN	: Convolutional Neural Network (Evrışimli Sinir Ağı)
CPU	: Central Processing Unit (Merkezi İşlem Birimi)
CSV	: Comma-Separated Values (Virgülle Ayrılmış Değerler)
DİA	: Derin İnanç Ağı
DL	: Deep Learning (Derin Öğrenme)
DÖ	: Derin Öğrenme
DR	: Diyabetik Retinopati
DSÖ	: Dünya Sağlık Örgütü
ESA	: Evrışimli Sinir Ağı
GPU	: Graphic Processing Unit (Grafik İşlem Birimi)
KSA	: Konvolüsyonel Sinir Ağı
ML	: Machine Learning (Makine Öğrenmesi)
OpenCV	: Open Source Computer Vision Library (Açık Kaynak Bilgisayar Görüsü Kütüphanesi)
PDR	: Proliferatif Diyabetik Retinopati
PODR	: Proliferatif Olmayan Diyabetik Retinopati
RGB	: Red Green Blue (Kırmızı, Yeşil, Mavi)
TN	: True Negative (Doğru Negatif)

TP	: True Positive (Doğru Pozitif)
vd.	: ve diğerleri
WHO	: World Health Organization (Dünya Sağlık Örgütü)
YSA	: Yapay Sinir Ağı
YZ	: Yapay Zeka

SÖZLÜK

Akson: Sinir hücresinin diğer sinir hücreleri veya hücrelerle iletişim kurmak için uzanan uzun, lif benzeri bir yapıdır.

Dendrit: Sinir hücresinin gövdesinden çıkan ve çevresindeki diğer sinir hücrelerinden gelen bilgiyi almak için kullanılan kısa ve dallanmış uzantılardır.

Fundus Görüntüsü: Gözün arka iç kısmının, yani retinanın, optik sinirin ve kan damarlarının detaylı bir görüntüsünü elde etmek için kullanılan bir tıbbi terimdir.

Model: Belirli bir problemin çözümü için kullanılan matematiksel ve algoritmik yapı veya sistem anlamına gelir.

Nöron: Sinir sisteminin temel yapı birimidir. Sinir hücresi olarak da bilinen nöronlar, sinir sinyallerini alıp işleyerek vücutta iletişim ve kontrolün sağlanmasına yardımcı olurlar.

Örnekleme: İstatistik ve araştırma yöntemleri alanında önemli bir kavramdır ve genel olarak belirli bir popülasyondan seçilen ve bu popülasyonu temsil eden bir alt küme anlamına gelir.

Piksel: Görsel bir sahnede veya ekranda tek bir noktayı temsil eder. Bir piksel, belirli bir renk değeriyle tanımlanan ve diğer piksellerle birlikte bir görüntüyü oluşturan en küçük grafik birimdir.

Sinaps: Sinir hücreleri arasındaki iletişimi sağlayan yapıdır. Sinir sistemindeki temel işlevi, bilgi iletimidir. Sinapslar, bir sinir hücresinden diğerine elektriksel veya kimyasal sinyallerin iletilmesini sağlar.

Sitoplazma: Hücre zarı ile hücre çekirdeği arasında bulunan ve hücre içindeki çeşitli organelleri, proteinleri, besin maddelerini ve diğer hücresel yapıları içeren jel benzeri bir maddedir.

Soma: Sinir hücresinin merkezi kısmıdır ve hücrenin çekirdeğini, sitoplazmasını ve diğer organellerini içerir.

Veri seti: Bir araştırma, çalışma veya analiz için toplanan veya üretilen verilerin bütününe denir.

GİRİŞ

Diyabet, vücudun yeterli miktarda insülin hormonu üretememesi veya üretilen insülinin etkili bir şekilde kullanılamaması sonucunda karbonhidrat, yağ ve proteinlerden yeterince faydalanamaması, bu durumun doğal bir sonucu olarak kan şekerinin sürekli olarak yükseldiği ve sürekli bakım gerektiren kronik bir hastalıktır.

Dünya Sağlık Örgütü'nün kronik hastalıklar raporuna göre, diyabet hastalığı dünya genelinde en çok görülen kronik hastalıklar arasında birinci sırada yer almaktadır.

Diyabet genellikle ağız kuruluğu, aşırı iştah ve ya iştahsızlık, aşırı susama, sık idrara çıkma, gece idrara kalkma, bulanık görme, belirgin olmayan kilo kaybı, ayaklarda uyuşma, karıncalanma, yanma hissi, idrar yolu enfeksiyonları, vulvovajinit, mantar enfeksiyonları, kaşıntı, cilt kuruluğu, hızlı yorulma ve halsizlik gibi belirtilerle kendini gösterir.

En yaygın olanı, genellikle yetişkinlerde ortaya çıkan ve vücudun insüline direnç geliştirdiği veya yeterli miktarda insülin üretemediği durumlarda ortaya çıkan tip 2 diyabettir. Son 30 yılda, tip 2 diyabetin prevalansı tüm gelir seviyelerindeki ülkelerde önemli ölçüde artmıştır. Bir zamanlar juvenil diyabet veya insüline bağımlı diyabet olarak bilinen Tip 1 diyabet ise, pankreasın kendi başına çok az veya hiç insülin üretemediği kronik bir durumu temsil eder. Diyabetle yaşayan bireyler için, uygun fiyatlı tedavilere, özellikle insüline erişim, hayatta kalmak açısından kritik bir öneme sahiptir. Diyabet ve obezite artışının 2025'e kadar global olarak durdurulması, küresel bir hedef olarak kabul edilmiştir.

Dünya çapında yaklaşık 422 milyon insan diyabet hastasıdır, ve bu kişilerin çoğunluğu düşük ve orta gelirli ülkelerde yaşamaktadır. Her yıl, 1,5 milyon ölüm doğrudan diyabete bağlanmaktadır. Diyabetin vaka sayısı ve prevalansı, son birkaç on yılda sürekli bir şekilde artış göstermektedir.

Diyabetik Retinopati (DR) hastalığı, Non-Proliferatif Diyabetik Retinopati (NPDR) ve Proliferatif Diyabetik Retinopati (PDR) olmak üzere iki ana kategoride incelenir. NPDR hastalığının erken evresi olarak kabul edilirken, PDR hastalığının ileri evresini temsil eder. NPDR evresi, hafif, orta ve şiddetli olmak üzere üç aşamaya ayrılır. Hafif NPDR evresinde, fundus görüntülerinde az sayıda küçük kanama ve

mikroanevrizmalar gözlemlenir. Orta NPDR evresinde ise kanamalar, eksudalar, venöz değişiklikler, retinal katmanlarda yaygın mikroanevrizmalar ve IntRaretinal Mikrovasküler Anomaliler (IRMA) bulunabilir. Şiddetli NPDR evresinde ise fundus görüntülerinde kanamalar, eksudalar, yaygın arteriyel tıkanıklıklar, venöz değişiklikler ve IRMA yoğunluğunda artışlar gözlemlenir. PDR evresinde, NPDR evrelerindeki bulgulara ek olarak fundus görüntülerinde retinal neovaskülarizasyonlar ve minimal fibröz doku proliferasyonu tespit edilir. Fundus görüntülerinden elde edilen tüm bu bulgular, hastaların görme yeteneklerinin azalmasına veya kaybolmasına neden olabilir. Görme yetisinin korunması için yapılan son yıllardaki araştırmalar, DR hastalığının erken aşamalarda tespit edilmesine odaklanmıştır.

1. LİTERATÜR ÇALIŞMASI

Nazir ve ekibi (2019), DR hastalığını sınıflandırmak için anatomik çıkarımlardan bağımsız yeni bir yöntem önermiştir. Önerilen yöntemde, içerik tabanlı görüntü alma araştırmasının özellik çıkarımını genişleterek ve çok kategorili tanıma kavramlarını yeni dörtgen yerel sekizli desenler olarak adlandırılan bir yöntemle birleştirerek fundus görüntülerinden anatomik çıkarımlardan bağımsız olarak özellik çıkarımı gerçekleştirmişlerdir. Ardından, aşırı öğrenme makinesini kullanarak sınıflandırma yapmışlardır. 44.000'den fazla DR hastasını temsil eden 88.704 fundus görüntüsünden oluşan bir veri seti üzerinde gerçekleştirdikleri deneysel çalışmada, aşırı öğrenme makinesi ile doğruluk, kesinlik ve geri çağırma oranları sırasıyla %99.6, %99.1 ve %99.3 olarak bulunmuştur (Nazir vd., 2019).

Math ve Fatima (2021), derin öğrenme kullanarak DR ve DR lezyonlarını tespit etmek ve sınıflandırmak için bölütleme tabanlı bir öğrenme yaklaşımını önermişlerdir. İlk olarak, fundus görüntülerine ve normalizasyon faktörlerine, örneğin kontrast görüntü ölçeği ve aydınlatma gibi, ön işleme uygulamışlardır. Görüntü bölütlerini, önceden işlenmiş görüntüden çıkararak ve önceden eğitilmiş Evrişimli Sinir Ağı'nı (ESA) diyabetik retinopatinin bölüt seviyesini elde etmek için uyarlayarak önceden işlemişlerdir. Daha sonra, fundus görüntülerini sınıflandırmak için tüm bölütleme seviyelerinin entegrasyonunu kullanmışlardır. Düzensiz diyabetik retinopatinin lezyonlarını daha iyi belirlemek için uçtan uca bölütleme tabanlı bir öğrenme yaklaşımı uygulamışlardır. Önerilen modelin değerlendirme sonuçlarına göre %96.3 AUC, %96.37 duyarlılık ve %96.37 özgüllük değerleri elde etmişlerdir (Math ve Fatima, 2021).

Qummar ve ekibi (2019), DR hastalığının teşhisi için derin öğrenme temelli bir yöntem uygulamışlardır. Bu yöntemde, halka açık retina görüntülerini içeren bir Kaggle veri setini kullanmışlardır. Veri setindeki zengin özellikleri kodlamak ve sınıflandırma işlemini geliştirmek için ESA tabanlı ResNet50, InceptionV3, Xception, Dense 121 ve Dense 169 modellerini retina görüntüleri ile eğiterek bir model önermişlerdir. Önerdikleri modelde, veri setlerini öncelikle dengelenmemiş şekilde kullanmışlar ve daha sonra üst ve alt örnekleme yaparak dengelemişlerdir. Elde edilen sonuçlara göre, önerilen modelin doğruluk, geri çağırma, özgüllük, kesinlik ve F1-

skoru deęerleri sırasıyla %80.8, %51.5, %86.72, %63.85 ve %53.74 olarak bulunmuştur (Qummar vd., 2019).

Nwankpa ve meslektaşları (2018), DR teşhisine katkıda bulunmak için derin öğrenme tabanlı ESA'larla sınıflandırma yöntemi uygulamışlardır. Bu yöntemde, halka açık Kaggle retina veri setinden faydalanmışlardır. Deneysel çalışmalarında, retina görüntülerini sınıflandırmak için AlexNet, VggNet, GoogleNet ve ResNet gibi modellere transfer öğrenme yöntemiyle birlikte hassas ayarlamalar yaparak sınıflandırma işlemini gerçekleştirmişlerdir. Yapılan çalışmalarda, en yüksek sınıflandırma doğruluğu VggNet mimarisinde %95.68 olarak belirlenmiştir (Nwankpa vd., 2018).

Qiao ve ekibi (2020) yaptıkları araştırmada, DR teşhisi için mikroanevrizma tespitine odaklanarak, derin öğrenme tabanlı bir model önermişlerdir. Önerdikleri yöntemde, DR lezyonlarının daha iyi şekilde tespit edilebilmesi için çeşitli ön işleme yöntemleri kullanmışlardır. Ön işleme adımından sonra lezyonların tespiti için anlamsal bölümlendirme, gauss filtreleme, ortak bilgilerin maksimize edilmesi ve temel bileşen analizi gibi yöntemlerle lezyonları tespit etmişler ve öznetelikleri çıkarmışlardır. Önerilen yöntemin koyu lezyonları tespit etmek için duyarlılık, özgüllük ve kesinlik deęerleri sırasıyla %97.4, %98.4 ve %95.1 olarak ölçülmüştür. Parlak lezyonları tespit etmek için ise sırasıyla %96.8, %97.1, %95.3 duyarlılık, özgüllük ve kesinlik deęerleri elde edilmiştir. Ayrıca, modelin test başarımı yaklaşık olarak %89 olarak bulunmuştur (Qiao vd., 2020).

Hemanth ve ekibi (2020), DR teşhisi için retina görüntülerini işleme ve derin öğrenme tabanlı bir hibrit model önermiştir. Önerdikleri yöntemde, öncelikle retina görüntülerine histogram eşitleme ve kontrast sınırlı uyarlanabilir histogram eşitleme gibi işlemler uygulanmıştır. Daha sonra, derin öğrenme modeliyle veri seti eğitilmiştir. MESSIDOR veri setinden elde ettikleri sonuçlarda, farklı görüntü işleme tekniklerini kullandıkları modellerin performansını karşılaştırmışlardır. Önerilen modelin ortalama doğruluk, duyarlılık, özgüllük, kesinlik, F-skoru ve GMean deęerleri sırasıyla %97, %94, %98, %94, %94 ve %95 olarak bulunmuştur (Hemanth vd., 2020).

Chakraborty ve ekibi(2020), DR teşhisi için denetimli öğrenme tabanlı bir Yapay Sinir Ağı (YSA) modeli geliştirmişlerdir. Çalışmalarında, retina

görüntülerinden çıkarılan özellikleri kullanarak UCI Machine Learning Repository'den elde edilen verileri girdi olarak kullanmışlardır. Bu özellikleri, ileri beslemeli geri yayımlı bir YSA mimarisi içinde değerlendirmişlerdir. Eğitim sürecinde Levenberg–Marquardt algoritmasını tercih etmişlerdir. Modelin sinir ağı yapısını belirlerken çeşitli deneme-yanılma yöntemleri kullanarak 20-20-1 nöronlu bir ağ seçmişlerdir. Deneysel çalışmalarında veri setini %90 eğitim ve %20 test verisi olarak bölerek modelin performansını değerlendirmişlerdir. Önerilen modelin doğruluk, özgüllük, duyarlılık, F skoru ve Ortalama Karesel Hata (OKH) gibi değerlerini sırasıyla %97.13, %97, %97.2, %97.2 ve 0.001 olarak bulmuşlardır (Chakraborty vd., 2020).

Khan ve ekibi (2020), DR tespiti için bir görüntü işleme algoritması önermiştir. Bu yöntem, Destek Vektör Makinesi (DVM) sınıflandırma yöntemini kullanarak fundus görüntülerinin piksel bilgilerini değerlendirir. Yapılan deneysel çalışmada 36 fundus görüntüsü üzerinde %90 üzerinde başarı elde edilmiştir (Khan vd., 2020).

Vijayan ve arkadaşları (2020), DR sınıflandırması için öznelilik çıkarımına dayalı bir makine öğrenmesi yöntemi geliştirmişlerdir. İlk olarak, 35,126 fundus görüntüsünden oluşan veri setindeki sınıf dengesizliğini gidermek için rastgele örnekleme ve alt örnek filtreleri kullanmışlardır. Ardından, elde edilen görüntülerden Gabor Filtresi kullanarak toplamda 61 öznelilik elde etmişlerdir. Son aşamada, görüntüleri J48, Rastgele Orman (RO), K-en Yakın Komşu (KYK) ve OneR sınıflandırıcılarıyla sınıflandırmışlardır. Deneysel çalışmalarında, toplamda 10,024 fundus görüntüsü, 61 öznelilik ve 10 kat çapraz doğrulama kullanmışlardır. Önerilen modelin performansı şu şekildedir: J48 sınıflandırıcı ile %52.6 doğruluk ve %75.5 ağırlıklı ortalama ROC; RO sınıflandırıcısı ile %70.2 doğruluk ve %86.2 ağırlıklı ortalama ROC; KYK sınıflandırıcısı ile %69.5 doğruluk ve %79.9 ağırlıklı ortalama ROC; OneR sınıflandırıcısı ile %39.7 doğruluk ve %58.4 ağırlıklı ortalama ROC (Vijayan vd., 2023).

Zeng ve ekibi (2019), DR sınıflandırması için transfer öğrenme tekniğini kullanan bir derin öğrenme yöntemi önermiştir. Önerdikleri model, binoküler fundus görüntülerini girdi olarak almakta ve bunların korelasyonunu öğrenerek tahminde bulunmaktadır. Burada "binoküler" ifadesi, iki gözün kullanılmasıyla yapılan görme

işlemine ifade etmektedir. Deneysel çalışmalarında, 28,104 binoküler fundus görüntüsünü modelin eğitimi için kullanırken, 7,024 binoküler fundus görüntüsünü modelin testi için kullanmışlardır. Önerilen modelin hassasiyet, özgüllük ve kappa skoru sırasıyla %82.2, %70.7 ve %82.9 olarak bulunmuştur (Zeng vd., 2019).

Deepa ve ekibi (2021), DR tespiti için makro ve mikro öznitelik çıkarımına dayalı bir model önermiştir. Önerilen model dört aşamalı bir süreçten oluşur. İlk olarak, görüntülerin bilgilerini iyileştirmek için normalleştirme, yeşil kanal çıkarma ve aydınlatma eşitleme tekniklerini uygulamışlardır. Mikro özniteliklerin çıkarımı için ikinci aşamada çift ağaçlı Kuaterniyon Ağırlık tekniğini kullanmışlardır. Makro özellikler için ise görüntüleri 8×8 boyutunda yamalara bölmüş ve enerjilerini hesaplamışlardır. Üçüncü aşamada, makro ve mikro özniteliklerini birleştirip temel bileşen analizi tekniğiyle boyutlarını azaltmışlardır. Son aşamada ise Yapay Sinir Ağı (YSA), Aşırı Öğrenme Makinesi (AÖM) ve K-en Yakın Komşu (KYK) sınıflandırıcıları ile sınıflandırmışlardır. Deneysel çalışmalarında 10 kat çapraz doğrulama yöntemini kullanmışlardır. KYK sınıflandırılması ile %90.6 doğruluk, AÖM sınıflandırmasıyla %93.2 doğruluk ve KYK sınıflandırmasıyla %92.5 doğruluk elde ettiklerini bulmuşlardır (Deepa vd., 2021).

