



AKSARAY ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

YÖNETİM BİLİŞİM SİSTEMLERİ ANA BİLİM DALI

**DIYABETİK RETİNOPATİ TEŞHİSİ İÇİN DERİN
ÖĞRENME TABANLI SINIFLANDIRMA ANALİZİ**

YÜKSEK LİSANS TEZİ

DİLAN BUDAK

DANIŞMAN

DOÇ. DR. RAHMİ BAKİ

AKSARAY-2024

AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
YÖNETİM BİLİŞİM SİSTEMLERİ ANA BİLİM DALI

**DİYABETİK RETİNOPATİ TEŞHİSİ İÇİN DERİN
ÖĞRENME TABANLI SINIFLANDIRMA ANALİZİ**

YÜKSEK LİSANS TEZİ

DİLAN BUDAK

DANIŞMAN : DOÇ. DR. RAHMİ BAKİ

2. DANIŞMAN : DOÇ. DR. KEMAL ADEM

JÜRİ ÜYESİ : PROF. DR. RAMAZAN KATIRCI

JÜRİ ÜYESİ : DR. ÖĞR. ÜYESİ ZEYNEP AYTAÇ

AKSARAY-2024

TELİF HAKLARI VE TEZ FOTOKOPİ İZİN FORMU

Bu tezin tüm hakları saklıdır. Kaynak göstermek koşuluyla tezin teslim tarihinden itibaren (....) ay sonra tezden fotokopi çekilebilir.

YAZARIN

Adı : Dilan

Soyadı : BUDAK

Bölümü : Yönetim Bilişim Sistemleri

İmza :

Teslim Tarihi :

TEZİN

Türkçe Adı : Diyabetik Retinopati Teşhisi İçin Derin Öğrenme Tabanlı Sınıflandırma Analizi

İngilizce Adı : Deep Learning Based Classification Analysis for Diabetic Retinopathy Diagnosis

ETİK İLKELERE UYGUNLUK BEYANI

Tez yazma sürecinde bilimsel ve etik ilkelere uyduđumu, yararlandıđım tüm kaynakları kaynak gösterme ilkelerine uygun olarak kaynakçada belirttiđimi ve bu bölümler dışındaki tüm ifadelerin şahsıma ait olduđunu beyan ederim.

Dilan BUDAK

İmza:

T.C.
AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
JÜRİ ONAY SAYFASI

Dilan BUDAK tarafından hazırlanan “Diyabetik Retinopati Teşhisi İçin Derin Öğrenme Tabanlı Sınıflandırma Analizi” başlıklı tez çalışması aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Aksaray Üniversitesi Sosyal Bilimler Enstitüsü Yönetim Bilişim Sistemleri Anabilim Dalı’nda Yüksek Lisans / Doktora tezi olarak kabul edilmiştir.

	<u>Kabul</u>	<u>Ret</u>	<u>İmza</u>
Danışman: Doç. Dr. Rahmi BAKİ (Yönetim Bilişim Sis.Anabilim Dalı, Aksaray Üniversitesi)	☐	☐	
Üye: Prof. Dr. Ramazan KATIRCI (Bilgisayar Mühendisliği Anabilim Dalı,Sivas Bilim ve Teknoloji Üniversitesi)	☐	☐	
Üye: Dr. Öğr. Üyesi Zeynep AYTAÇ (Yönetim Bilişim Sis.Anabilim Dalı, Aksaray Üniversitesi)	☐	☐	

Tez Savunma Tarihi:27/09/2024

Sosyal Bilimler Enstitüsü Yönetim Kurulu’nuntarih ve sayılı kararı ile onaylanmıştır.

Sosyal Bilimler Enstitüsü Müdürü

Prof. Dr. Aybala ÇAYIR

İmza

TEŞEKKÜR SAYFASI

Yüksek Lisans sürecinin en başından, bu çalışmanın gerçekleşmesine kadar olan tüm süreçlerde desteğini hiçbir zaman esirgemeyen ve üzerimde büyük emeği olan annem ile babama, kardeşlerime sonsuz şükranlarımı sunarım. Öğrencisi olmaktan gurur duyduğum ve prensiplerini ilke edindiğim hocalarım Doç. Dr. Kemal ADEM ve Doç. Dr. Rahmi BAKİ' ye çok teşekkür ederim. Ayrıca çalışma süreci boyunca daima yanımda olan sevgili iş arkadaşlarım ve dostlarıma da çok teşekkür ederim.