Gayathri ve ekibi (2020), DR sınıflandırması için öznitelik çıkarımına dayalı bir model önermiştir. Bu çalışma IDRID, MESSIDOR ve DIARETDB0 veri setleri üzerinde yapılmıştır. Başlangıçta, fundus görüntülerinden elde edilen öznitelikler için hızlandırılmış sağlam özellikler ve ikili sağlam değişmez ölçeklenebilir anahtar noktalar kullanılmıştır. Ardından, öznitelik seçimi ve sıralaması için maksimum uygunluk minimum fazlalık teknikleri uygulanmıştır. Son aşamada ise DR'yi ikili ve çoklu sınıflandırmak için DVM, Adaboost, Naive Bayes, RO ve ÇKA gibi farklı sınıflandırma teknikleri kullanılmıştır. Deneylerde toplamda 30 öznitelik kullanılmıştır. Çalışmanın en iyi sonuçları ÇKA sınıflandırıcı ile elde edilmiştir. Bu sınıflandırıcı ile, ikili sınıflandırma için üç veri setinde ortalama doğruluk %98.13, çoklu sınıflandırma için ise IDRID ve MESSIDOR veri setlerinde ortalama doğruluk %95.13 olarak belirlenmiştir (Gayathri vd., 2020).

Ali ve ekibi (2020), DR teşhisi için görüntü işleme ve makine öğrenimi temelli bir yöntem geliştirdi. Geliştirdikleri modelde, her biri 500 adet olmak üzere toplamda

2500 retina görüntüsü kullanıldı. Her bir retina görüntüsünden lezyon analizi için histogram, dalgacık dönüşümü, birlikte oluşum matrisi ve çalışma uzunluğu matrisi tekniklerini kullanarak dört tür öznitelik çıkarıldı. Modelin sınıflandırma doğruluğunu artırmak için veri birleştirme yaklaşımı kullanılarak kaynaşmış bir hibrit veri kümesi oluşturuldu. Deneysel çalışmada, her bir retina görüntüsünden 245 adet hibrit öznitelik gözlemlendi ve bu öznitelikler dört farklı öznitelik seçim tekniği kullanılarak 13 optimize öznitelik seçildi. Önerilen modelden sıralı minimum optimizasyon, lojistik, ÇKA, lojistik model ağacı ve basit lojistik makine öğrenmesi sınıflandırıcıları ile elde edilen sonuçlar sırasıyla %98.53, %99, %99.66, %99.73 ve %99.73 doğruluk oranlarına ulaştı (Ali vd., 2020).

Mahmoud ve meslektaşları (2023), otomatik olarak DR hastalığını tespit etmek için bir hibrit endüktatif makine öğrenmesi tabanlı bir yöntem geliştirdi. Geliştirdikleri model, uygun DR vakalarını belirleyerek renkli fundus görüntülerini sağlıklı veya sağlıklı olarak sınıflandırıyor. Algoritma, ön işleme, bölütleme, öznitelik çıkarma ve sınıflandırma olmak üzere dört aşamadan oluşuyor. Ön işleme aşamasında, retina görüntülerini belirli bir parlaklık seviyesine normalleştirmek için önlem alındı, bölütleme aşamasında ise görüntülerin bölümlere ayrılması için kodlama ve kodun çözülmesi gerçekleştirildi. Öznitelik çıkarımı ve sınıflandırma aşamasında ise çoklu örnek öğrenme tekniği kullanıldı. Deneysel çalışmaları sonucunda, önerdikleri hibrit modelin doğruluk, duyarlılık ve özgüllük metriklerini sırasıyla %96.62, %95.31 ve %96.88 olarak belirlediler (Mahmoud vd., 2023).

Tsao ve çalışma arkadaşları (2018), DR hastalığının tespiti için makine öğrenmesi tabanlı bir model geliştirdiler. Önerdikleri model, destek vektör makineleri, karar ağaçları, yapay sinir ağları ve lojistik regresyonlar gibi çeşitli veri madenciliği tekniklerini bir araya getirmiştir. Deneysel aşamada, veri setini %60 eğitim, %20 doğrulama ve %20 test olarak bölerek önerdikleri modele uyguladılar. Elde ettikleri sonuçlara göre, destek vektör makineleri için yaklaşık %81 doğruluk, lojistik regresyon için yaklaşık %79 doğruluk, yapay sinir ağları için yaklaşık %78, karar ağaçları için ise yaklaşık %78 doğruluk elde ettiler (Tsao vd., 2018).

Dhokal ve diğerleri (2019) yaptıkları çalışmada DR ikili ve sınıflandırma için öznitelik çıkarımına dayalı bir makine öğrenmesi modeli önerdiler. Başlangıçta

modelin daha iyi performans gösterebilmesi için görüntüleri gri tonlamalı hale getirip histogram eşitleme tekniğini uyguladılar. Ardından, elde edilen görüntüler üzerinde optik disk, damarlar ve Ex'lerin segmentasyonunu gerçekleştirdiler. Öznelik çıkarımı için gri düzey birlikte oluşum matrisi yöntemini kullandılar. Son olarak, sınıflandırma için Adaboost sınıflandırıcı ve ESA tekniğini entegre ettiler. Deneysel aşamada Himalaya Göz Hastanesi Pokhara, MESSIDOR ve EyePACS gibi standart veri setlerini kullandılar. Elde edilen sonuçlara göre, Adaboost sınıflandırıcısıyla yerel veri seti için %65.3 özgüllük, %100 hassasiyet, %65.3 doğruluk ve %79 F skoru; standart veri setleri için %64.2 özgüllük, %87.1 hassasiyet, %62 doğruluk ve %73.9 F skoru elde edildi. ESA ile yapılan sınıflandırmada ise farklı mimarilerden oluşan iki durumda, durum 1 için %96.9 doğruluk, durum 2 için ise %80.9 doğruluk elde edildi (Dhakal vd., 2019).

DR hastalığının tespiti için fundus görüntüleri üzerinden geliştirilen birçok uygulamalı mühendislik ve uçtan uca öğrenme tabanlı yaklaşım bulunmaktadır. Ancak, mevcut yöntemler hafif NPDR evresini yüksek doğrulukla sınıflandırmada yetersiz kalmaktadır. Hafif NPDR evresinin doğru şekilde belirlenmesi, hastalığın erken tedavi edilmesi ve kontrol altına alınması açısından büyük önem taşımaktadır (Qummar vd., 2019; Gayathri vd., 2020). Bu tez çalışmasında, DR hastalığının erken evresi olan hafif NPDR dahil olmak üzere tüm evrelerinin yüksek doğrulukla ve hızlı bir şekilde tespit edilebilmesi için iki boyutlu sinyal işleme teknikleri, ESA ve transfer öğrenmesi yöntemleri kullanılarak derin öğrenme tabanlı bir DR hastalığı sınıflandırıcı modeli geliştirilmiştir. Geliştirilen model, ön işleme ve ESA tabanlı önceden eğitilmiş bir derin öğrenme mimarisiyle sınıflandırma olmak üzere iki temel aşamadan oluşmaktadır.

Ön işlem aşamasının ana amacı, modelin daha iyi performans gösterebilmesi için veri setinde bulunan görüntülerin normalleştirilmesi, büyütülmesi, simetriği alınması ve belirli bir açıyla döndürülmesi gibi iki boyutlu sinyal işleme teknikleriyle görüntü sayısını artırmaktır. Sınıflandırma aşamasının temel amacı ise artırılan fundus görüntülerinin, ESA tabanlı önceden eğitilmiş bir derin öğrenme mimarisi üzerinde uygulanan transfer öğrenme tekniğiyle önerilen modelin beş sınıfı yüksek doğrulukla tahmin etmesidir. Ayrıca, önerilen model, üç farklı ESA tabanlı önceden eğitilmiş derin öğrenme mimarisiyle karşılaştırılmıştır.


2.RETİNANIN YAPISI VE DİYABETİK RETİNOPATİ HASTALIĞI

Bu kısımda, göz ve retinanın anatomisi ile birlikte tez çalışmasının odaklandığı DR hastalığının önemi ele alınmaktadır. Hastalığın tanısı, kökenleri ve evreleri hakkında genel bilgiler yer almaktadır.

2.1. Göz Ve Retina

Göz, içi boş küre formunda bir organdır ve ortalama olarak 10-12 gram ağırlığında ve 2-2,5 cm çapındadır. Temel olarak üç tabakadan oluşan göz, dıştan içe doğru şu sırayla düzenlenmiştir: sert tabaka, damar tabaka ve ağ tabaka. Bunun yanı sıra, gözü koruyan ve destekleyen çeşitli oluşumlar da bulunmaktadır. Bu oluşumlar arasında kaşlar, göz kapakları, göz kasları, gözyaşı bezleri ve konjonktiva yer almaktadır (Uyansız, 2019).

Göz, sert tabaka, damar tabaka ve retina (ağ tabaka) olmak üzere üç ana bölümden meydana gelir (Şekil 1). Sert tabaka, gözün dış kısmında yer alan beyaz renkli bir bölümdür ve gözü dış etkilere koruma görevi görür. Bu tabaka aynı zamanda ışığı kırdığı için saydam tabaka (kornea) olarak da adlandırılır. Damar tabaka ise sert tabakanın altında bulunur ve gözü besleyen kan damarlarını içerir.



Şekil 1. İnsan gözünün anatomisi

Kaynak: Uyansız, M. (2019). *Göz Nedir? Yapısı, İşlevi ve Hastalıkları*. 28 Ocak 2024 tarihinde <https://www.psikopatolojibilimi.com/2019/01/23/goz-nedir-yapisi-islevi-ve-hastaliklari/> adresinden edinilmiştir.

Retina, göz duvarının en iç kısmında konumlanmış ve ışığa duyarlı sinir hücrelerini içeren bir tabakadır. Işık, önce korneadan geçer, ardından ise mercek tarafından kırılarak retina üzerine odaklanır. Retinadaki sinir hücreleri, bu ışığı elektro-kimyasal enerjiye dönüştürerek optik sinir (görme siniri) aracılığıyla beyne iletilir.

Retina içerisinde, karanlıkta görmemizi sağlayan rod hücreleri ve aydınlıkta görmemizi sağlayan kon hücreleri bulunmaktadır. Kon hücreleri, S kon (kısa dalga boylu mavi ışık), M kon (orta dalga boylu yeşil ışık) ve L kon (uzun dalga boylu kırmızı ışık) olmak üzere üç çeşide ayrılır; her biri belirli dalga boylarına duyarlıdır.


Retinada oluşan yırtıklar veya göz içindeki iltihabi durumlar, özellikle arka üveit olarak adlandırılanlar, retinayı etkileyebilir. Ayrıca, şeker hastalığı ve sarı nokta hastalığı gibi durumlar da retinada hasarlara neden olabilir (Gündoğan, 2018).

Genel olarak bakıldığında, retinada meydana gelen hastalıklar aşağıdaki gibi sıralanabilir.

- Şeker ve hipertansiyon hastalığına bağlı kanamalar
- Retina damar tıkanmaları
- Retina dekolmanları / yırtıkları, Sarı nokta hastalığı
- Doğumsal retina hastalıkları
- Retina altında sıvı birikmesi, retina ödemi
- Göz içine giren yabancı cisimler
- Makula delikleri
- Vitreoretinal yüzey bozuklukları
- Retina tümörleri

2.2. Diyabet

Diyabet (Diabetes Mellitus), tek bir bozukluk değildir ve tanımı kişinin bakış açısına bağlı olarak değişebilir. Tıbbi bir perspektiften bakıldığında, diyabet, hiperglisemi ile ilişkilendirilen ve kısmi veya tam insulin yetersizliği tarafından tetiklenen bir dizi metabolik durumu temsil eder. Kronik hiperglikemiye maruz kalma, retinada, böbrekte veya periferik sinirlerde mikrovasküler komplikasyonlara neden olabilir. Bunlar diyabetin karakteristik özellikleri olabilir, ancak bozukluğu tanımlamak için kullanılamazlar çünkü ortaya çıkması çok uzun zaman alır. Diyabetin sözde makrovasküler komplikasyonları (miyokard enfarktüsü, inme, periferik arter hastalığı) daha sık görülür, çünkü bunlar genellikle prediyabetik durumda bulunurlar. Diyabetin 'erken aterosklerozla ilişkili hiperglikemi' olarak tanımlanması önerilmiştir, böylece çoğu hastanın maruz kaldığı klinik sorunlara vurgu yapılır.



Şekil 2. Avrupa Ülkelerinde Karşılaştırılabilir Diyabet Prevalansı Oranları

Kaynak: saglik (2014,10,01) *Türkiye diyabet programı*. 1 Haziran 2024 tarihinde https://hsgm.saglik.gov.tr/depo/Yayinlarimiz/Programlar/Turkiye_Diyabet_Programi.pdf adresinden edinilmiştir.

Toplumsal bir perspektiften bakıldığında, diyabet tanımı, hastalığın tedavisinin maliyeti ve ilişkili erken morbidite ve mortalite açısından ekonomilere yük koyduğu durumu içerir. Bireysel hasta perspektifinden bakıldığında ise, günlük olarak beslenme, yaşam tarzı ve kan şekeri izleme gibi konulara sürekli dikkat gerektiren, sık sık ilaç kullanımını içeren bir ömür boyu süren bir durumdur. Bu durum, değişen

derecelerde anksiyete, depresyon ve sađlık uzmanlarına sıkça başvuru gerektirebilir (Egan ve ark., 2019).

2.2.1. Diyabetin Sınıflandırması


Diyabet genellikle dört ana kategoride sınıflandırılır: Tip-I, Tip-II, gestasyonel diyabet ve diđer özel türler. Bu sınıflandırmalar arasında en yaygın olanlar Tip-I ve Tip-II diyabet türleridir. Gestasyonel diyabet, gebelik sırasında ortaya çıkan bir türü ifade ederken, diđer spesifik türler ise çeşitli nedenlere bađlı olarak ortaya çıkan ve pankreas üzerindeki etkileriyle karakterize edilen yüksek kan şekeri seviyelerini tanımlar (Coşansu, 2015).

2.3 Diyabetik Retinopati

Diyabet, insan vücutta insülin hormonunun yetersiz salgılanması veya etkisinin azalması sonucu kan şekerinin artması ile karakterize edilen, ömür boyu devam eden bir hastalıktır. Diyabete bađlı olarak gelişen bir komplikasyon ise gözün retina tabakasındaki damarlarda meydana gelen hasardır ve bu duruma Diyabetik Retinopati (DR) adı verilmektedir. Kobrin Klein'in 2007 tarihli çalışmasına göre, DR'nin görülme olasılığı, diyabetin süresi ile doğru orantılı olarak artmaktadır (Klein, 2007).



Şekil 3. Sağlıklı Retina Görüntüsü



Şekil 4. Diyabetik Retinopati Görüntüsü

DR, erken aşamada tespit edildiğinde başarılı bir şekilde tedavi edilebilir ve görme kaybının önüne geçilebilir. Ancak, erken teşhis ve tedavi sağlanmazsa DR ilerleyerek körlüğe neden olabilir. Bu nedenle, diyabet hastalarının düzenli olarak retina taramalarından geçmeleri kritik bir öneme sahiptir, çünkü bu taramalar sayesinde DR erken aşamada teşhis edilebilir.

Günümüzde, retina taramaları genellikle Fundus Floresein Anjiyografisi (FFA) tekniği kullanılarak gerçekleştirilmektedir. DR'nin toplum arasında yaygın olma olasılığı göz önüne alındığında, diyabet hastalarının her yıl düzenli olarak retina taramalarını yaptırmaları, potansiyel riskleri erken tespit etme ve etkili bir tedaviye başlama açısından büyük önem taşımaktadır.



Şekil 5. Solda: Sağlıklı bir bireyin görüşü. Sağda: DR hastalığına sahip bireyin görüşü


Kaynak: *Anonim*

FFA, retinada ortaya çıkan hastalıkların değerlendirilmesi amacıyla sıkça tercih edilen bir yöntemdir. Bu teknikte, retinanın damarsal görüntüleri elde etmek için

mavi ışık altında sarı-turuncu renkli floresein adlı bir madde kol üzerinden vücuda verilir. Floresan özellik gösteren bu madde sayesinde retinadaki damarlar detaylı bir şekilde incelenebilir. FFA, özellikle deneyimli ve uzman bir hekim tarafından yapılan inceleme ile Diyabetik Retinopati (DR) teşhisi koymak için kullanılabilir (Antcliff vd., 2000).

2.3.1. Diyabetik Retinopati Evreleri

DR (diyabetik retinopati), görme kaybının yaygın bir nedenidir ve hastalığın ilk aşamalarında belirtiler göstermeyebilir, hatta bazı durumlarda uzun süre fark edilemez. Ayrıca, DR tek başına gözde ağrı veya rahatsızlık gibi belirtiler oluşturmaz. Örneğin, görme merkezi hasar görmemişse ve sadece damar tabakasında hasar varsa, DR belirtileri çok ileri evrelere kadar ortaya çıkmayabilir. Bu durumlar aniden görme kaybına neden olabilir. DR'nin tipik belirtileri arasında uzak ve yakın görmede azalma, bulanık görüş ve eğri bükü görme yer alabilir.



Şekil 6. Diyabetik Retinopati Aşamaları


DR, Erken Retinopati Çalışma Grubu (Early Treatment Diabetic Retinopathy Study Research Group-ETDRS) tarafından geliştirilen Airlier-House

sınıflandırmasına göre derecelendirilir (Early Treatment Diabetic Retinopathy Study Research Group, 1991). DR, non-proliferatif diyabetik retinopati ve proliferatif diyabetik retinopati olmak üzere iki evrede incelenir. NPDR evresi, DR hastalığının ilk aşamasını temsil ederken, PDR evresi DR hastalığının ilerlemiş evresini tanımlar.

2.3.1.1. Non-Proliferatif Diyabetik Retinopati

NPDR, fundus görüntülerinde ilk lezyonların belirginleşmeye başladığı, kendi içinde hafif, orta ve şiddetli olmak üzere üç aşamaya ayrılan bir evre olarak değerlendirilmektedir.

Hastalığın hafif NPDR evresinde, ilk lezyon olan mikroanevrizmalar gözlemlenir. Şekil 7’de, göz retinasındaki mikroanevrizma belirtilmiştir.



Şekil 7. Fundus Floresein Anjiyografi (FFA) tekniği ile elde edilen retina görüntüsünde mikroanevrizma lezyonu

Mikroanevrizmalar, retina damarlarında 12-125 mikron çapında keseleşmelerin bir sonucu olarak ortaya çıkan fundus görüntülerinde küçük kırmızı noktasal şekillerdir.


Bu evrede ayrıca, az miktarda küçük kanamalar ve yer yer görülen sert eksudalar gibi diğer lezyonlar da gözlemlenir. Göz retinasındaki kanamalar ve sert eksudalara ise Şekil 8’de yer verilmektedir. Kanamalar, mikroanevrizmaların yırtılması sonucu oluşan retina içi kanamalar olarak tanımlanır. Sert eksudalar ise, damarlardan sızan lipid yapıdaki sıvının fundus görüntülerinde sarı-beyaz renkte

kümelenmiş veya mikroanevrizmaları çevrelemiş şekiller olarak ifade edilir (İnan, 2014).




Şekil 8. Gözün Retina Tabakasındaki Kanama ve Sert Eksuda Lezyonları

Orta NPDR evresindeki hastalık durumunda, mikroanevrizma ve kanama lezyonları dört retinal kadranda yaygın olarak bulunmaktadır. Bu lezyonlara ek olarak, yumuşak eksudalar, venöz boncuklanma ve IntraRetinal Mikrovasküler Anomali (IRMA) lezyonları da gözlenmektedir. Şekil 9'da, retina tabakasında bulunan yumuşak eksuda lezyonu görsel olarak tasvir edilmiştir. Yumuşak eksudalar, retinadaki sinirlerde pamuk atılmış gibi görünen lezyonlardır.



Şekil 9. Retina görüntüsündeki yumuşak eksuda

Hastalığın orta NPDR evresinde gözlenen venöz boğumlanma ve IRMA lezyonlarına ise Şekil 10'da yer verilmiştir. Fokal venöz genişleme alanları, ven duvarının incilmesi ile ilişkilidir ve venöz boğumlanma lezyonları olarak adlandırılmaktadır. IRMA lezyonu ise arteriol ve venüller arasında genişlemiş, kıvrımlı ve ince çizgiler gibi görünen kanalları tanımlar (İnan, 2014; Early Treatment Diabetic Retinopathy Study Research Group, 1991).



Şekil 10. Gözün retina tabakasında venöz boğumlanma ve IRMA (intraretinal mikrovasküler anormallikler) lezyonları

Şiddetli NPDR evresinde, retinada kanamalar, mikroanevrizmalar, venöz boğumlanmalar ve IRMA lezyonları belirgin bir şekilde gözlemlenmektedir. Bu evrede, tüm retinal kadrantlarda kanama ve mikroanevrizma lezyonları yaygın olarak bulunurken, en az iki retinal kadranda venöz boğumlanmalar ve en az bir retinal kadranda IRMA lezyonları gözlenmektedir. Şiddetli NPDR, diğer NPDR sınıfları arasında en fazla lezyona sahip olan evre olarak nitelendirilebilir. Ayrıca, bu evre, hastalığın PDR evresine en yakın aşama olarak tanımlanır ve bu nedenle retinada, PDR evresinin gelişme riskinin çok yüksek olduğu gözlemlenir (İnan, 2014).

2.3.1.2. Proliferatif Diyabetik Retinopati

DR hastalığının ileri evresi olan PDR evresinde, fundus görüntülerindeki NPDR lezyonlarına ek olarak, temel belirti olarak öne çıkan neovaskülarizasyonlar ve fibroz doku proliferasyonu bulunmaktadır. PDR tanısı koyulabilmesi için, bu lezyonların retina yüzeyinde veya optik diskte kesinlikle mevcut olması gerekmektedir (Engerman, 1989).

2.3.2. Mikroanevrizmalar

Diyabet kaynaklı kan şekeriindeki artış, vasküler duvarlarda değişikliklere yol açar. Bu değişimler, retinanın kılcal damarlarında mikroanevrizma adı verilen küçük, gerilmiş alanların ortaya çıkmasına neden olur. Mikroanevrizmalar, diyabetik retinopatinin ilk belirtisi olarak kabul edilir. Bu aşamada, mikroanevrizmalar genellikle körlüğe yol açmaz; ancak tanı konulmazsa hastalık ilerleyerek görme kusurları veya körlük gibi daha ciddi komplikasyonlara neden olabilir (Walter vd., 2007). Mikroanevrizmaların erken teşhisi, oftalmoloji uzmanları için son derece önemlidir, çünkü bu, görme kaybını engelleyebilecek bir önlem sağlar (Shan ve Li, 2016).


2.3.3. Kanamalar

Mikroanevrizmalara benzer bir şekilde, kanamalar genellikle aynı anda ortaya çıkar, ancak genellikle daha büyük boyuttadır. Retinanın kılcal damarları ve damarları sürekli kanama sonucu düzensiz kenarlar ve şekiller gösterirler (Grinsven vd., 2016).

2.3.4. Eksüdalar

Diyabetik retinopatinin daha ileri seviyelerinde ortaya çıkan etkilerden biri, eksüdaların belirgin hale gelmesidir. Retinal fundusta, farklı büyüklüklerde ve çeşitli şekillerde ortaya çıkan sarı-beyaz alanlar, bu durumu karakterize etmektedir. Eksüdaların temel nedeni, retinal kılcal damarlardaki yüksek kan şekeri seviyelerine bağlı olarak ortaya çıkan hasarlar sonucunda meydana gelmektedir. Bu durumda,

kılcal damar duvarlarında oluşan hasarlar, sıvı ve proteinlerin kılcal damar duvarlarını aşarak retina dokusuna sızmasına neden olur. Bu sızma sonucunda retina şişer ve eksüda adı verilen lezyonlar oluşur (Bethanney vd., 2015; Kumar vd., 2016).



Şekil 11. Yumuşak Ve Sert Eksüda


Eğer eksüdalar makula bölgesinde ortaya çıkarsa, bu durum körlüğe neden olabilir. Genellikle, eksüdaların varlığı göz bebeğindeki büyüme ile tespit edilir (Bethanney vd, 2015). Eksüdalar, sert eksüda ve yumuşak eksüda olmak üzere iki temel türe ayrılabilir. Sert eksüdalar, keskin kenarları ve sarı-beyaz alanları olan protein ve lipoprotein içeren kan plazması materyallerinden oluşur. Bu eksüdalar genellikle retinanın dış katmanında ortaya çıkar. Yumuşak eksüdalar ise sert eksüdalarından daha küçük olup, düşük kontrasta, beyaz-gri renkte ve yumuşak kenarlara sahiptir (Asiri vd., 2019).

3.MATERYAL VE YÖNTEM

Bu bölümde, çalışmada kullanılan veriler tanıtılmış ve bu veriler üzerinde kullanılan metot ve uygulama adımları açıklanmıştır. Çalışmanın bu adımları, Şekil 12'de özetlenmiştir. DR sınıflandırma metodu, fundus görüntü veri seti üzerinde çeşitli görüntü işleme teknikleri uygulandıktan sonra verilerin uygun şekilde etiketlenmesini içerir. Daha sonra, ilgili KSA modeli üzerinde eğitim ve test işlemleri gerçekleştirilir ve bunun sonucunda görüntüler sınıflandırılır.

Bu çalışma, diyabetik retinopati (DR) hastalığının hızlı teşhisini sağlamak amacıyla önerilen EfficientNetB5 modelinin performansını değerlendirmeye yöneliktir. DR hastalığı, DR yok, Hafif NPDR, Orta NPDR, Şiddetli NPDR ve PDR olmak üzere beş sınıfa ayrılmıştır.


Fundus retina görüntülerine uygulanan ön işleme adımlarının ardından, EfficientNetB5 modeli ile eğitim ve sınıflandırma gerçekleştirilmiştir. Toplamda 5.290 fundus retina görüntüsü ile çalışılmıştır. Çalışmada, önerilen modelin performansını değerlendirmek için çeşitli hata metrikleri kullanılmıştır.



Şekil 12. Çalışmanın Akış Diyagramı

3.1. DR Veriseti

Bu tez çalışmasında, Asya Pasifik Oftalmoloji Derneği (Asia Pacific Tele-Ophthalmology Society - APTOS) tarafından düzenlenen diyabetik retinopati sınıflandırma yarışmasına ait APTOS 2019 blindness detection veri seti kullanılmıştır (APTOS, 2019). Bu veri seti, Hindistan'daki Aravind Göz Hastanesi teknisyenleri tarafından birden fazla klinikten toplanan 5.290 retinal fundus görüntüsünden oluşmaktadır. Görüntülerin çözünürlükleri 474×358 piksel ile 3388×2588 piksel arasında değişmektedir ve tüm dosyalar .png formatındadır. Her bir görüntü, DR'nin tespiti için uzmanlar tarafından 0 ila 4 arasında bir ölçekte derecelendirilmiştir. Bu derecelendirme, hastalığın şiddetini yansıtmaktadır; DR olmayan görüntüler için ölçüt 0, hafif NPDR belirtileri için ölçüt 1, orta NPDR belirtileri için ölçüt 2, şiddetli NPDR belirtileri için ölçüt 3 ve PDR belirtileri için ölçüt 4 olarak sıralanmıştır. Veri setinde bulunan her bir sınıf için ölçüt değerleri ve görüntü sayıları, Tablo 3'de sunulmuştur.



Şekil 13. Verisetindeki DR 'nin Dağılımı

Toplamda, veri setinde 1805 DR Yok, 370 Hafif NPDR, 999 Orta NPDR, 193 Şiddetli NPDR ve 295 PDR görüntüsü bulunmaktadır. Şekil 13'de, bu çalışmada kullanılan veri setinde yer alan DR Yok, Hafif NPDR, Orta NPDR, Şiddetli NPDR ve PDR olan fundus görüntülerinin enine kesitlerine yer verilmiştir.


Tablo 1. DR Yok (ilk satır), Hafif NPDR (ikinci satır), Orta NPDR (üçüncü satır), Şiddetli

Ölçüt	DR Durumu	Görüntü Sayısı
0	DR Yok	1805
1	Hafif NPDR	370
2	Orta NPDR	999
3	Şiddetli NPDR	193
4	NPDR	295

Tablo 3’de belirtilen veri setindeki sınıflara ait görüntü sayıları incelendiğinde, sınıflar arasında belirgin bir dengesizlik olduğu görülmektedir. Bu nedenle, kullanılan modelin performansını ve dayanıklılığını artırmak amacıyla, her bir sınıftan 193 görüntü olmak üzere toplamda 965 retina görüntüsünden oluşan bir veri setine boyutlandırma, normalizasyon ve veri artırma teknikleri uygulanmıştır. Bu teknikler sayesinde, veri setindeki retina görüntüleri işlenerek her bir sınıf için 1200 retina görüntüsünden oluşan bir fundus veri seti oluşturulmuştur. Çalışmada kullanılan veri setinde, her bir sınıf için 1007 sentetik ve 193 gerçek retina görüntüsü olmak üzere toplamda 6000 fundus retina görüntüsü bulunmaktadır. Bu genişletilmiş veri seti ile veri çeşitliliği sağlanarak, modelin aşırı öğrenme riski azaltılmıştır.

3.2. Ön İşlem Adımları

Veri setindeki görüntülerin özelliklerinin KSA modeli eğitiminde daha net öğrenilebilmesi, görüntülerin standart hale getirilmesi ve işlem maliyetinin düşürülmesi amacıyla, görüntüler bir dizi işlemten geçirilmiştir. Bu işlemlerin yanı sıra, Gauss bulanıklaştırma ve CLAHE (Contrast Limited Adaptive Histogram Equalization) tekniklerikleri uygulanmıştır.



Şekil 14. Ön İşleme uygulanmış fundus görüntüleri

Çalışmada kullanılan veri setindeki fundus görüntüleri 474×358 piksel ile 3388×2588 piksel çözünürlük aralığına sahiptir. Ön işleme adımında ilk olarak, veri setinde bulunan fundus görüntüleri 400×400 piksel boyutuna şekil ve boyut açısından ölçeklendirilmiştir.

Ön işleme adımının ikinci aşamasında, veri çeşitliliğinin artırılması ve modelin başarısının ve performansının iyileştirilmesi amacıyla, 965 fundus retina görüntüsüne indirgenen veri setindeki her bir retina görüntüsüne çeşitli görüntü işleme teknikleri uygulanmıştır. Bu teknikler arasında döndürme, yansıma ve yakınlaştırma gibi iki boyutlu görüntü işleme teknikleri bulunmaktadır. Ön işleme adımının sonunda, fundus retina görüntülerinin alındığı cihazların farklı sıcaklık ve aydınlatma koşullarında çekilmiş olabilecek görüntüler arasındaki farklılıkların giderilmesi için görüntüler üzerinde normalizasyon işlemi gerçekleştirilmiştir. Bu çalışmada, veri setinde yer alan gerçek fundus görüntüleri ve sentetik olarak üretilmiş fundus görüntülerinin tamamına min-maks normalizasyon işlemi uygulanmıştır. Bu işlem, ön işlem aşamasını tamamlamış ve veri seti, oluşturulan modelin eğitilmesi ve test edilmesi için hazır hale getirilmiştir.


3.3. Derin Öğrenme Modellerinin Oluşturulması Ve Eğitimi

Modellerin eğitimi transfer learning yöntemiyle gerçekleştirilmiş ve sınıflandırma performanslarını artırmak için hassas ayarlamalar yapılmıştır. Çalışmada, diyabetik retinopatinin tüm sınıflarını yüksek doğrulukla sınıflandırabilmek için önerilen model EffcientNet-B5' dir.

3.4. Makine Öğrenmesi

1959'da Arthur Samuel tarafından öne sürülen "makine öğrenimi" terimi, esasen bilgisayarın açıkça programlanmadan öğrenme yeteneğini ifade eder. Bu, bilgisayar sistemlerinin deneyimlerden elde ettiği bilgilerle otomatik öğrenme süreçlerini geliştirmesini ve uygulamasını içeren bir tanımlamadır (Ayodele, 2010).

Makine öğrenimi, doğru tahminler yapabilme yeteneğini geliştirmek amacıyla, otomatik teknikler kullanarak matematiksel ve istatistiksel yöntemleri benimseyen bir süreçtir. Bu süreç, gözlenmiş bir örneklem kümesinden elde edilen veriler üzerinden çıkarımlar yaparak, bilinmeyen durumlar hakkında tahminlerde bulunan bir sistem olarak açıklanabilir (Schapire, 2003).



Şekil 15. AI, ML ve DL Arasındaki İlişkisi

İnsanların öğrenme süreci, bireyden bireye farklılık gösterir. Her insanın kendine özgü öğrenme yöntemleri bulunur ve bu, zamanla öğrenme sürecinin esnekliğini azaltabilir. İnsan zihnine farklı bir öğrenme yaklaşımıyla müdahale etmek, kalıplaşmış sistemi değiştirmeyi daha zor hale getirebilir.

Ancak, makine öğreniminde farklı algoritmaları tercih ederek öğrenme yöntemini değiştirmek oldukça basittir.

3.5. Yapay Sinir Ağları


Yapay Sinir Ağları (YSA), insan beynini modelleyerek öğrenme kabiliyetini kazandırmayı amaçlayan bir yapay zeka yöntemidir. Yapılarındaki yapay nöronlar sayesinde bilgiyi kendi hafızalarında saklarlar ve ağırlıklar aracılığıyla katmanlar arasındaki bağlantıları güçlendirirler. YSA, dağıtık bir mimariye sahiptir ve bilgiyi paralel olarak işler. Biyolojik sinir ağlarını taklit eden bilgisayar programları olan YSA, kendi kendine öğrenme yeteneğine sahiptir (Yılmaz ve Kaya, 2022, s. 30).

3.6. Biyolojik Sinir Ağı ve Nöron

Biyolojik sinir ağlarının yapısı, 10 milyardan fazla nöronun birbiriyle karmaşık bağlantılar kurmasıyla oluşur. Bu nöronlar, sinaps adı verilen özel yapılar aracılığıyla birbirleriyle iletişim kurarlar. Bir nöronun iç yapısı, soma, akson ve dentrit adı verilen bileşenlerden oluşur.

Soma, hücre çekirdeğini, çekirdekçiyi ve hücrenin içinde bulunan sitoplazmayı içerir. Dentritler, diğer nöronların dentritleriyle bağlantı kurabilen lifli yapılarıyla donatılmıştır. Dentritler, diğer nöronlardan gelen elektriksel sinyalleri alıp bunları soma hücresine ileten anahtar rolü üstlenirler. Akson ise soma hücresinden gelen elektriksel sinyalleri, akson uçları adı verilen yapılar aracılığıyla diğer hücrelere iletmekten sorumludur.

Bu şekilde, biyolojik nöronlar kompleks bir yapıya sahiptir ve bilgiyi vücudun farklı bölgeleri arasında iletmek için birbirleriyle etkileşim halindedirler. Bu etkileşim, insan vücudunun sinir sisteminin temel işlevini oluşturur (Karaboğa ve Uzun, 2017).



Şekil 16. Biyolojik Nöron Hücresi

Kaynak: Erkamaz H (2014) Elektrokulogram (EOG) Sinyalinin İncelenmesi ve Yapay Zekâ Teknikleri İle Modellenmesi. Doktora Tezi, Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Zonguldak, 126 s.

3.7. Derin Öğrenme

Derin öğrenme, makine öğrenmesinin bir alt kategorisidir. Bu yöntem, insan beyni ile etkileşimde bulunan sinir hücrelerine benzer bir yapı kullanılarak tasarlanmıştır. Derin sinir ağlarını içeren bu yöntem, büyük miktarda etiketlenmiş veriden özellikler tespit edebilen ve sınıflandırılabilen sistemler oluşturmak amacıyla kullanılmaktadır (Chan vd., 2015).