Saygılarımla,

Dilan BUDAK

ÖZET

Diyabetik retinopati, diyabet (şeker hastalığı) olan kişilerde görülen bir göz hastalığıdır. Bu hastalığın erken teşhisi önemlidir. Yapay zekâ, büyük veri analitiği ve derin öğrenme gibi gelişmiş algoritmaları kullanarak, tıp alanında çeşitli uygulamalara sahiptir. Bu sistemler uzman doktorların teşhislerini desteklemek veya büyük bir hasta kitlesini tarayarak erken teşhis için yardımcı olmak amacıyla kullanılabilir.

Bu çalışmada, normal, hafif, orta, şiddetli ve proliferatif fundus göz görüntülerinden oluşan 3662 örnekten oluşan Aptos veri seti ile 7915 görselden oluşan özgün bir veri seti hazırlanmıştır. İki farklı veri seti kullanılarak evrimsel sinir ağı modellerinde hiper parametrelerin sınıflandırma performansı üzerindeki etkileri incelenmiştir. Değerlendirilen hiper parametreler arasında sabit öğrenme oranı, öğrenme oranı planlaması yöntemleri, aktivasyon fonksiyonları, L2 düzenleme, veri artırma teknikleri ve optimizasyon algoritmaları yer almaktadır. Görüntülerin sınıflandırma başarısını artırmak için çeşitli ön işleme adımları uygulanmış ve transfer öğrenme yaklaşımıyla ResNet34 modeli kullanılarak eğitim gerçekleştirilmiştir. Başlangıçta 3662 Aptos veri seti üzerinde SGD optimizasyon algoritması ile model eğitilmiştir. Daha sonra 7915 veri seti üzerinde veri artırma teknikleri, L2 regülarizasyon kullanılarak Momentum optimizasyon algoritmasıyla tekrar eğitime tabi tutulmuş olup çıkan sonuçlar neticesinde başlangıç değerine göre ReLU %9,93, Leaky ReLU %8,99 oranında bir yükselme göstermiştir. Elde edilen sonuçlar, ReLU aktivasyon fonksiyonunun 0,786 doğruluk ve F1 skoru, Leaky ReLU'nun ise 0,751 doğruluk ve F1 skoru ile en yüksek başarıyı sağladığını göstermiştir. Bu bulgular, fundus göz görüntülerinin sınıflandırmasında hiper parametrelerin önemini vurgulamaktadır.

Anahtar Kelimeler: (Diyabetik Retinopati, Derin öğrenme, Aktivasyon Fonksiyonları, Optimizasyon Algoritmaları, L2 düzenleme).

Bilim Kodu: 114614

Sayfa Adedi: 63

Yazar: Dilan BUDAK

Danışman: Doç. Dr. Rahmi BAKİ

ABSTRACT

Diabetic retinopathy is an eye disease that occurs in people with diabetes. Early diagnosis of this disease is essential. Artificial intelligence has various applications in the medical field, using advanced algorithms such as big data analytics and deep learning. These systems can be used to support expert doctors' diagnoses or to screen a large population of patients to help with early diagnosis.

In this study, an Aptos dataset of 3662 samples of normal, mild, moderate, severe and proliferative fundus eye images and a unique dataset of 7915 images were prepared. The effects of hyperparameters on the classification performance of convolutional neural network models were analyzed using two different datasets. The hyper-parameters evaluated include fixed learning rate, learning rate planning methods, activation functions, L2 regularization, data augmentation techniques and optimization algorithms. Various preprocessing steps were applied to improve the classification success of the images and training was performed using the ResNet34 model with a transfer learning approach. Initially, the model was trained with an SGD optimization algorithm on 3662 Aptos datasets. Then, the model was retrained on 7915 datasets with the Momentum optimization algorithm using data augmentation techniques and L2 regularization, and the results showed an increase of 9.93% in ReLU and 8.99% in Leaky ReLU compared to the initial value. The results showed that the ReLU activation function achieved 0.786 accuracy and F1 score, while Leaky ReLU achieved the highest success with 0.751 accuracy and F1 score. These findings emphasize the importance of hyperparameters in the classification of fundus eye images.