Derin öğrenme, temelde çok katmanlı yapay sinir ağlarını içermektedir. Bu ağlarda, birden fazla nöronun birleşimiyle katmanlar oluşmaktadır. Oluşturulan katmanlar arka arkaya sıralandığında derin sinir ağı adını alır. Bu ağdaki katman sayısı, derinliğin bir göstergesi olarak kabul edilir. Katman sayısının artması, ağın derinleştiğini ifade ederken, azalması ağın derin olmadığını ya da derinliğinin azaldığını gösterir. Derin sinir ağları, klasik yapay sinir ağlarından farklı olarak yüzlerce katmandan oluşabilir. Bu özellikleriyle, klasik yapay sinir ağlarından ayıran derin sinir ağları, kritik öznitelik çıkarımı ve sınıflandırma adımlarını tamamen otomatikleştirerek problemlerin çözümünü kolaylaştırır.

Derin öğrenme, 2012 yılına kadar pek çok araştırmacı tarafından tercih edilmeyen bir alan olarak kalmıştır. Modellerin çalıştırılması için donanım

eksiklikleri, eğitilebilecek veri setlerinin yetersiz olması ve gelişmemiş algoritmalar gibi çeşitli nedenler bu durumu etkilemiştir. Ancak, ilerleyen yıllarda dijitalleşme ve internetin yaygınlaşmasıyla birlikte büyük veri setlerinin toplanması ve dağıtılması daha kolay hale gelmiştir. Donanım eksiklikleri, yüksek hesaplama gücüne sahip grafik işlem üniteleri ile aşılmış, böylece çok büyük miktardaki verilerin daha hızlı bir şekilde eğitimi mümkün olmuştur. Ayrıca, daha uygun aktivasyon fonksiyonları, başlangıç ağırlıklarının daha iyi bir şekilde başlatılması ve daha etkili iyileştirme yöntemleri gibi faktörlerle birlikte, çok katmanlı modellerin oluşturulması da mümkün hale gelmiştir. Bu gelişmeler, derin öğrenmenin popülerliğini hızla arttırmıştır (Altan ve Karasu, 2020). Derin konvolüsyonel sinir ağıları tekniği olan AlexNet'in 2012'de Krizhevsky ve diğerleri tarafından tanıtılması ve elde edilen yüksek sınıflandırma başarıları, derin öğrenmenin yükselmesine öncülük etmiştir (Krizhevsky vd. 2012).

Tablo 2. Derin öğrenme zaman tablou

Yıl	Yaklaşım
1943	Sinir Ağları
1950	Bilgisayar Mekanizması ve Zeka
1957	Algılayıcı
1960	Adaline
1969	Algılayıcılar ve XOR Problemi
1974	Geriye Yayılım Algoritması
1980	Neocognitron Ağı
1982	Hopfield Ağı
1985	Boltzmann Makinesi
1986	Çok Katmanlı Algılayıcı
1986	Kısıtlanmış Boltzmann Makinesi
1990	Tekrarlı Sinir Ağları
1990	LeNet
1997	İki-yönlü Tekrarlı Sinir Ağı
1997	Uzun Kısa Süreli Bellek
2006	Derin Fikir Ağları
2009	Derin Boltzmann Makinesi
2012	Dropout
2014	Üretici Çekişmeli Ağlar (GANs)
2017	Kapsül Ağları

Kaynak: Karakuş B (2018) Derin Öğrenme ve Büyük Veri Yaklaşımları ile Metin Analizi. Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Elazığ, 233s.


Donanım, büyük veri setleri, geliştirilen algoritmalar ve AlexNet'in elde ettiği başarı sayesinde, derin öğrenme son yıllarda tekrar popüler bir teknik haline gelmiştir. Günümüzde, endüstri, tıp, görüntü işleme, bilgisayarlı görü, sınıflandırma, nesne tespiti, ses işleme ve tanıma, çeviri, gelecek tahmini ve finans gibi pek çok alanda derin öğrenme teknikleri yaygın bir şekilde kullanılmaktadır (Doğan ve Türkoğlu, 2019).

3.8. Evrişimli Sinir Ağları

ESA, birden fazla gizli katmanın kullanıldığı bir yapay sinir ağı modeli olarak ifade edilmektedir. Bu modelde, giriş verisi bir nöron tarafından alınmakta ve ardından katmanlarda belirli fonksiyonlar uygulanarak çıkış verisine ulaşılmaktadır (Indolia vd., 2018).

Genel olarak ESA'nın matematiksel formülü $\phi(\mathbf{x}, \mathbf{w}) = \mathbf{y}$ şeklindedir. Bu bağlamda, $\mathbf{x}$ vektörel giriş verisini, $\mathbf{w}$ ise çıkış vektörünü temsil etmektedir. Ağırlık vektörü $\mathbf{w}$ ise bitişik katmanlardaki nöronlar arasındaki bağlantı gücünü simgeler. Bu ağırlık vektörü, sınıflandırma işlemi için kullanılır. Ağırlık vektörü aracılığıyla elde edilen bağlamsal bilgi sayesinde, ESA sınıflandırma problemlerinde etkili bir şekilde tercih edilmektedir (Han vd., 2018).

Görüntü sınıflandırma problemlerinde yaygın olarak tercih edilen ESA'lar, yüksek bir başarı gösterme eğilimindedir. Şekil 17'de, Yan LeCun tarafından geliştirilen mimari gösterilmektedir. 1998 yılında evrişim ve tam bağlantılı katmanlar içeren yedi katmanlı mimari, ESA'nın ilk başarılı tasarımı ve uygulaması olarak kabul edilmektedir (LeCun vd., 1999).



Şekil 17. Evrişimli sinir ağına ait temel yapı taşları

Kaynak: LeNet. *Dive into Deep Learning*. 9 Mart 2024 tarihinde https://tr.d2l.ai/chapter_convolutional-neural-networks/lenet.html adresinden edinilmiştir

Bir ESA mimarisi, girdi, çıktı ve bir dizi ara katmandan oluşur. ESA'daki katmanlar, standart YSA' dan farklı olarak üç boyutta düzenlenir: genişlik, yükseklik ve derinlik. Genişlik ve yükseklik terimleri, görüntünün mekânsal boyutsallığını ifade ederken, derinlik terimi, ağ içindeki toplam katman sayısına değil, girdi hacminin üçüncü boyutuna karşılık gelir. Görüntülerde genellikle kırmızı, mavi ve yeşil (Red Green Blue - RGB) olmak üzere üç kanal bulunmaktadır. Her görüntü normalde iki boyutta olmasına rağmen, renk kanallarının eklenmesiyle üçüncü boyut oluşur.

Standart YSA' ların her katmanındaki nöronlar, önceki katmandaki tüm nöronlarla bağlantılıdır. ESA'da ise bir katmandaki nöronlar, sadece ondan önceki katmandaki nöronların küçük bir kısmı ile bağlantılıdır (O'Shea ve Nash, 2015).

ESA' da bulunan nöronların tamamının bağlantılı olmaması, oluşan parametre sayısının standart YSA' ya kıyasla önemli ölçüde az olmasını sağlar. ESA' lar, öznetelik çıkarımı ve sınıflandırma olmak üzere iki temel bileşenden oluşur. Öznetelik çıkarımı bölümünde, ağ, görüntü pikselleri üzerinde evrişim ve havuzlama işlemleri uygulayarak öznetelikleri belirler; çıkarılan öznetelikler bir vektör halini alır. Sınıflandırma kısmında ise tam bağlantılı katman, özneteliklere dayanarak girdideki olasılık tahminlerini üretir. Öznetelik çıkarımı ve sınıflandırma işlemleri için, araştırmacılar tarafından sıfırdan bir model tasarlanabilir veya önceden eğitilmiş ESA mimarileri ImageNet (Russakovsky vd., 2015) veri seti üzerinde çeşitli modifikasyonlarla kullanılabilir.

3.8.1. Evrişimli Sinir Ağlarını Oluşturan Katmanlar

ESA mimarileri genellikle şu sırayla düzenlenmiştir: giriş katmanı, evrişim katmanı, düzleştirilmiş ana birim katmanı, havuzlama katmanı, tam bağlantılı katman, seyreltme katmanı ve sınıflandırma katmanı. Bu katmanların sayıları, modeli tasarlayan kişi tarafından belirlenir. Günümüzde literatürde, farklı katman sayılarına sahip ve dolayısıyla farklı parametre sayılarına sahip birçok farklı ESA mimarisi bulunmaktadır (Chollet, 2017; Simonyan ve Zisserman, 2014; Szegedy vd., 2016; Tan ve Le, 2019).


3.8.1.1. Giriş Katmanı

Giriş katmanı, bir ESA'nın ilk katmanıdır ve kullanılan veri setindeki verilerin ağa aktarıldığı katman olarak tanımlanır. Bu katmanda ağa aktarılan verilerin boyutu, oluşturulan modelin performansı açısından kritiktir. Giriş verisinin büyük bir boyuta sahip olması, kullanılan bilgisayarın bellek ihtiyacını artırabilir ve her bir veri için eğitim ve test zaman maliyetlerini yükseltebilir. Ancak, bu durum model başarısını artırabilir. Diğer yandan, veri seti boyutunun küçük seçilmesi bellek ihtiyacını azaltabilir ve modelin eğitim ve test zaman maliyetlerini düşürebilir, ancak bu durumda modelin derinliği ve performansı da düşebilir. Bu nedenle, oluşturulacak modelin performansı, derinliği ve eğitim-test zaman maliyetleri için uygun bir giriş veri boyutunun seçilmesi gerekmektedir (Özkan ve Ülker, 2017).

3.8.1.2. Evrişim Katmanı

Evrişim katmanı, adından da anlaşılacağı gibi ESA'ların en temel katmanıdır. Bu katmanda, giriş görüntüleri evrişim işlemine tabi tutularak görüntülerdeki özelliklerin çıkarılması sağlanır. Evrişim işleminde, görüntüdeki özellikleri elde edebilmek için bir dizi filtre kullanılır. Bu filtrelerin boyutları, giriş görüntüsü boyutlarından daha küçüktür. Genellikle 3×3 , 5×5 veya 7×7 gibi boyutlu filtreler tercih edilir. Filtreler, giriş görüntüsü üzerinde kaydırılarak görüntü ile filtre arasındaki noktasal çarpımlar her uzamsal konumda hesaplanarak evrişim işlemi gerçekleştirilir (Altan ve Karasu, 2020; Sezer ve Altan, 2021). Filtreler, kendinden önceki katmandan

gelen görüntülere evrişim işleminin uygulanmasıyla çıkış verilerini oluşturur. Bu çıkış verileri, giriş görüntülerinin özellik haritalarını temsil eder. Yani evrişim işleminde, genellikle 3×3 veya 5×5 boyutlu filtreler kullanılarak, 3 boyutlu giriş görüntüsü üzerinde her noktadan 3 boyutlu (filtre yüksekliği, filtre genişliği, giriş derinliği) parçalar çıkarılır (Shanthi vd. 2020). Daha sonra, bu 3 boyutlu parçalar bir vektör haline dönüştürülür. Tüm bu vektörler, 2 boyutlu uzay koordinatlarında yan yana getirilerek (yükseklik, genişlik, çıkış derinliği) şeklinde 3 boyutlu çıktı özellik haritası oluşturulur. Şekil 18’de, bir ESA’nın birinci evrişim katmanının sonucunda oluşan özellik haritası gösterilmiştir.



Şekil 18. Evrişim katmanlarının özelleşmiş filtreleri aracılığıyla görsel veriden özgün özellik haritası

Kaynak: Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25

Evrişim işleminde özellik haritalarının boyutları üzerinde etkili olan iki önemli parametre, adım aralığı ve kenar etkisi parametreleri dir. Adım aralığı parametresi, kullanılan filtrenin görüntü üzerinde kaç adım ilerleyeceğini belirler. Yapılan çalışmalarda, genellikle kullanılan filtreler görüntü üzerinde 1 adım kaydırılacak şekilde ayarlanmıştır (Albawi vd., 2018; Xiao vd., 2021). Adım aralığı değeri arttıkça elde edilen çıkış verisinin boyutu küçülmektedir.

Örneğin, 6×6 boyutunda bir girdi görüntüsüne, dolgu değeri 1 olan 3×3 boyutunda bir filtre uygulandığında elde edilen özellik haritası 6×6 boyutundadır.

Şekil 19’da 6×6 boyutundaki bir girdi görüntüsüne uygulanan padding işlemi gösterilmektedir.


0	0	0	0	0	0	0
0						0
0						0
0						0
0						0
0						0
0	0	0	0	0	0	0

Şekil 19. 6×6 boyutunda giriş görüntüsüne uygulanan padding işlemi.

ESA’ larında bir evrişim katmanındaki toplam parametre sayısı (TPS), Denklem 3.4’te ifade edildiği gibi, görüntünün yüksekliği (GY), görüntünün genişliği (GG), ve görüntünün derinliği (GD) kavramlarına bağlı olarak hesaplanmaktadır (Shanthi vd., 2020).

3.8.1.3. Aktivasyon Katmanı


Evrişim katmanlarını takiben gelen aktivasyon katmanları, sinir ağlarına doğrusal olmayan özellikler kazandırmak amacıyla kullanılmaktadır (Pauly vd., 2017). Bu durum, doğrusal olmayan ifadelerin öğrenilmesini hedeflemektedir. Bu amaçla çeşitli aktivasyon fonksiyonları kullanılmaktadır; bunlar arasında Düzleştirilmiş Doğrusal Birim (Rectified Linear Unit-ReLU), sigmoid ve hiperbolik tanjant fonksiyonları bulunmaktadır. ReLU’nun, sigmoid ve hiperbolik tanjant fonksiyonlarına kıyasla daha düşük hesaplama yüküne sahip olması, özellikle çok katmanlı ağlarda tercih edilmesini sağlamaktadır (Xiao vd., 2021).



Şekil 20. Yapay Nöronda girdi, ağırlıklar, net fonksiyonu, aktivasyon fonksiyonu ve çıktı

2010 yılında ortaya çıkan ReLu aktivasyon fonksiyonu, matematiksel olarak şu şekilde ifade edilmektedir: $\sigma(x) = \max(0, x)$

Burada x , ReLu aktivasyon fonksiyonuna verilen giriş sinyalinin sayısal değerini temsil etmektedir. ReLu aktivasyon fonksiyonu, evrişim katmanından gelen özellik haritalarındaki negatif değerleri sıfıra çevirerek doğrusal yapının doğrusal olmayan bir yapıya dönüşmesine katkıda bulunmaktadır (Nair ve Hinton, 2010). Şekil 21’de ReLu katmanının çıkış verisi üzerindeki etkisi, bir grafik aracılığıyla gösterilmiştir. Grafik incelendiğinde, ReLu aktivasyon fonksiyonunun negatif değerleri sıfır almasıyla birlikte ağıdaki hesaplama yükünün azaldığı ve ağı daha hızlı çalıştığı gözlemlenmektedir. ReLu fonksiyonu kullanılarak ağı daha hızlı öğrenmesi sağlanmaktadır.



Şekil 21. ReLu katmanının çıkış verisi üzerinde gösterdiği etki

Kaynak: Pauly L, Hogg D, Fuentes R and Peel H (2017) Deeper Networks for Pavement Crack Detection. Proceedings of the 34th International Symposium in Automation and Robotics in Construction, 2017: 479-485

3.8.1.4. Ortaklama Katmanı

ESA mimarilerinde, genellikle aktivasyon katmanından sonra gelen ortaklama katmanı, kendisinden sonraki evrişim katmanı için giriş boyutunun genişlik ve yükseklik değerlerini azaltırken derinlik değerini değiştirmemektedir. Bu katmandaki işlemler, boyuttaki azalmada bilgi kaybına neden olabilir; ancak bir sonraki katman için hesaplama yükünü azaltarak sistemin ezberlemesini önler. Maksimum ortaklama ve ortalama ortaklama olmak üzere iki tür ortaklama katmanı bulunmaktadır. Ortaklama katmanında belirli filtreler, görüntü üzerinde gezdirilerek piksel değerlerinin maksimum değerini almak için maksimum ortaklama işlemi gerçekleştirilebilir. Piksel değerlerinin ortalamasını almak içinse ortalama ortaklama işlemi kullanılabilir. Nesnelerin sınıflandırılması görevinde, Scherer ve arkadaşları maksimum ortaklama işleminin ortalama ortaklama işlemine göre daha etkili sonuçlar ortaya koyduğunu göstermişlerdir (Scherer vd., 2010). Şekil 22'de görüldüğü üzere, 4×4 boyutundaki bir girdi görüntüsüne 2×2 filtre boyutunda maksimum ortaklama

işlemi uygulandığında her filtrenin maksimum değeri alınır, ardından 2×2 boyutunda yeni bir çıktı elde edilir. Ortalama ortaklama işleminde ise her filtrenin ortalama değeri alınır ve ardından 2×2 boyutunda yeni bir çıktı elde edilir. Bu işlemler, ortaklama katmanının giriş boyutunu azaltarak bilgi kaybına neden olur, ancak hesaplama yükünü düşürerek sistemin genel performansını artırır.

Maksimum Havuzlama

29	15	28	184
0	100	70	38
12	12	7	2
12	12	45	6



Havuzlama
Boyutu
(2×2)

100	184
12	45

Ortalama Havuzlama

29	15	28	184
0	100	70	38
12	12	7	2
12	12	45	6



Havuzlama
Boyutu
(2×2)


36	80
12	15

Şekil 22. Maksimum ve Ortalama katmanlarının şematik gösterimi

3.8.1.5. Tam Bağlantılı Katman

Evrişim katmanları, aktivasyon katmanları ve ardından gelen tam bağlantılı katmanlar, bir katmanda bulunan nöronları bir sonraki katmandaki tüm nöronlara bağlayarak çalışır. Şekil 23'te tam bağlantılı katmanın sembolik temsili görülmektedir. Burada, iki gizli katmandaki tüm nöronlar birbirine bağlanır ve bu, tam bağlantılı katmanın oluşumunu gösterir. $\square$ ve ϕ ifadeleri sırasıyla birinci ve ikinci gizli

katmandaki nöronları temsil etmektedir. Ayrıca, gizli katman sayıları model tasarımcısı tarafından talebe bağlı olarak arttırılabilir. Genellikle standart sinir ağlarında, tam bağlantılı katmanlar YSA 'ların sonlarına doğru yerleştirilir. Bu katmana kadar olan katmanlarda özellik çıkarma işlemleri gerçekleşirken, tam bağlantılı katmanlarda sınıflandırma işlemleri başlar. Tam bağlantılı katmanlar, evrişim katmanlarında öğrenilemeyen bazı önemli özellikleri öğrenme yeteneğine sahiptir ve çıkışta istenilen sınıf sayısına dönüştürme görevini üstlenir (Liu vd., 2018).



Şekil 23. Tam bağlı katman


3.8.1.6. Seyreltme Katmanı

ESA' ların eğitim aşamasında, nöronlar öğrendikleri bilgileri sık sık ezberleyebilir. Ancak bu ezberleme durumu, modelin gerçek dünya verilerine daha iyi uyarlanmasını zorlaştırabilir. Bu nedenle, seyreltme katmanı geliştirilmiştir. Seyreltme katmanı, eğitim sırasında belirli nöronları rastgele bir şekilde devre dışı bırakarak ağın ezberleme eğilimini azaltmaya çalışır (Srivastava vd., 2014). Rastgele nöron devre dışı bırakma işlemi, ağın hesaplama yükünü azaltmanın yanı sıra genel model

performansını artırabilir. Şekil 23'te, bir ESA modelinde çıkış verisi $\square$, gizli katman 1, gizli katman 2 ve gizli katman 3 için sırasıyla $\square$, ϕ , $\square$ ifadeleri ile temsil edilen bazı nöronların rastgele devre dışı bırakıldığı seyreltme işlemi gösterilmektedir.

3.8.1.7. Sınıflandırma Katmanı

ESA katmanlarının en sonunda bulunan sınıflandırma katmanında, önceki katmanlardan elde edilen özellikler kullanılarak sınıflandırma işlemi gerçekleştirilir. Bu aşamada çıkış değeri, istenilen durum sayısı kadar olacaktır. Örneğin, 5 farklı durumu sınıflandırmak için sınıflandırma katmanının çıkış değeri 5 olacaktır. Sınıflandırma katmanında genellikle softmax aktivasyon fonksiyonu tercih edilir. Bu aktivasyon fonksiyonu, sınıflandırılacak veriler için 0 ile 1 arasında olasılık değerleri üretir. Elde edilen olasılık değerlerinden en yüksek olan, ağın tahmin ettiği sınıf olarak kabul edilir. Softmax aktivasyon fonksiyonu, çoklu sınıflandırma problemlerinde diğer aktivasyon fonksiyonlarına göre daha iyi performans gösterdiği için sınıflandırma katmanında tercih edilen bir fonksiyondur. Bu fonksiyon, girdi değerinin belirli bir sınıfa ait olma olasılığını 0 ile 1 arasında değerler üreterek çıkış değerlerinin sınıflara ait olma olasılığının dağılımını sağlar (Kadam vd., 2019).







Şekil 24. Seyreltme işlemi (a) orijinal ESA (b) seyreltme işlemi uygulanan ESA

Kaynak: Srivastava N, Hinton G, Krizhevsky A, Sutskever I and Salakhutdinov R (2014) Dropout: A Simple Way to Prevent Neural Networks from Overfitting. The journal of machine learning research, 15(1): 1929-1958.

3.9. Hiper-Parametreler

Seçim modeli tasarlayan kişiye bırakılmış olan hiper parametreler, modelin performansını belirleyen kritik unsurları içerir. Bu parametreler, kullanılacak veri setine göre ayarlanmalıdır. Evrişim katmanlarının sayısı, uygulanacak filtrelerin sayısı ve boyutu, aktivasyon fonksiyonları, mini batch boyutu, öğrenme oranı, eğitim turu sayısı (epok), momentum katsayısı, L2 düzenlileştirme metodu ve kayıp fonksiyonunu minimize etmek için kullanılan optimizasyon algoritmaları gibi faktörler, modelin başarısını etkileyen önemli değişkenlerdir.

Ancak, bu hiper parametrelerin hangi değerlerinin daha iyi sonuç vereceği kesin olarak belirlenmemiştir (Cao vd., 2019). Bu durum, hiper parametre ayarlamasının genellikle deneme-yanılma yöntemleriyle gerçekleştirildiği anlamına gelir. Yani, bir hiper parametre setinin performansı önceden tahmin edilemez ve denemeler yoluyla belirlenir. Bu nedenle, model tasarımında uzmanlığa dayalı bir yaklaşım ve dikkatli bir hiper parametre ayarlama süreci gereklidir.

Aktivasyon Fonksiyonları	Fonksiyon Grafikleri	Matematiksel İfadeleri
ReLU	$f(u) = \max(0, u)$ 	$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x > 0 \end{cases}$
Sigmoid		$f(x) = \frac{1}{1 + e^{-x}}$
Softmax		$f(x) = \frac{e^{x_i}}{\sum_{j=1}^K e^{x_j}}$
Tanh		$\tanh(x) = \frac{2}{1 + e^{-2x}} - 1$

Şekil 25. Aktivasyon Fonksiyonları

3.9.1. Aktivasyon Fonksiyonları

ESA'larında kritik bir rol oynayan aktivasyon fonksiyonları, oluşturulan modelin daha üst düzey performans sergilemesi için bir katmandan gelen girdilere karşılık gelecek çıktıları belirleyen fonksiyonlar olarak tanımlanmaktadır. Aktivasyon fonksiyonları, özellikle daha derin sinir ağlarında, yüksek dereceli polinomları öğrenmeye yardımcı olan doğrusal olmayan çıkış sinyallerine dönüştürme ihtiyacını

karşılar. Bu sayede, aktivasyon fonksiyonları, çok katmanlı yapay sinir ağlarında doğrusal olmayan dönüşüm işlemlerini gerçekleştirir.

Doğrusal olmayan aktivasyon fonksiyonlarının özelliklerinden biri, türevlenebilir olmalarıdır. Bu özellik, aktivasyon fonksiyonlarının, derin sinir ağlarının geriye yayılımı (backpropagation) sırasında etkin bir şekilde çalışmalarını sağlar (Nwankpa vd., 2018). Yani, aktivasyon fonksiyonları, modelin eğitim sürecinde gradient tabanlı optimizasyon algoritmalarının kullanılabilmesini mümkün kılar, bu da sinir ağı parametrelerinin güncellenmesini ve daha iyi öğrenme sağlanmasını destekler.

Aktivasyon fonksiyonlarının bir Yapay Sinir Ağı'nda kullanılmadığını düşündüğümüzde, modelin çıkışındaki sinyalin yalnızca tek dereceli bir polinom, yani doğrusal bir fonksiyon olacağı görülecektir. Bu durumda, Yapay Sinir Ağı sınırlı öğrenme gücüne sahip olacaktır. Bu noktada, önemli olan düşünce, oluşturulan sinir ağına doğrusal olmayan bilgilerin, örneğin görüntü, yazı, video, ses gibi, verilerek ağı daha karmaşık ilişkileri öğrenmesini sağlamaktır. Aktivasyon fonksiyonları bu bağlamda, doğrusal olmayan durumlar için modelin öğrenme sürecini zenginleştirebilmektedir.

Bu amaçla kullanılan aktivasyon fonksiyonları arasında ReLu, softmax, sigmoid, tanh, prelu ve swish gibi yaygın örnekleri sıralayabiliriz. Bu fonksiyonlar, doğrusal olmayan ilişkileri modellemek ve ağı esnekliğini artırmak için tercih edilmektedir. Özellikle, ReLu aktivasyon fonksiyonu, hesaplama yükünün düşük olması nedeniyle sıklıkla tercih edilen bir seçenektir (Pauly vd., 2017).

ReLu aktivasyon fonksiyonu, Şekil 25' deki denkleme ve grafiğe göre incelendiğinde, x değeri fonksiyonun aldığı giriş değerini ifade eder. Fonksiyonun aldığı değer negatifse, bu değer sıfır ile değiştirilir; pozitifse aynı kalır. Bu özellik, negatif değerlerin sıfır değerini alması ve sigmoid, tanh gibi diğer aktivasyon fonksiyonlarına kıyasla ağıdaki nöronların neredeyse tamamını aynı şekilde aktive etmemesi anlamına gelir. Bu durum, ağıdaki bazı nöronların aktif olmasını sağlayarak verimli bir hesaplama yükü sağlar. ReLu aktivasyon fonksiyonunun hesaplama yükünün düşük olduğu ve ağı daha hızlı öğrendiği gözlemlenir.

Sigmoid aktivasyon fonksiyonu için Şekil 25'e bakıldığında, fonksiyonun yüksek değer aldığındaki yaklaşık bir, düşük değer aldığındaki ise yaklaşık sıfır değerini aldığı görülmektedir. Sigmoid aktivasyon fonksiyonu, sıfır ile bir arasında değerler döndürür ve eksponansiyel ifade içerdiği için yavaş bir aktivasyon fonksiyonu olarak nitelendirilir.

Softmax aktivasyon fonksiyonu için Şekil 25 incelendiğinde, bu fonksiyonun sıfır ile bir arasında değerler döndürdüğü görülmektedir. Softmax aktivasyon fonksiyonu genellikle çoklu sınıflandırma problemlerinde çıkış katmanında kullanılır ve sınıflandırıcı olarak kullanıldığında olumlu sonuçlar verir (Gao vd., 2021). Bu fonksiyon, çıkış katmanındaki sınıflar arasında olasılık dağılımını normalize etme yeteneği ile bilinir.

Şekil 25' deki tanh aktivasyon fonksiyonu incelendiğinde, sigmoid aktivasyon fonksiyonu ile benzerlikler görülmektedir. Ancak, tanh aktivasyon fonksiyonunun belirgin bir farkı, değerleri -1 ile 1 arasında döndürmesidir. Eğer tanh aktivasyon fonksiyonuna gelen değer düşükse, fonksiyon -1'e daha yakın bir değer alır; eğer değer yüksekse, 1'e daha yakın bir değer alır. Bu özellik, tanh aktivasyon fonksiyonunun değer aralığını genişlemesinden kaynaklanmaktadır.

Ayrıca, tanh aktivasyon fonksiyonunun türevi sigmoid aktivasyon fonksiyonuna göre daha dik bir eğriye sahiptir. Bu durum, tanh aktivasyon fonksiyonunun daha hızlı öğrenme ve sınıflandırma işlemleri için daha geniş bir aralığa sahip olmasını sağlar. Dolayısıyla, sigmoid aktivasyon fonksiyonuna kıyasla tanh aktivasyon fonksiyonu, daha avantajlı bir seçenek olabilir. Bu özellikleri nedeniyle tanh aktivasyon fonksiyonu, özellikle gradient lerin daha hızlı düşmesine izin vererek derin sinir ağlarında daha etkili bir şekilde kullanılabilir.

3.9.2. Mini-batch Boyutu

Derin öğrenme algoritmalarında, modelin öğrenme aşamasında her bir iterasyonda katmanlardaki nöron değerleri geriye yayılma işlemi ile güncellenir. Bu güncelleme işleminin süresi, kullanılan veri setinin boyutuna ve türüne bağlı olarak değişir. Özellikle büyük veri setlerinde, bu işlem küçük bellek alanına sahip bilgisayarlarda önemli bir zaman alabilir. Bu sorunu çözmek için geliştirilen mini

batch tekniđi, veri setini paralara ayırarak eđitimi gerekleřtirir, bylece tm veri setini aynı anda iřlemek yerine daha hızlı bir đrenme sreci sađlar. Mini batch hiper parametresinin deđeri, model tasarımcısı tarafından belirlenir.

Literatrdeki alıřmalar (Mishkin vd., 2017) incelendiđinde, mini batch deđerinin nemli olduđu ve bu deđerin modelin performansını etkilediđi grlmektedir. zellikle dřk belleđe sahip bilgisayarlarda olduka faydalı olan mini batch, modelin dođruluđunu ve performansını artırabilir. Arařtırmalar, mini batch deđerinin 512, 1024, 2048 gibi byk deđerler ieren modellerin hesaplama iřleminin uzun srdđn, modelin dođruluđunun ve performansının dřk olduđunu; ancak mini batch deđeri 32, 64, 128, 256 gibi kk deđerler ieren modellerin en iyi performansı sunduđunu gstermektedir. Bu nedenle, mini batch hiper parametresinin dikkatlice seilmesi, modelin etkinliđi aısından kritik bir neme sahiptir.


Mini batch deđeri, modelin eđitim ařamasında kullanılan veri setinde bulunan tm verilerin sayısı ile 1 arasında bir deđer alır. Eđer mini batch deđeri 1 olarak seilirse, model her dngde yalnızca bir veri zerinde iřlem gerekleřtirir. Bu durumda, model grlty đrenmede etkili olabilir, ancak optimum deđerlere ulařmada zorluk yařayabilir. te yandan, mini batch deđeri eđitim verisindeki tm veri sayısı olarak seilirse, model her dngde tm veri seti zerinde alıřır. Bu durum, đrenme sresini artırabilir, ancak grlt đrenimini azaltabilir.

Mini batch deđerinin seiminde, modelin sorunsuz eđitimi iin kullanılan grafik iřlem nitesi belleđine uygun deđerler seilmelidir. zellikle 2 ve katları olan deđerlerin seilmesi, daha bařarılı sonulara yol aabilir. Bu nedenle, mini batch hiper parametresinin dođru bir řekilde seilmesi, derin đrenme algoritmalarının bařarı dzeyini nemli lde etkileyebilir.

3.9.3. đrenme Oranı

Derin đrenme algoritmalarında, modellerin ađrılıklarının gncellenmesi geriye yayılım iřlemi ile gerekleřtirilir. Geriye yayılım iřlemi, ađrılıkların geriye dođru trev alınarak hesaplanan fark deđerinin đrenme oranı ile arpılmasının ardından, bu sonucun mevcut ađrılık deđerinden ıkarılmasıyla elde edilen yeni ađrılık deđerlerini ifade eder. đrenme oranı, ađrılıkların gncellenme hızını belirleyen bir

oran olarak tanımlanır. Şekil 26'da, öğrenme oranının sabit bir değer alabileceği gibi, artan veya azalan bir değer de alabileceği durumları gösterilmektedir. Şekil 26 incelendiğinde, öğrenme oranının büyük seçilmesi durumunda modelin veri setindeki maksimum ve minimum noktalara hızla yaklaşma eğiliminde olduğu, ancak bu durumun z değerlerinin hedefe ulaşmasını zorlaştırabileceği görülmektedir. Diğer yandan, öğrenme oranının çok küçük seçilmesi durumunda, modelin değere yakınsamasının uzun sürdüğü ve dolayısıyla modelin daha uzun sürede öğrenim sağladığı gözlemlenir (Hoffer vd., 2017). Bu durumlar, öğrenme oranının modelin başarı düzeyini etkileyen kritik bir faktör olduğunu vurgular.



Şekil 26. Öğrenme oranı seçilmesi (a) Büyük öğrenme oranı seçimi (b) Küçük öğrenme oranı seçimi.

3.9.4. Eğitim Tur (Epok) Sayısı

Derin öğrenme algoritmalarında, modelin eğitimi tüm veri seti ile aynı anda gerçekleştirilmez. Bunun yerine, önceden belirlenmiş bir mini-batch değeri kadar veri eğitime dahil edilir. Mini-batch değeri kadar veri eğitimi tamamlandıktan sonra, modelin doğrulanması işlemi gerçekleştirilir ve bu doğrulama değerine göre geriye yayılım yöntemi ile modelin ağırlıkları güncellenir. Ardından, mini-batch değeri kadar yeni veri ile benzer işlemler tekrarlanır ve ağırlıklar güncellenir. Bu adımlar, mini-batch değeri kadar yeni veri kümesi üzerinde tekrarlanarak, model için en uygun ağırlık değerleri elde edilmeye çalışılır. Bu işlemler içerisindeki her bir eğitim adımına "eğitim turu" veya "epok" denir.

Modelin başarımı, her epok başına ağırlıkların güncellenmesi ile yakınsama arttığı için epok sayısı arttıkça performans da artar. Ancak, belirli bir tur sayısından sonra, modelin başarımındaki değişim önemli ölçüde azalmaktadır. Modelin başarımındaki bu değişimin önemli ölçüde yavaşlaması, belirli bir öğrenme noktasına ulaşıldığını ve eğitimin devamının artık anlamlı olmadığını gösterir. Bu nedenle, belirli bir epok sayısına ulaşıldığında, modelin başarımındaki değişimin yeterince azaldığı düşünülerek eğitim sonlandırılabilir.

3.9.5. Momentum Katsayısı

Stokastik gradyan iniş (SGD) gibi optimizasyon algoritmaları, oluşturulan modelin eğitimi sırasında optimum nokta ararken genellikle fazla salınım neden olabilir. SGD algoritması, adından da anlaşılacağı üzere tüm eğimlere odaklanmak yerine, bir kısmını rastgele seçerek modelin ağırlıklarını günceller. Bu durumda, algoritma modelin eğitim sürecinde aşırı salınım yapabilir. Momentum katsayısı, bu tür algoritmaların neden olduğu salınımları azaltmak ve eğitimi hızlandırmak için kullanılan bir katsayıdır.

Bu yöntemde, mevcut eğimlerin tamamı yerine momentum katsayısıyla ağırlıklı eğimler kullanılır ve bu sayede salınımların azaltılması sağlanır. Momentum katsayısı, geçmiş güncellemelerin etkisini koruyarak, ağırlık güncellemelerini daha tutarlı ve pürüzsüz hale getirir. Bu özellik, modelin daha hızlı ve daha etkili bir şekilde eğitilmesine katkıda bulunur (Zeiler, 2012).

Yapılan literatür incelemeleri, genellikle momentum katsayısının 0.9 olarak tercih edildiğini göstermektedir (Yan vd., 2018). Bu değer, momentum katsayısının optimal bir performans sergilemesi açısından yaygın olarak tercih edilen bir ayar olarak öne çıkmaktadır. Momentum katsayısının 0.9 olarak belirlenmesi, modelin eğitiminde salınımları azaltma ve daha hızlı bir öğrenme süreci sağlama amacını taşır. Bu nedenle, literatürdeki birçok çalışma, momentum katsayısını bu değerde kullanarak derin öğrenme modellerinin başarımını artırmayı hedeflemektedir.

3.9.6. L2 Düzenleştirme

Derin öğrenme algoritmalarında geliştirilen modellerin eğitimi sırasında, ağırlıkların güncellenmesine bağlı olarak genellikle eğitim kayıp değerleri ve doğrulama kayıp değerleri her epokta azalma eğilimindedir. Ancak, bazı durumlarda eğitim kayıp değerleri sürekli azalırken, doğrulama kayıp değerleri minimuma ulaştıktan sonra kademeli olarak artma eğiliminde olabilir. Bu durum, modelin aşırı uyum durumuna girdiğini gösteren belirgin bir işarettir (Ying, 2019).