Keywords: (Diabetic Retinopathy, Deep Learning, Activation Functions, Optimization Algorithms, L2 regularization).

Science Code: 114614

Number of Pages: 63

Author: Dilan BUDAK

Supervisor: Doç. Dr. Rahmi BAKİ

İÇİNDEKİLER

TELİF HAKLARI VE TEZ FOTOKOPİ İZİN FORMU	i
ETİK İLKELERE UYGUNLUK BEYANI	ii
JÜRİ ONAY SAYFASI.....	iii
TEŞEKKÜR SAYFASI.....	iv
ÖZET	v
ABSTRACT	vi
İÇİNDEKİLER.....	vii
TABLolar LİSTESİ	ix
ŞEKİLLER LİSTESİ	x
KISALTMALAR.....	xi
GİRİŞ.....	1
BİRİNCİ BÖLÜM.....	4
KURAMSAL TEMELLER	4
1.1. Araştırmanın Problemi	4
1.2. Araştırmanın Amacı	4
1.3. Araştırmanın Önemi	5
İKİNCİ BÖLÜM	6
KAVRAMSAL ÇERÇEVE VE LİTERATÜR TARAMASI	6
2.1. Diyabetik Retinopati Hastalığı	6
2.2. Diyabetik Retinopati Seviyeleri	7
2.2.1. Sağlıklı DR Görüntüsü.....	8
2.2.2. Hafif DR Görüntüsü.....	8
2.2.3. Orta DR Görüntüsü	9
2.2.4. Şiddetli DR Görüntüsü.....	9
2.2.5. Proliferatif DR Görüntüsü	10
2.3. Yapay Sinir Ağları.....	11
2.4. Derin Öğrenme	12

2.5. Evrişimli Sinir Ağları (ESA)	14
2.5.1. Evrişimli Sinir Ağları Giriş Katmanı	15
2.5.2. Evrişim Katmanı	15
2.5.3. Havuzlama Katmanı	17
2.5.4. Tam Bağlı Katman	17
2.6. Transfer Öğrenme	18
2.7. Transfer Öğrenme Modelleri	19
2.8. Performans Metrikleri	21
2.9. Model Eğitiminde Kullanılan ESA Hiper Parametreler	22
2.9.1. Eğitim Oranı	22
2.9.2. Doğrulama Oranı	23
2.9.3. Eğitim Tur Sayısı	23
2.9.4. Paket Boyutu	23
2.9.5. Öğrenme Oranı	23
2.9.7. Aktivasyon Fonksiyonları	26
2.9.8. Optimizasyon Fonksiyonları	27
ÜÇÜNCÜ BÖLÜM	31
MATERYAL VE YÖNTEM	31
3.1. Araştırmanın Yöntemi	31
3.2. Veri Setlerinin Oluşturulması ve Sınıflanması	32
3.3. Veri Ön İşleme Aşamaları	34
3.3.1. Gri Tonlamalı Görüntü (2D)' ye Dönüştürme	34
3.3.2. Görüntü Yeniden Boyutlandırma	34
3.3.3. Maskeleme ve Kırpma	35
3.3.4. Görüntüye Kontrast ve Bulanıklaştırma (Gaussian Blur) Uygulama	35
3.3.5. Dairesel Kırpma	36
3.4. Araştırmada Kullanılan Kütüphaneler	37
DÖRDÜNCÜ BÖLÜM	39
BULGULAR VE SONUÇ	39
4.1. Deneyisel Çalışma Ortamı	39

4.2. Sabit Öğrenme Oranı– ReLU, Leaky ReLU ve ELU-SGD Analiz Sonuçları	40
4.3. Öğrenme Oranı Planlaması ve OneCycleLR – ReLU, Leaky ReLU ve ELU-SGD Analiz Sonuçları	44
4.4. ReLU, Leaky ReLU ve ELU-Momentum Analiz Sonuçları	50
SONUÇ	56
KAYNAKÇA.....	58
AKSARAY ÜNİVERSİTESİ TEZ DEĞERLENDİRME FORMU.....	65



TABLÖLAR LİSTESİ

Tablo 1. Karışıklık Matrisi	21
Tablo 2. Aktivasyon Fonksiyonları	27
Tablo 3. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının 1e-2 Öğrenme Oranına Göre Doğrulama ve Kayıp Grafikleri.....	40
Tablo 4. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının 1e-3 Öğrenme Oranına Göre Doğrulama ve Kayıp Grafikleri.....	41
Tablo 5. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının 1e-4 Öğrenme Oranına Göre Doğrulama ve Kayıp Grafikleri.....	42
Tablo 6. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının Sabit Öğrenme Oranlarına Göre Performans Analizi.....	43
Tablo 7. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının Cosine Annealing Yöntemine Göre Doğrulama ve Kayıp Grafikleri.....	44
Tablo 8. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının OneCycleLR Yöntemine Göre Doğrulama ve Kayıp Grafikleri.....	45
Tablo 9. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının ReduceLRonPlateau (Factor: 0,1) Yöntemine Göre Doğrulama ve Kayıp Grafikleri.....	46
Tablo 10. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının ReduceLRonPlateau (Factor: 0,2) Yöntemine Göre Doğrulama ve Kayıp Grafikleri.....	47
Tablo 11. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının ReduceLRonPlateau (Factor: 0,5) Yöntemine Göre Doğrulama ve Kayıp Grafikleri.....	48
Tablo 12. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının ReduceLRonPlateau- Cosine Annealing- OneCycleLR'e Göre Performans Metrikleri	49
Tablo 13. ReLU, Leaky ReLU ve ELU-Momentum Algoritmalarının Doğrulama ve Kayıp Grafikleri	51
Tablo 14. ReLU, Leaky ReLU ve ELU-Momentum Algoritmalarının Doğrulama ve Kayıp Grafikleri	52
Tablo 15. ReLU, Leaky ReLU ve ELU-Momentum Algoritmalarının Performans Metrikleri.....	53

ŞEKİLLER LİSTESİ

Şekil 1. Diyabetik Retinopati Semptomlarını Gösteren Fundus Görüntüleri.....	7
Şekil 2. Diyabetik Retinopati Şiddet Dereceleri	8
Şekil 3. DR Normal Retina Fundus Görüntüsü.....	8
Şekil 4. Hafif DR Fundus Görüntüsü	9
Şekil 5. Orta DR Fundus Görüntüsü	9
Şekil 6. Şiddetli DR Fundus Görüntüsü	10
Şekil 7. DR Proliferatif Fundus Görüntüsü	10
Şekil 8. Bir Sinir Hücresinin Matematiksel Modeli	11
Şekil 9. Tek Gizli Katmanlı ve Çok Katmanlı Sinir Ağı Yapısı	12
Şekil 10. Çok Katmanlı Yapay Sinir Ağ Model Örneği.....	13
Şekil 11. ESA Yapısı.....	15
Şekil 12. Evrişim İşlemi	16
Şekil 13. ResNet Mimari Yapısı	16
Şekil 14. Ortalama Havuzlama.....	17
Şekil 15. Maksimum Havuzlama	17
Şekil 16. Tam Bağlantılı Katman	18
Şekil 17. Transfer Öğrenme Modeli.....	19
Şekil 18. ResNet34 Mimarisi	20
Şekil 19. Diyabetik Retinopati Tespiti için Kurulan Mimari	32
Şekil 20. DR Evreleri	32
Şekil 21. DR Sınıf Dağılım Grafiği 1	33
Şekil 22. DR Sınıf Dağılım Grafiği 2.....	33
Şekil 23. RGB ve Gri Tonlamalı Fundus Görüntüsü	34
Şekil 24. DR Görüntü Kırpma.....	35
Şekil 25. Gaussian Blur Uygulanmış Fundus Görüntüsü.....	35
Şekil 26. Dairesel Kırpma ve Gaussian Bulanıklığı Uygulanmış Fundus Görüntüsü	36

Şekil 27. 7915 Veri Seti ReLU-Momentum Karışıklık Matrisi	54
Şekil 28. 7915 Veri Seti Leaky ReLU-Momentum Karışıklık Matrisi	55