Düzenleştirme işlemi, modelin aşırı uyum durumuna düşmesini önlemek için kullanılan bir tekniktir ve bu işlem, modelin ağırlıklarını kullanarak kayıp fonksiyon değerini cezalandırma temeline dayanır. L2 düzenleştirme, standart olarak kullanılan kayıp fonksiyon değerine ağırlık vektörünün normunu ekleyen bir tekniktir.

3.9.7. Optimizasyon Yöntemleri

Derin öğrenme algoritmalarında, optimizasyon yöntemleri modelin eğitim aşamasında hata oranını minimize etmek amacıyla kullanılır. Hata oranının minimize edilmesi, oluşturulan modelin doğru tahmin oranının yüksek olması ve dolayısıyla modelin başarısının artması anlamına gelir. Derin öğrenme algoritmalarında oluşturulan modellerin öğrenme süreci, temelde bir optimizasyon problemi olarak tanımlanır. Oluşturulan modelin optimum değerini bulabilmek için doğrusal olmayan problemlerin çözümünde çeşitli optimizasyon yöntemleri kullanılır. Derin öğrenmede, modellerin eğitim aşamasında hata oranlarını minimize etmek için sıkça kullanılan optimizasyon yöntemleri arasında stokastik gradyan inişi (stochastic gradient descent), adagrad, adadelta, RMSprop ve adam bulunmaktadır.

Stochastic Gradient Descent: Stokastik Gradyan İniş (SGD) algoritması, modelin eğitimi sırasında hata oranını minimize etmek için kullanılan bir optimizasyon algoritmasıdır. Bu algoritma, modelin ağırlıklarını güncellemek için tüm veri setini kullanmak yerine, rastgele seçilen mini partileri kullanarak bu partilerin gradyanlarını takip eder. SGD'de, ağırlıkları güncellemek için bir veya birkaç eğitim örneği kullanılır. Bu, tipik gradyan iniş algoritmasına kıyasla tüm gradyan terimlerini toplamak yerine yalnızca tek bir veri için gradyan terimini hesaplamayı içerir. Bu sayede SGD, ağırlıklardaki değişiklikleri daha hızlı bir şekilde gerçekleştirir.

Hesaplama maliyeti açısından tipik gradyan iniş göre daha avantajlıdır, çünkü tüm eğitim setini incelemeye gerek olmaksızın çalışabilir.

SGD optimizasyon algoritması, belirli sayıda verinin rastgele seçilmesi nedeniyle her tekrarda modelin minimuma ulaşma yolunun tipik gradyan iniş göre daha gürültülü olmasını sağlar. SGD'nin gürültülü olması ve rastgelelik içermesi, modelin minimum değere ulaşabilmesi için daha fazla eğitim turu gerektirebilir. Ancak bu duruma rağmen, SGD hesaplama maliyeti açısından tipik gradyan iniş göre daha verimlidir ve özellikle büyük veri kümeleriyle çalışmak için tercih edilen bir seçenektir (Zhang, 2019).


AdaGrad, gradyan tabanlı bir optimizasyon algoritmasıdır ve öğrenme oranını manuel olarak ayarlamaya gerek kalmadan optimize etmektedir. Bu algoritma, öğrenme oranını sık olmayan parametreler için büyük güncellemelerle, sık olan parametreler için ise daha küçük güncellemelerle uyarlamaktadır. Genellikle, AdaGrad'da öğrenme oranı varsayılan olarak 0.01 olarak ele alınır ve bu değer değiştirilmez. AdaGrad optimizasyon yönteminde, her terim pozitif olduğundan biriken toplam, eğitim sırasında devam eden bir büyüme gösterir. Bu durum, modelin öğrenme oranının küçülmesine ve sonunda çok küçük olmasıyla algoritmanın ek bilgi elde edememesine neden olabilir (Ruder, 2016).

AdaDelta, AdaGrad optimizasyon tekniğinin öğrenme oranındaki agresif düşüşü azaltmaya yönelik bir optimizasyon tekniğidir. Bu özelliği nedeniyle AdaDelta, AdaGrad optimizasyon tekniğinin bir tür genişletmesi olarak tanımlanabilir. AdaDelta, öğrenme oranındaki bu agresif düşüşü kontrol altına almak için geçmiş gradyanları biriktirmek yerine, birikmiş gradyan penceresini sabit bir "w" değeriyle sınırlar. Yani, tüm geçmiş gradyanların ortalamasını almak yerine, belirli bir pencere boyutunda geçmiş birikmiş gradyanları kullanır. Bu sayede AdaDelta, öğrenme oranını manuel olarak ayarlamaya gerek kalmadan daha etkili bir şekilde optimize edebilir (Ruder, 2016).

RMSprop, öğrenme oranındaki sabit problemleri çözmek amacıyla geliştirilmiş bir optimizasyon yöntemidir, benzer şekilde AdaGrad'de olduğu gibi. Ancak, RMSprop, dikey salınımları minimize ederek modelin öğrenme oranını artırma ve yatay yönde daha hızlı hareket etme yeteneği sağlar, böylece minimum değere daha

hızlı ulaşabilir. RMSprop optimizasyon yöntemi, gradyan karelerini hesaplamak yerine momentumlu gradyan karelerini kullanarak AdaGrad'den ayrılmaktadır. Bu özellik, RMSprop'un daha etkili bir şekilde çalışmasına ve modelin daha hızlı bir şekilde optimize edilmesine olanak tanır (Zhang, 2019; Ruder, 2016).

Kingma ve Ba tarafından tanıtılan Adam optimizasyon yöntemi, günümüzde yaygın bir şekilde kullanılan bir algoritmadır. Adam, RMSprop ve SGD'nin momentumunu birleştirerek çalışır. Öğrenme oranını ölçeklendirmek için kare gradyanları kullanarak RMSprop'a benzer bir özellik taşıırken, gradyanın yerine gradyanın hareketli ortalamasını kullanarak SGD'ye benzer bir momentum avantajı sağlar. Adam optimizasyon yöntemi, uygulaması basit, hesaplama açısından verimli, az bellek gereksinimine sahip, gradyanların çapraz yeniden ölçeklenmesinde değişmez ve büyük veri setleriyle çalışmak için uygun bir yöntem olarak bilinir. Şekil 26'da, Adam optimizasyon yönteminin diğer optimizasyon yöntemleriyle karşılaştırılması gösterilmiştir (Kingma ve Ba, 2014).



Şekil 27. MNIST veri seti kullanılarak bazı optimizasyon yöntemlerinin karşılaştırılması

Kaynak: Brownlee, J. (2017). Gentle introduction to the Adam optimization algorithm for deep learning. Deep Learning Performance. <https://machinelearningmastery.com/adam-optimization-algorithm-for-deep-learning>


Şekil 27'de MNIST veri seti üzerinde yapılan incelemelerde, AdaGrad, RMSprop, Adadelta, SGD ve Adam optimizasyon yöntemlerinin performansları karşılaştırılmıştır. Bu grafiklere göre, Adam optimizasyon yöntemi her epokta diğer optimizasyon yöntemlerine göre daha hızlı bir ilerleme kaydetmiş ve değerlere daha hızlı bir şekilde yakınsamıştır. Bu durum, Adam'ın MNIST veri seti üzerinde daha etkili bir performans sergilediğini göstermektedir.

3.10. Transfer Öğrenme (Transfer Learning)

Transfer öğrenme, derin öğrenme algoritmalarında yaygın olarak kullanılan bir yöntemdir. Bu yöntem, bir problemi çözerken elde edilen bilgilerin saklanması ve daha sonra yeni bir problemle karşılaşıldığında bu bilgilerin kullanılması esasına dayanır. Transfer öğrenme sayesinde, önceki bilgiler kullanılarak daha küçük bir veri seti üzerinde daha yüksek başarı elde eden ve daha hızlı öğrenen derin öğrenme modelleri tasarlanabilir.

Şekil 28'de transfer öğrenme tekniğinin blok diyagramı verilmiştir. Bu diyagramda, ilk satırda bir ESA mimarisinin büyük bir sınıflandırma için geniş bir veri kümesi olan ImageNet üzerinde eğitilmesi gösterilmektedir. İkinci satırda ise daha küçük bir sınıflandırma görevi için eğitilecek veri setinin, daha önce ImageNet veri seti üzerinde eğitilmiş olan ESA modelinin ağırlıklarının transfer edilerek aynı ESA modeli üzerinde eğitilmesi ve sınıflandırılması işlemi gösterilmektedir.

Transfer öğrenme, önceden eğitilmiş bir modelin ağırlıklarını kullanarak küçük bir veri kümesinin özelliklerini çıkarmak ve modelin parametrelerini hassas bir şekilde ayarlamak anlamına gelir. Bu yaklaşım, özellikle büyük ölçekli görüntü sınıflandırma görevlerinde başarılı sonuçlar elde etmek için kullanılır (Khan vd., 2019).



Şekil 28. Transfer öğrenme tekniği blok diyagramı

Modellerin sıfırdan oluşturulduğu durumlarda genellikle büyük veri setleri gerekmekte ve bu veri setlerinin oluşturulması zaman açısından oldukça maliyetlidir. Transfer öğrenme tekniği, bu zorluğun üstesinden gelmek için kullanılır. Önceden büyük bir veri kümesi üzerinde eğitilmiş olan modeller, içerdikleri ağırlıklar sayesinde zengin bir bilgi havuzu sunar. Bu bilgiler, daha küçük bir veri seti üzerinde modelin ince ayarını yapmak için kullanılabilir.

Transfer öğrenme ile, önceden eğitilmiş modellere yeni tam bağlantılı katmanlar eklenerek, model daha spesifik bir görev için uyarlanabilir. Bu sayede, daha küçük bir veri seti kullanarak modelin daha hızlı bir şekilde eğitilmesi ve daha iyi performans elde edilmesi mümkün olur. Önceden eğitilmiş modeller arasında, ImageNet veri seti üzerinde başarıyla eğitilmiş birçok model bulunmaktadır. Öne çıkan modeller arasında Görsel Geometri Grup Ağı (VGGNet), Xception, InceptionV3 ve ResNet101 gibi modeller bulunmaktadır. Bu modeller, çeşitli görevlerde transfer öğrenme uygulamalarında yaygın olarak kullanılmaktadır.


3.10.1. Görsel Grup Geometri Ağı (VGG)

Visual Geometry Group Network (VGGNet), Simonyan ve Zisserman tarafından geliştirilen bir çok katmanlı derin sinir ağıdır. Literatürde VGG-16 ve VGG-19 olmak üzere iki temel mimari şekli bulunmaktadır, ve bu mimariler arasındaki temel fark, katman derinliklerindedir. VGG-16 mimarisi, 13 evrişim katmanı ve 3 tam

bağlantılı katman olmak üzere toplamda 16 katmandan oluşurken, VGG-19 mimarisi 16 evrişim katmanı ve 3 tam bağlantılı katman içererek toplamda 19 katmandan oluşur. Şekil 29'da VGG-19 mimarisine ait bir görsel bulunmaktadır.

Mimari, 3x3 boyutundaki evrişimli katmanları kullanarak derinlik seviyesini artırır. Uzamsal çözünürlüğü korumak adına uzamsal dolgu da kullanılır. ReLU aktivasyon fonksiyonları, her evrişimli katmandan sonra sınıflandırma performansını artırır ve hesaplama süresini minimize eder. Mimari, özneteliklerin boyutunu azaltmak için beş maksimum havuzlama katmanını içerir. Son üç tam bağlantılı katman, önceki katmanlardan gelen değerlere bağlı nöronları içerir ve son katman, 1000 sınıflı ImageNet veri seti için olasılık değerlerini üreten bir softmax aktivasyon fonksiyonu ile beslenir.

VGG mimarileri, basit yapısı ile öne çıkar, ancak diğer modellerden farklı olarak 3x3 boyutundaki evrişim katmanlarını maksimum havuzlama katmanlarıyla takip etmeleriyle dikkat çeker (Simonyan ve Zisserman, 2014).



Şekil 29. VGG-19 mimarisi

Kaynak: Özçelik, Y. B., & Altan, A. (2021). Diyabetik retinopati teşhisi için fundus görüntülerinin derin öğrenme tabanlı sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (29), 156-167.

Şekil 29'da, VGGNet mimarisinin 2014 yılında düzenlenen ImageNet sınıflandırma yarışmasındaki performansı gösterilmektedir. Çizelgeye göz atıldığında, VGGNet mimarisi %7.3'lük bir test hatası ile yarışmada ikinci sırayı elde etmiştir. Yarışmayı %6.7'lik test hatası ile kazanan mimari ise GoogleNet'tir (He vd., 2016).

Ancak dikkat çekici bir şekilde, VGGNet mimarisi tek ağ mimarisi olarak, performans açısından GoogleNet mimarisini %0.9 oranında geride bırakarak %7.0'lik bir hata oranıyla en iyi performansı sergilemiştir.

Tablo 3. VggNet mimarisinin ImageNet veri kümesi sınıflandırma performansı

Metot	Top-1 doğrulama hatası(%)	Top-1 doğrulama hatası(%)	Top-5 test hatası
VGG (2 ağ)	23.7	6.8	6.8
VGG (1 ağ)	24.4	7.1	7.0
VGG (7 ağ)	24.7	7.5	7.3
GoogleNet (1 ağ)	-	7.9	7.9
GoogleNet (7 ağ)	-	6.7	6.7
Clarifai (Russakovsky vd. 2014) (Çoklu ağ)	-	-	11.7
Clarifai (Russakovsky vd. 2014) (1 ağ)	-	-	12.5

Kaynak: Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.

3.10.2. Xception

Xception, Keras üreticisi François Chollet tarafından önerilen bir mimari olup, Inception mimarilerinin bir yorumu olarak ortaya çıkmıştır. Xception mimarisinde, derinlemesine ayrılabilir evrişim işlemleri ve düzenli evrişim kullanılmaktadır. Derinlemesine ayrılabilir evrişim, önce derinlik yönünde bir evrişim ve ardından bir noktasal evrişim işlemi olarak tanımlanabilir. Xception mimarisinin önemli bir farkı, işlem sırasının Inception mimarilerinden farklı olmasıdır. Inception mimarilerinde önce kanal-yönlü uzaysal evrişim, sonra 1×1 boyutlu evrişim uygulanırken, Xception mimarisinde bu sıra tersine çevrilmiştir. Yani önce 1×1 boyutlu evrişim, ardından kanal-yönlü uzaysal evrişim işlemi gerçekleştirilmektedir. Bu özellikleri sayesinde

Xception mimarisi, ImageNet yarışmasında InceptionV3 mimarisinden daha üstün bir performans göstermiştir. Xception mimarisi, sınıflandırma problemlerinde kullanılmak üzere toplamda 36 evrişim katmanı içermektedir. Genel olarak, Xception mimarisi, artık bağlantılara sahip, derinlemesine ayrışabilir evrişim katmanlarının doğrusal olarak sıralandığı bir mimari olarak tanımlanabilir (Chollet, 2017).

3.10.3. InceptionV3

Temelde ESA algoritmasına dayanan InceptionV3, Szegedy ve diğer araştırmacılar tarafından V1 ve V2 modelleriyle birlikte önerilmiştir. InceptionV3 modeli, evrişim katmanlarına ek olarak yardımcı sınıflandırıcı, küme normalizasyonu ve tam bağlantılı katmanlar içermesi açısından diğer V1 ve V2 modellerinden farklılık gösterir (Szegedy vd., 2016). Bu özellikler, InceptionV3'ü önceki modellere kıyasla daha karmaşık ve etkili bir yapıya sahip kılar. InceptionV3, özellik çıkarımı ve sınıflandırma görevlerinde başarıyla kullanılan bir derin öğrenme mimarisidir.

3.10.4. ResNet 101


ResNet ailesinin 101 katman derinliğindeki ESA tabanlı mimarisi olan ResNet101, önceden ImageNet veri seti ile eğitilmiştir ve 224×224 boyutlu giriş görüntülerini kullanmaktadır. Bu geniş görüntü yelpazesi, ağı 1000 nesneyi farklı kategorilere ayırabilmesine olanak tanır. ResNet101 modeli, beş ana evrişim katmanı içeren toplamda yüz evrişim katmanı, ortalama havuzlama ve tam bağlantılı katmanlardan oluşmaktadır. Ayrıca, veri boyutlarını artırmak amacıyla kısayol bağlantıları uygulanarak evrişim derinliği önemli ölçüde arttırılmış ve modelin performansı belirgin bir şekilde geliştirilmiştir. Kısayol bağlantıları, arttırılan ağ derinliğinin neden olduğu bozulmanın önüne geçmek için kimlik eşleştirmesi işlemini gerçekleştirir (Chen vd., 2021). Bu özellikleriyle ResNet101, derin öğrenme alanındaki önemli modellerden biridir.

3.10.5. EfficientNet

EfficientNet modeli, Google araştırma ekibinden Tan ve Le tarafından 2019 yılında geliştirildi. Bu araştırmacılar, KSA (Katman, Serbest ve Alan) model ölçeklendirmesini inceleyerek, ağın derinlik, genişlik ve çözünürlüğünün dengeli bir şekilde ölçeklendirilmesinin ağı performansını önemli ölçüde etkilediğini tespit ettiler. Bu bulguya dayanarak, ağı bu üç boyutunu eşit şekilde ölçeklendiren yeni bir yöntem önerdiler (Kumar, 2020). EfficientNet, B0'dan B7'ye kadar uzanan sekiz modelden oluşur. Model numarası arttıkça kullanılan parametre sayısı ve modelin performansı da artar. Öncelikle temel model olan EfficientNet-B0 oluşturulur ve ardından doğruluğu ve model boyutunu artırmak amacıyla bu temel model, bileşik ölçeklendirme yöntemiyle EfficientNet-B1'den EfficientNet-B7'ye kadar genişletilir. Her bir artışla birlikte, modelin işlem gücü yaklaşık olarak iki katına çıkar (Kızrak, 2019).

EfficientNet modelleri, ImageNet'teki diğer mevcut CNN (Konvolüsyonel Sinir Ağları) mimarileriyle karşılaştırıldığında hem doğruluk oranını artırmış hem de parametre boyutunu ve FLOPS'u (Floating Point Operations Per Second) azaltarak daha yüksek verimlilik elde etmiştir. Örneğin, EfficientNet-B7 modeli, mevcut en iyi CNN modeline göre 8,4 kat daha küçük ve 6,1 kat daha hızlı olmasına rağmen, ImageNet yarışmasında 66M parametre ile %84,4 doğruluk oranı yakalamıştır.

Benzer şekilde, EfficientNet-B4 modeli, yaygın olarak kullanılan ResNet-50 modeliyle karşılaştırıldığında, neredeyse aynı sayıda parametre kullanarak ResNet-50'nin %76,3 doğruluk oranına karşın %82,6 doğruluk oranı elde etmiştir (Tan ve Le 2019). EfficientNet modellerinin diğer modellere göre parametre sayısı ve doğruluk oranı kıyaslaması, Şekil 30'da gösterilmiştir.



Şekil 30. EfficientNet modellerinin diğer modellerle karşılaştırılması

Kaynak: Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.

3.10.6. K Kat Çapraz Doğrulama

Derin öğrenme algoritmalarındaki sınıflandırma problemlerinde kullanılan veri setleri genellikle eğitim ve doğrulama olmak üzere iki ana kategoriye ayrılır. Eğitim veri seti, modelin öğrenme sürecinde kullanılarak eğitildiği verileri içerirken, doğrulama veri seti ise eğitilen modelin performansının değerlendirilmesi için kullanılır. Ancak, özellikle küçük veri setlerinde, bu ayrım rastgele yapılmamış olabilir. Bu durumda, modelin aşırı uyum durumuna düşme riski ortaya çıkabilir, çünkü model eğitildiği veri setine çok fazla odaklanabilir ve genelleme yeteneği kaybolabilir.


Bu tür problemleri aşmak ve modelin gerçek değerlendirmesini sağlamak için derin öğrenme algoritmalarında sıklıkla kullanılan bir teknik, k kat çapraz doğrulama

yöntemidir. Bu yöntemde, veri seti k eşit alt küme veya katmana bölünür. Model, bu alt kümelerden biri hariç kalan k-1 alt kümeyle eğitilir ve kalan alt küme üzerinde doğrulama yapılır. Bu işlem k kez tekrarlanır ve elde edilen doğruluk değerleri ortalaması alınarak modelin sağlamlığı değerlendirilir.

K kat çapraz doğrulama, rastgele alt kümeler kullanılarak modelin aşırı uyumdan korunmasına yardımcı olur. Her alt küme, modelin eğitim verilerinin farklı bir kesitini temsil eder, bu da genelleme yeteneğini artırır ve modelin gerçek dünya verilerine daha iyi uyarlanmasına olanak tanır (Xiong vd., 2020). Bu nedenle, k kat çapraz doğrulama tekniği, derin öğrenme modellerinin performansını güvenilir bir şekilde değerlendirmek için önemli bir strateji olarak kabul edilmektedir.


3.11. Performans Metrikleri

Yapay zeka teknikleri, makine öğrenmesi ve derin öğrenme teknikleriyle oluşturulan modellerin başarılarının test edilmesi, modelin eğitim sürecine dahil edilmeyen verilerle gerçekleştirilmelidir. Bu yüzden, oluşturulacak modelde kullanılacak veri seti, eğitim ve test verileri olarak ayrılmaktadır. Model eğitildikten sonra, test verisi kullanılarak modelin performansı değerlendirilir. Modelin performansını ölçmek için çeşitli hesaplama teknikleri bulunmaktadır. Bu çalışmada, modellerin performansını değerlendirmek amacıyla karışıklık matrisi ve bu matrise dayalı olarak hesaplanan doğruluk, kesinlik, geri çağırma ve f-1 skoru gibi performans metrikleri kullanılmaktadır.



Şekil 31. Doğrulama Grafiği


Şekil 31' de modelin eğitim doğruluğu (mavi çizgi) ve doğrulama doğruluğu (turuncu çizgi) epoch (iterasyon) sayısına göre değişimi gösterilmektedir. Başlangıçta, eğitim doğruluğu %65 civarında iken doğrulama doğruluğu %75'e yakındır, bu da modelin başlangıçta eğitim verilerine yeterince iyi uyum sağlamadığını ancak doğrulama verileri üzerinde daha iyi performans gösterdiğini işaret eder. Epoch 2'den itibaren, eğitim doğruluğunda belirgin bir artış görülmekte ve modelin eğitim verilerine daha iyi uyum sağladığı anlaşılmaktadır. Epoch 3 ve 4'te, her iki doğruluk değeri birbirine yaklaşmakta ve yükselmektedir, bu da modelin hem eğitim hem de doğrulama verilerinde iyileştiğini gösterir. Epoch 5'e gelindiğinde, eğitim doğruluğu %80'in üzerine çıkarken doğrulama doğruluğu %77 civarındadır, bu da modelin eğitim verilerine doğrulama verilerine göre daha iyi uyum sağladığını ve aşırı öğrenme (overfitting) yapma potansiyelini işaret edebilir. Genel olarak, modelin eğitim süreci ilerledikçe hem eğitim hem de doğrulama doğruluğunda iyileşme gözlemlenmektedir.



Şekil 32. Eğitim Ve Doğrulama Kayıp Grafiği


Şekil 32'de , modelin eğitim kaybı (mavi çizgi) ve doğrulama kaybı (turuncu çizgi) epoch (iterasyon) sayısına göre değişimi gösterilmektedir. Başlangıçta (Epoch 1), eğitim kaybı oldukça yüksek (%1 civarında) iken doğrulama kaybı daha düşük (%0.7 civarında) seviyededir. Bu, modelin başlangıçta eğitim verileri üzerinde yüksek kayıplar yaşadığını ancak doğrulama verileri üzerinde daha düşük kayıplar yaşadığını gösterir. Epoch 2'den itibaren, her iki kayıp değerinde de belirgin bir düşüş gözlemlenmektedir; eğitim kaybı hızla azalırken doğrulama kaybı da istikrarlı bir şekilde azalmaktadır. Epoch 3 ve 4'te, eğitim kaybı sürekli olarak azalırken doğrulama kaybında küçük bir artış ve ardından tekrar azalma görülmektedir. Bu durum, modelin

genel performansının iyileştiğini ancak doğrulama verileri üzerinde küçük dalgalanmalar yaşadığını gösterir. Epoch 5'te, eğitim kaybı %0.3 seviyelerine kadar düşerken doğrulama kaybı %0.6 civarında kalmaktadır. Bu, modelin eğitim verileri üzerinde çok düşük kayıplar yaşadığını ancak doğrulama verileri üzerinde biraz daha yüksek kayıplar yaşadığını gösterir. Genel olarak, modelin eğitim sürecinde hem eğitim hem de doğrulama kayıplarının azaldığını göstermektedir. Eğitim kaybının doğrulama kaybından daha hızlı azalması, modelin eğitim verilerine daha iyi uyum sağladığını ancak doğrulama verileri üzerinde hala iyileştirme potansiyeli olduğunu işaret edebilir. Bu durum, modelin aşırı öğrenme (overfitting) yapma riskini de gösterebilir, çünkü eğitim verilerine çok iyi uyum sağlarken doğrulama verilerindeki performans farklılıkları devam etmektedir.




Şekil 33. Overfitting Grafiği

Şekil 33' de modelin eğitim kaybı (mavi çizgi) ve doğrulama kaybı (kırmızı çizgi) epoch sayısına göre değişimi gösterilmektedir; başta her iki kayıp değeri de yüksek iken, epoch ilerledikçe her ikisi de azalmakta, ancak eğitim kaybı daha hızlı ve sürekli olarak azalırken doğrulama kaybı daha yavaş azalmakta ve hatta epoch 3'te hafif bir artış göstermektedir; bu durum, modelin eğitim verilerine aşırı uyum sağladığını (overfitting) ve doğrulama verileri üzerinde beklenenden daha kötü performans sergileyebileceğini işaret eder. Ancak epoch sayısı arttıkça aşırı öğrenme değerinde düştüğü gözlemlenmektedir.



Şekil 34. Çok Sınıflı ROC Eğrisi

Şekil 34’de , modelin çeşitli sınıflar için ROC (Receiver Operating Characteristic) eğrileri ve her bir sınıfın AUC (Area Under the Curve) değerleri gösterilmektedir. ROC eğrisi, doğru pozitif oranının (sensitivity) yanlış pozitif oranına (1-specificity) karşı çizilmesiyle elde edilir ve modelin sınıflandırma performansını değerlendirir. Sınıf 0 için ROC eğrisi, AUC değeri 0.99 ile en yüksek performansı göstermekte, bu sınıfın neredeyse mükemmel bir şekilde ayrıştırıldığını işaret etmektedir. Diğer sınıflar için AUC değerleri sırasıyla sınıf 1 için 0.86, sınıf 2 için 0.92, sınıf 3 için 0.91 ve sınıf 4 için 0.90 olarak verilmiştir. Bu değerler, modelin tüm sınıflarda iyi bir performans sergilediğini, ancak bazı sınıflarda (özellikle sınıf 1) diğerlerine göre daha düşük performans gösterdiğini belirtir. Genel olarak, ROC eğrilerinin eğimleri ve AUC değerleri modelin çok sınıflı sınıflandırma görevinde oldukça başarılı olduğunu göstermektedir.




Şekil 35. Her Sınıf İçin F1 Skoru

F1 skoru, bir modelin performansını değerlendirmek için kullanılan bir metriktir ve doğruluk (precision) ile geri çağırma (recall) metriklerinin harmonik ortalamasıdır. F1 skoru, doğruluk ve geri çağırma arasındaki dengeyi gösterir ve özellikle sınıflar arasındaki dengesizliklerin olduğu durumlarda faydalıdır. F1 skoru 1'e ne kadar yakınsa, modelin performansı o kadar iyidir; 0'a yakın olması ise zayıf performansı gösterir.

Şekil 35'de, modelin farklı sınıflar için F1 skorları gösterilmektedir. F1 skoru, doğruluk (precision) ve geri çağırma (recall) metriklerinin harmonik ortalaması olup, modelin dengeli performansını ölçmek için kullanılır.

DR Yok (0.95): En yüksek F1 skoruna sahiptir, model bu sınıfta oldukça başarılıdır. Hafif NPDR (0.45): F1 skoru düşüktür, bu sınıfta modelin performansı zayıftır. Orta NPDR (0.75): Orta derecede yüksek bir F1 skoru ile model bu sınıfta iyi performans göstermektedir. Şiddetli NPDR (0.40): Düşük bir F1 skoru ile bu sınıfta modelin performansı zayıftır. PDR (0.60): Orta düzeyde bir F1 skoru ile modelin bu sınıfta kabul edilebilir bir performansı vardır.

Bu sonuçlar, modelin bazı sınıflarda (örneğin, DR Yok ve Orta NPDR) yüksek performans sergilediğini, ancak Hafif NPDR ve Şiddetli NPDR gibi bazı sınıflarda performansının düşük olduğunu göstermektedir. Modelin genel performansı dengeli değildir ve bazı sınıflar için iyileştirilmesi gerekmektedir.



Şekil 36. Karışıklık (Confusion Matrix) Matrisi

Karışıklık matrisi (confusion matrix), bir sınıflandırma modelinin performansını değerlendirmek için kullanılan bir tablodur. Bu matris, gerçek sınıflar ile modelin tahmin ettiği sınıflar arasındaki ilişkiyi gösterir. Matristeki her bir hücre, belirli bir sınıfın gerçek ve tahmin edilen değerlerinin sayısını temsil eder.

Şekil 36 incelendiğinde; DR YOK (278): Model bu sınıfı doğru bir şekilde 278 kez tahmin etmiştir. Hafif NPDR (55): Model bu sınıfı doğru bir şekilde 55 kez tahmin etmiştir. Orta NPDR (177): Model bu sınıfı doğru bir şekilde 177 kez tahmin etmiştir.

Şiddetli NPDR (13): Model bu sınıfı doğru bir şekilde 13 kez tahmin etmiştir. PDR (27): Model bu sınıfı doğru bir şekilde 27 kez tahmin etmiştir.

Karışıklık matrisi modelin performansının değerlendirilmesi açısından önemlidir. Örneğin, "DR YOK" sınıfında 278 doğru tahmin yapılmış ve bu sınıf için hiç yanlış tahmin yapılmamıştır. Benzer şekilde, diğer sınıflar için de doğru tahminler yüksek orandadır ve yanlış sınıflandırma oranları düşüktür. Bu, modelin genel olarak iyi performans gösterdiğini ve sınıfları doğru bir şekilde ayırt edebildiğini göstermektedir.

SONUÇ

İnsülin hormonunun eksikliği veya yokluğu nedeniyle ortaya çıkan diyabetes mellitus, yani şeker hastalığı, retinadaki görme hücrelerine zarar verebilen diyabetik retinopati (DR) komplikasyonuna yol açabilmektedir. Dünyada ve Avrupa'nın en yüksek diyabet oranına sahip olan ülkemizde, DR komplikasyonunun artışı bireyler için ciddi sorunlar yaratmaktadır. Bu nedenle, en sık görülen körlük sebebi olan bu hastalığın erken dönemde tespit edilmesi, hasta bireyleri kalıcı hasarlardan korumak açısından büyük önem taşımaktadır. Bu doğrultuda, teşhis süreçlerini hızlandırmak, tıp uzmanlarının iş yükünü azaltmak ve kararlarını güçlendirmek amacıyla yapay zeka tabanlı sistemler önerilmektedir.

Bu tez çalışmasında, retina görüntülerinden diyabetik retinopati (DR) hastalığını sağlıklı, hafif NPDR (non-proliferatif diyabetik retinopati), orta NPDR, şiddetli NPDR ve PDR (proliferatif diyabetik retinopati) olmak üzere beş sınıfa ayırarak teşhis etmek amaçlanmıştır. DR sınıflandırma işlemi, görüntü işleme teknikleri ve derin öğrenme metotları kullanılarak gerçekleştirilmiştir. Çalışmada kullanılan Kaggle APTOS 2019 veri seti çeşitli gürültüler içerdiğinden, görüntü özneteliklerinin daha verimli bir şekilde çıkarılarak sınıflandırma başarısını artırmak amacıyla görüntü işleme tekniklerine ihtiyaç duyulmuştur. Bu bağlamda, görüntüler üzerinde Gauss bulanıklaştırma filtresi ve CLAHE (Contrast Limited Adaptive Histogram Equalization) olmak üzere iki ayrı teknik uygulanmıştır. Böylece, bu iki farklı görüntü işleme tekniğinin aynı sınıflandırma problemi üzerindeki başarıma etkisi kıyaslanmıştır. Görüntüler, 400x400 piksel boyutuna getirilerek standartize edilmiştir. Sınıflandırma işlemi, çoklu etiketli sınıflandırma (multi-label classification) problemi olarak ele alınmış ve hedef sınıfın önceki sınıftaki semptomları da kapsayacak şekilde tahmin edilmesi sağlanmıştır. Bu yaklaşım, modelin tahminleri ile gerçek değerler arasındaki farkın azaltılarak isabetli tahmin oranının artırılmasını amaçlamıştır. Sınıflandırma aşaması için 2019 yılında Google tarafından geliştirilen bir konvolüsyonel sinir ağı (KSA) mimarisi olan EfficientNet kullanılmış ve ince ayar yapılmıştır.

EfficientNet-B5 modeli, Kaggle veri setinden alınan test görüntüsü üzerinde Gauss bulanıklaştırma filtresi ile %80 doğruluk skoru elde etmiştir. Sonuçlar, Gauss

bulanıklaştırma filtresi ile görüntülerin ortalama yerel renginin çıkarıldığı görüntü işleme tekniğinin, CLAHE tekniğine kıyasla daha başarılı olduğunu göstermektedir.

Diyabetik retinopati (DR) tespit çalışmaları, genellikle iki sınıflı olarak "hasta" ve "sağlıklı" şeklinde, ya da hastalığın farklı evrelerini belirleyerek beş sınıflı olarak gerçekleştirilir. Bazı çalışmalar, bu evreleri birleştirerek üçlü veya dörtlü sınıflandırma da yapmaktadır. Sınıf sayısı arttıkça modelin doğru tahmin yapma işlemi zorlaşmakta ve performans düşmektedir. Bu durumu önlemek için, modelin daha karmaşık özellikleri öğrenebilmesi gerekmektedir. EfficientNet-B5 modeli, performans metrikleri incelendiğinde DR sınıflandırmasında başarılı bir performans sergilemiştir. Modelin hastalığın hangi aşamalarını daha net algılayabildiği incelendiğinde, elde edilen karışıklık matrislerinden modelin "sağlıklı" etiketli görüntüleri neredeyse kesin bir şekilde sınıflandırabildiği, ancak bazı diğer sınıflar için aynı kesinliği yakalayamadığı görülmüştür. Özellikle "ileri NPDR" etiketli görüntüleri, model diğer sınıflara göre daha az algılamaktadır. Bu durum, kullanılan veri setindeki sınıfların dağılımının homojen olmamasından ve veri setinde en az sayıda bulunan sınıfın "ileri NPDR" etiketli görüntüler olmasından kaynaklanmaktadır.

KAYNAKÇA

- Aiello, L. M. (2003). Perspectives on diabetic retinopathy. *American Journal of Ophthalmology*, 136(1), 122-135.
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017, August). Understanding of a convolutional neural network. In *2017 International Conference on Engineering and Technology (ICET)* (pp. 1-6). IEEE.
- Ali, A., Qadri, S., Khan Mashwani, W., Kumam, W., Kumam, P., Naeem, S., ... & Sulaiman, M. (2020). Machine learning based automated segmentation and hybrid feature analysis for diabetic retinopathy classification using fundus image. *Entropy*, 22(5), 567.
- Anonim. (2024, Ocak 28). Dünya Sağlık Örgütü, “World Health Organization”. <https://www.who.int/healthtopics/diabetes> adresinden edinilmiştir.
- Anonim. (2024, Mayıs 7). <https://invisioncare.com/diabetic-retinopathy/> adresinden edinilmiştir.
- Antcliff, R. J., Stanford, M. R., Chauhan, D. S., Graham, E. M., Spalton, D. J., Shilling, J. S., & Marshall, J. (2000). Comparison between optical coherence tomography and fundus fluorescein angiography for the detection of cystoid macular edema in patients with uveitis. *Ophthalmology*, 107(3), 593-599.
- Asiri, N., Hussain, M., Al Adel, F., & Alzaidi, N. (2019). Deep learning based computer-aided diagnosis systems for diabetic retinopathy: A survey. *Artificial Intelligence in Medicine*, 99, 101701.
- Ayodele, T. O. (2010). Machine learning overview. In Y. Zhang (Ed.), *New Advances in Machine Learning* (pp. 9-18). IntechOpen.
- Bethanney, J., Divakaran, S., Abraham, S., G, M., & G, U. S. (2015). Detection and classification of exudates in retinal image. *Journal of Chemical and Pharmaceutical Sciences*, 8(3), 6.