KISALTMALAR

Adagrad:	Adaptive Gradient Algorithm
Adam:	Adaptive Moment Estimation
BVLC:	Berkeley Vision and Learning Center
CNN/ESA:	Convolutional Neural Networks / Evriřimsel Sinir Aęları
CPU:	Central Processing Unit
CSOA:	Crow Search Optimization Algorithm
DM:	Diabetes Mellitus-řeker Hastalıęı
DMÖ:	Diyabetik Maköler Ödem
DNN:	Deep Neural Network
DOI:	Digital Object Identifier
DR:	Diabetic Retinopathy-Diyabetik Retinopati
ELU:	Exponential Linear Activation Function
FC:	Fully Connected Layer
FN:	False Negative
FP:	False Positive
GPU:	Graphics Processing Unit
HRD:	Heart Rate Disorder
Leaky ReLU:	Leaky Rectified Linear Unit
Nadam:	Nesterov-accelerated Adaptive Moment Estimation
NIH:	National Institutes of Health
NPDR:	Nonproliferative Diabetic Retinopathy

OCT:	Optical Coherence Tomography
PDR:	Proliferative Diabetic Retinopathy
PRELU:	Parametric Rectified Linear Unit
ReLU:	Rectified Linear Activation Function
RGB:	Red-Green-Blue
RMSprop:	Root Mean Square Propagation
ROP:	Prematüre Retinopatisi
SGD:	Stochastic Gradient Descent
Tanh:	Tanjant Hiperbolik
TN:	True Negative
TP:	True Positive
TPU:	Tensor Processing Unit
VEGF:	Vascular Endothelial Growth Factor
YBMD:	Yaşa Bağlı Makula Dejenerasyonu
YSA:	Yapay Sinir Ağı

GİRİŞ

Diyabetin sık görülen ve potansiyel olarak yaşamı tehdit eden bir sonucu, diyabetik retinopati (DR) olarak adlandırılır (Singh ve Tripathi, 2010, s. 18-19). Bu hastalığın erken teşhisi, hastaların retinalarının normal fonksiyonunu geri kazanmasına yardımcı olur ve körlüğü önler (Saleh ve Eswaran, 2012, s. 2). Bununla birlikte, DR'yi tanımlamaya yönelik geleneksel manuel yöntemler, çok miktarda veri nedeniyle zaman alıcıdır ve sıklıkla yanlış sınıflandırmalara neden olur (Alyoubi vd., 2020, s. 1-2). Tıbbi görüntülerde anormal örnekler normal örneklerle göre daha az görülür ve çoğu zaman değerlidir; bu nedenle dengesiz verileri incelemek çok önemlidir (Chen vd., 2021, s. 2-4). Retinopati şiddetinin belirlenmesi, kapsamlı mesleki bilgi ve deneyim gerektirir. Hekimin deneyimine bağlı olarak aynı veri setinin yorumları farklılık gösterebilir ve bu da hatalara neden olabilir. Bu nedenle, görüntülerin sayısallaştırılması önem arz etmektedir. Ayrıca, makine öğrenmesi ve derin öğrenme teknikleri kullanılarak teşhisler doğrulanabilmekte ve gerekli tedaviler net bir şekilde belirlenebilmektedir. Bu teknikler, doktorların doğru tanı koymasına ve lezyonları tanımlamasına yardımcı olabilir. Özellikle derin öğrenme algoritmaları, büyük veri setleri üzerinde eğitilerek retinopati gibi karmaşık hastalıkların tanısında yüksek doğruluk oranları sağlayabilmektedir. Bu sayede, retinopati şiddetinin daha objektif ve tutarlı bir şekilde belirlenmesi mümkün hale gelmektedir (Ting vd., 2019, s. 1-2; Bellemo vd., 2019, s. 2-12).