- Cao, Z., Dan, Y., Xiong, Z., Niu, C., Li, X., Qian, S., & Hu, J. (2019). Convolutional neural networks for crystal material property prediction using hybrid orbital-field matrix and magpie descriptors. *Crystals*, 9(4), 191.
- Chakraborty, S., Jana, G. C., Kumari, D., & Swetapadma, A. (2020). An improved method using supervised learning technique for diabetic retinopathy detection. *International Journal of Information Technology*, 12, 473-477.
- Chan, T. H., Jia, K., Gao, S., Lu, J., Zeng, Z., & Ma, Y. (2015). PCANet: A simple deep learning baseline for image classification? *IEEE Transactions on Image Processing*, 24(12), 5017-5032.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 1251-1258).
- Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20, 274-46.
- Coşansu, G. (2015). Diyabet: Küresel bir salgın hastalık. *Okmeydanı Tıp Dergisi*, 31(ek sayı), 1-6.
- Deepa, V., Kumar, C. S., & Andrews, S. S. (2021). Fusing dual- tree quaternion wavelet transform and local mesh based features for grading of diabetic retinopathy using extreme learning machine classifier. *International Journal of Imaging Systems and Technology*, 31(3), 1625-1637.
- Dhakal, A., Bastola, L. P., & Shakya, S. (2019). Detection and classification of diabetic retinopathy using adaptive boosting and artificial neural network. *International Journal of Advanced Research and Publications (IJARP)*, 3(8), 191-196. <http://www.ijarp.org/online-papers-publishing/aug2019> adresinden edinilmiştir.
- Early Treatment Diabetic Retinopathy Study Research Group. (1991). Grading diabetic retinopathy from stereoscopic color fundus photographs—an extension of the modified Airlie House classification: ETDRS report number 10. *Ophthalmology*, 98(5), 786-806.

- Early Treatment Diabetic Retinopathy Study Research Group. (1991). Early photocoagulation for diabetic retinopathy: ETDRS report number 9. *Ophthalmology*, 98(5), 766-785.
- Egan, A. M., & Dinneen, S. F. (2019). What is diabetes?. *Medicine*, 47(1), 1-4.
- Engerman, R. L. (1989). Pathogenesis of diabetic retinopathy. *Diabetes*, 38(10), 1203-1206.
- Forsyth, D. A., Mundy, J. L., di Gesù, V., Cipolla, R., LeCun, Y., Haffner, P., ... & Bengio, Y. (1999). Object recognition with gradient-based learning. *Shape, Contour and Grouping in Computer Vision*, 319-345.
- Gao, F., Li, B., Chen, L., Shang, Z., Wei, X., & He, C. (2021). A softmax classifier for high-precision classification of ultrasonic similar signals. *Ultrasonics*, 112, 106344.
- Gayathri, S., Gopi, V. P., & Palanisamy, P. (2020). Automated classification of diabetic retinopathy through reliable feature selection. *Physical and Engineering Sciences in Medicine*, 43(3), 927-945.
- Gimenez, M., Palanca, J., & Botti, V. (2020). Semantic-based padding in convolutional neural networks for improving the performance in natural language processing. A case of study in sentiment analysis. *Neurocomputing*, 378, 315-323.
- Gündoğan, F. Ç. (2018). 28 Ocak 2024 tarihinde <https://gozdoktor.net/gozun-yapisi/> adresinden edinilmiştir.
- Han, D., Liu, Q., & Fan, W. (2018). A new image classification method using CNN transfer learning and web data augmentation. *Expert Systems with Applications*, 95, 43-56.
- Hemanth, D. J., Deperlioglu, O., & Kose, U. (2020). An enhanced diabetic retinopathy detection and classification approach using deep convolutional neural network. *Neural Computing and Applications*, 32(3), 707-721.

- Hoffer, E., Hubara, I., & Soudry, D. (2017). Train longer, generalize better: closing the generalization gap in large batch training of neural networks. *Advances in Neural Information Processing Systems*, 30.
- İnan, S. (2014). Retina anatomisi. *Kocatepe Tıp Dergisi*, 15(3), 355-359.
- Indolia, S., Goswami, A. K., Mishra, S. P., & Asopa, P. (2018). Conceptual understanding of convolutional neural network: A deep learning approach. *Procedia Computer Science*, 132, 679-688.
- Kadam, V. J., Jadhav, S. M., & Vijayakumar, K. (2019). Breast cancer diagnosis using feature ensemble learning based on stacked sparse autoencoders and softmax regression. *Journal of Medical Systems*, 43(8), 263.
- Karaboğa D (2017) Yapay Zekâ Optimizasyon Algoritmaları. 4. Baskı, ISBN: 978-605-133-764-7, Nobel Akademik Yayıncılık, Ankara, 246 s.
- Khan, F. G., Shah, S., Khan, A., Shamshirband, S., Rehman, Z. U., ... & Jadoon, W. (2019). A deep learning ensemble approach for diabetic retinopathy detection. *IEEE Access*, 7, 150530-150539.
- Khan, M. A., Balgi, A. P., Chaithra, C., & Kumar, P. (2020). Diabetic retinopathy detection by image processing algorithms and machine learning technique. *JNNCE Journal of Engineering & Management (JJEM)*, 4(1), 8.
- Khan, S., Islam, N., Jan, Z., Din, I. U., & Rodrigues, J. J. C. (2019). A novel deep learning based framework for the detection and classification of breast cancer using transfer learning. *Pattern Recognition Letters*, 125, 1-6.
- Kızrak, A. 2019. Web Sitesi: <https://medium.com/@ayyucekizrak/ölçeklendirme-ile-cnnmodelinin-doğruluk-ve-verimliliğini-artırma-efficientnet-cb6f2b6512de/>, Erişim Tarihi: 21.05.2024.
- Kobrin Klein, B. E. (2007). Overview of epidemiologic studies of diabetic retinopathy. *Ophthalmic Epidemiology*, 14(4), 179-183.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25.

- Kumar, H. V., Bharathi, P. T., & Madhuri, R. (2016). A novel method for image analysis and exudates detection in retinal images. *Int J Adv Res Innov*, 4(1), 219-223.
- Larson, E. B., & Yao, X. (2005). Clinical empathy as emotional labor in the patient-physician relationship. *JAMA*, 293(9), 1100-1106.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Liu, Z., & Cheng, Y. (2021). Fuzzy C-means clustering with feature selection for dimension reduction in machine learning. *IEEE Transactions on Fuzzy Systems*.
- Lloyd, M. (2000). Diabetic retinopathy: an update. *Community Eye Health*, 13(35), 27.
- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 3431-3440).
- Mahmoud, M. H., Alamery, S., Fouad, H., Altinawi, A., & Youssef, A. E. (2023). An automatic detection system of diabetic retinopathy using a hybrid inductive machine learning algorithm. *Personal and Ubiquitous Computing*, 1-15.
- Math, L., & Fatima, R. (2021). Adaptive machine learning classification for diabetic retinopathy. *Multimedia Tools and Applications*, 80(4), 5173-5186.
- Mathews, N. R., & Dumitrescu, C. E. (2017). Diagnosis and management of diabetic retinopathy: a comprehensive review. *Journal of Ophthalmology*, 2017.
- Mishkin, D., Sergievskiy, N., & Matas, J. (2017). Systematic evaluation of convolution neural network advances on the imagenet. *Computer vision and image understanding*, 161, 11-19.
- Mohan, V., Sandeep, S., Deepa, R., Shah, B., & Varghese, C. (2007). Epidemiology of type 2 diabetes: Indian scenario. *The Indian Journal of Medical Research*, 125(3), 217-230.

- Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)* (pp. 807-814).
- Nazir, T., Irtaza, A., Shabbir, Z., Javed, A., Akram, U., & Mahmood, M. T. (2019). Diabetic retinopathy detection through novel tetragonal local octa patterns and extreme learning machines. *Artificial intelligence in medicine*, 99, 101695.
- Nikhil, J., & Nwaneri, A. O. (2019). Supervised machine learning algorithms: classification and comparison. *International Journal of Computer Trends and Technology (IJCTT)*, 68(5), 111-118.
- Nwankpa, C., Ijomah, W., Gachagan, A., & Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*.
- O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*.
- Özkan, İ. N. İ. K., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Park, J., Kong, S. G., & Lee, H. (2021). Diabetic retinopathy classification using the subband features of near-infrared images and softmax classifier. *Journal of Electrical Engineering and Technology*, 16(1), 293-300.
- Pauly L, Hogg D, Fuentes R and Peel H (2017) Deeper Networks for Pavement Crack Detection. *Proceedings of the 34th International Symposium in Automation and Robotics in Construction*, 2017: 479-485
- Pead, E. (2018). An introduction to diabetic retinopathy. *Community Eye Health*, 31(102), 42-43.
- Pieroni, L., Santini, S., Amato, F., & Masciulli, F. (2019). Diabetic retinopathy assessment and classification using eye fundus image. In *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)* (pp. 4238-4243). IEEE.

- Prasetyo, S., & Tarigan, E. (2017). A novel feature extraction approach for diabetic retinopathy diagnosis system. In *2017 5th International Conference on Cyber and IT Service Management (CITSM)* (pp. 1-6). IEEE.
- Pratap, A., Raj, B., & Sathiyabhama, B. (2019). Early detection and classification of diabetic retinopathy using faster R-CNN and APTOS dataset. *International Journal of Engineering and Advanced Technology (IJEAT)*, 9(1), 5392-5397.
- Pugh, J. A., Jacobson, J. M., Van Heuven, W. A. J., Watters, J. A., Tuley, M. R., & Lairson, D. R. (1993). Screening for diabetic retinopathy: the wide-angle retinal camera. *Diabetes Care*, 16(6), 889-895.
- Qayyum, A., & Hemanth, D. J. (2022). Hybrid ResNet50–SVM model for early diagnosis of diabetic retinopathy. *Multimedia Tools and Applications*, 81, 29953–29975. <https://doi.org/10.1007/s11042-022-13208-5> adresinden edinilmiştir.
- Qiao, L., Zhu, Y., & Zhou, H. (2020). Diabetic retinopathy detection using prognosis of microaneurysm and early diagnosis system for non-proliferative diabetic retinopathy based on deep learning algorithms. *IEEE Access*, 8, 104292-104302.
- Qummar, S., Khan, F. G., Shah, S., Khan, A., Shamshirband, S., Rehman, Z. U., ... & Jadoon, W. (2019). A deep learning ensemble approach for diabetic retinopathy detection. *Ieee Access*, 7, 150530-150539.
- Rachid, H., Abdelaziz, B., Soukaina, L., & Rachid, L. (2020). Convolutional neural networks for diabetic retinopathy diagnosis. In *2020 IEEE International Conference on Technology Management, Operations and Decisions (ICTMOD)* (pp. 1-6). IEEE.
- Rahim, M. S. M., & Raja Abdullah, S. S. M. (2017). Detection and classification of diabetic retinopathy using difference of gaussian filtering and support vector machine. *Journal of Medical Imaging and Health Informatics*, 7(2), 388-393.
- Rosin, L. M., & Bell, N. P. (2004). Presbyopia: a review of the evidence. *Eye*, 18(9), 872-876.

- Ruder S (2016) An Overview of Gradient Descent Optimization Algorithms. *arXiv preprint arXiv:1609.04747*.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... & Fei-Fei, L. (2015). Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115, 211-252.
- Saleh, A. E., & Mahmoud, M. A. (2020). Diabetic retinopathy detection in color fundus images using convolutional neural network. In *2020 International Conference on Innovative Trends in Communication and Computer Engineering (ITCE)* (pp. 65-70). IEEE.
- Schapire, R. E. (2003). The boosting approach to machine learning: An overview. *Nonlinear estimation and classification*, 149-171.
- Scherer, D., Müller, A., & Behnke, S. (2010, September). Evaluation of pooling operations in convolutional architectures for object recognition. In *International conference on artificial neural networks* (pp. 92-101). Berlin, Heidelberg: Springer Berlin Heidelberg
- Shan, J., & Li, L. (2016, June). A deep learning method for microaneurysm detection in fundus images. In *2016 IEEE First International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE)* (pp. 357-358). IEEE.
- Shanthi, T., Sabeenian, R. S., & Anand, R. (2020). Automatic diagnosis of skin diseases using convolution neural network. *Microprocessors and Microsystems*, 76, 103074.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Soh, S., Azar, D., & Seddon, J. M. (2018). Diabetic retinopathy and age-related macular degeneration: Emerging genetic and environmental interactions. *Cell Metabolism*, 27(3), 535-553.
- Srivastava N, Hinton G, Krizhevsky A, Sutskever I and Salakhutdinov R (2014) Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *The journal of machine learning research*, 15(1): 1929-1958.

- Su, J., Vargas, D. V., & Sakurai, K. (2019). One pixel attack for fooling deep neural networks. *IEEE Transactions on Evolutionary Computation*, 23(5), 828-841.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
- Takahashi, H., Yoshida, T., Ishikawa, S., Yamasaki, M., Shimizu, M., Kanda, K., & Yoneda, K. (2018). Functional roles of ophthalmic beta-blockers in patients with glaucoma. *Journal of Ocular Pharmacology and Therapeutics*, 34(7), 553-560.
- Tawfik, R. A., & Abdel-Mottaleb, M. (2021). Diabetic retinopathy assessment and classification using deep learning. *Electronics*, 10(17), 2050.
- Tsao, H. Y., Chan, P. Y., & Su, E. C. Y. (2018). Predicting diabetic retinopathy and identifying interpretable biomedical features using machine learning algorithms. *BMC bioinformatics*, 19, 111-121.
- Uchida, T., Uchida, K., & Akashi, T. (2019). Intraocular lens dislocation after cataract surgery: five-year results of the national registry of Japan. *Ophthalmology*, 126(8), 1064-1071.
- Uyansız, M. (2019). *Göz Nedir? Yapısı, İşlevi ve Hastalıkları*. 28 Ocak 2024 tarihinde <https://www.psikopatolojibilimi.com/2019/01/23/goz-nedir-yapisi-islevi-ve-hastaliklari/> adresinden edinilmiştir.
- Uzun R, Yılmaz E and Özer M (2017) Effects of Autapse and Ion Channel Block on The Collective Firing Activity of Newman–Watts Small-World Neuronal Networks. *Physica A: Statistical Mechanics and Its Applications*, 486 (1): 386-396.
- Van Eyk, J. E., & Tsai, H. T. (2003). An introduction to diabetic retinopathy. *Community Eye Health*, 16(45), 12-15.
- Van Grinsven, M. J., van Ginneken, B., Hoyng, C. B., Theelen, T., & Sánchez, C. I. (2016). Fast convolutional neural network training using selective data sampling: Application to hemorrhage detection in color fundus images. *IEEE transactions on medical imaging*, 35(5), 1273-1284.

- Vijayan, T., Sangeetha, M., Kumaravel, A., & Karthik, B. (2023). Feature selection for simple color histogram filter based on retinal fundus images for diabetic retinopathy recognition. *IETE Journal of Research*, 69(2), 987-994.
- Walter, T., Massin, P., Erginay, A., Ordonez, R., Jeulin, C. and Klein, J.-C. 2007. Automatic detection of microaneurysms in color fundus images. *Medical image analysis*, 11:6, 555-566.
- Wang, H., Yuan, Y., Zhu, H., Li, M., Yang, X., & Liu, Y. (2019). Machine learning methods for diabetic retinopathy image classification. In *Proceedings of the 2019 International Conference on Deep Learning and Machine Learning* (pp. 15-20).
- Xiao, T., Singh, M., Mintun, E., Darrell, T., Dollár, P., & Girshick, R. (2021). Early convolutions help transformers see better. *Advances in neural information processing systems*, 34, 30392-30400.
- Yan, Y., Yang, T., Li, Z., Lin, Q., & Yang, Y. (2018). A unified analysis of stochastic momentum methods for deep learning. *arXiv preprint arXiv:1808.10396*.
- Yau, J. W., Rogers, S. L., Kawasaki, R., Lamoureux, E. L., Kowalski, J. W., Bek, T., ... & Mitchell, P. (2012). Global prevalence and major risk factors of diabetic retinopathy. *Diabetes Care*, 35(3), 556-564.
- Yılmaz, A., & Kaya, U. (2022). *Derin öğrenme*. KODLAB.
- Ying, X. (2019, February). An overview of overfitting and its solutions. In *Journal of physics: Conference series* (Vol. 1168, p. 022022). IOP Publishing.
- Zeiler, M. D. (2012). Adadelata: an adaptive learning rate method. *arXiv preprint arXiv:1212.5701*.
- Zeng, X., Chen, H., Luo, Y., & Ye, W. (2019). Automated diabetic retinopathy detection based on binocular siamese-like convolutional neural network. *IEEE access*, 7, 30744-30753.
- Zhang, K., Liu, X., Xu, J., Yuan, Y., Tong, K., Wang, S., & Zhang, K. (2020). A retinal image based diabetic retinopathy grading system using transfer learning. *Computers in Biology and Medicine*, 116, 103629.

- Zhang, L., & Zhou, W. (2017). Diabetic retinopathy detection based on deep convolutional neural networks. In *2017 36th Chinese Control Conference (CCC)* (pp. 9076-9080). IEEE.
- Zhao, H., Chen, C., Li, X., Ma, Z., & Liu, Y. (2021). Improved fully convolutional network for building extraction from high-resolution remote sensing images. *Remote Sensing*, *13*(2), 209.