Hao vd., (2020) çalışmalarında, araştırmacılar tarafından yaygın olarak kullanılan çeşitli aktivasyon fonksiyonları incelenmekte ve belirli sinir ağı modelleri ile birleştirilerek niteliksel karşılaştırma sonuçlarını sunmuşlardır (Hao vd., 2020). Örneğin, LeNet modeli kullanılarak MNIST veri kümesi üzerinde yapılan çalışmalarda, PReLU aktivasyon fonksiyonu %98,724 ile en yüksek doğruluğa ulaşmış, bunu %98,708 doğruluk oranı ile Swish takip etmiştir. Cifar-10 veri seti üzerinde yapılan deneylerde ise ELU aktivasyon fonksiyonu %64,580 ile en yüksek doğruluğu elde etmiş, ardından %64,455 ile Mish gelmiştir. VGG16 modeli kullanıldığında ReLU aktivasyon fonksiyonu %90,226 doğruluk oranı ile en iyi performansı göstermiş, PReLU ise %90,197 ile onu takip etmiştir. ResNet50 modeli ile yapılan çalışmalarda ise ELU %89,943 doğruluk oranı ile en yüksek performansı sergilerken, Mish %89,780 doğruluk oranı ile ikinci sırada yer almıştır. Bu bulgular, farklı aktivasyon fonksiyonlarının farklı sinir ağı mimarileri ve veri kümeleri üzerinde değişken performans sergilediğini göstermektedir. Dolayısıyla, sinir ağı

modellerinin performansını optimize etmek için doğru aktivasyon fonksiyonunun seçimi kritik öneme sahiptir.

Bu çalışmada, göz sağlığını tehdit eden ciddi bir hastalık olan DR tespiti için derin öğrenme tabanlı sınıflandırma yöntemleri ele alınmıştır. Literatürde, DR gibi retina hastalıklarının erken teşhisi ve sınıflandırılması, körlük gibi geri dönüşü olmayan sonuçların önüne geçmek için büyük önem taşımaktadır. Fundus göz görüntülerinin kullanıldığı bu tür çalışmalar, sağlık alanında klinik karar destek sistemlerinin geliştirilmesine katkı sağlamaktadır. Ancak, literatürde mevcut olan çalışmaların çoğu belirli veri setleri üzerinde sınırlı kalmakta ve hiper parametre optimizasyonu gibi modelin başarısını doğrudan etkileyen faktörlere yeterince yer verilmemektedir.

Bu çalışmanın amacı, DR teşhisinde kullanılan Evrişimsel Sinir Ağı (ESA) modellerinde hiper parametrelerin sınıflandırma performansı üzerindeki etkilerini kapsamlı bir şekilde incelemektir. Bu bağlamda, kamuya açık "Aptos Blindness Detection" ismiyle Kaggle platformunda yayınlanan ve 3662 örnekten oluşan veri seti ile 7915 görselden oluşan özgün bir veri seti kullanılarak iki farklı veri seti üzerinde karşılaştırmalı bir analiz gerçekleştirilmiştir. Literatüre katkı sağlamak amacıyla, hiper parametrelerin her iki veri seti üzerindeki etkileri ayrı ayrı değerlendirilmiş ve farklı veri artırma teknikleri, optimizasyon algoritmaları, öğrenme oranı stratejileri gibi faktörlerin performansa olan katkıları detaylı olarak incelenmiştir.

Çalışmada ele alınan hiper parametreler arasında sabit öğrenme oranı, öğrenme oranı planlaması, aktivasyon fonksiyonları, L2 düzenleme, veri artırma teknikleri ve optimizasyon algoritmaları bulunmaktadır. Bu parametrelerin her birinin ESA tabanlı modellerin sınıflandırma doğruluğu üzerindeki etkisi deneysel olarak analiz edilmiştir. Ayrıca, görüntülerin sınıflandırma başarısını artırmak amacıyla, çeşitli ön işleme adımları uygulanmıştır. Bu adımlar arasında gri tonlama, yeniden boyutlandırma, maskeleme, Gauss bulanıklığı ve dairesel kırpmaya gibi teknikler yer almaktadır. Bu sayede, veri setlerinin kalitesini ve çeşitliliğini artırarak modelin genelleme yeteneği güçlendirilmiştir.

Transfer öğrenme yaklaşımı kullanılarak ResNet34 mimarisi üzerine yapılan çalışmalar da literatürde önemli bir yer tutmaktadır. Bu çalışmada, ResNet34 mimarisinin son katmanı değiştirilerek, farklı sınıflar arasında daha başarılı bir sınıflandırma elde edebilmek için transfer öğrenme yöntemi kullanılmıştır. Böylece, modelin daha önce eğitildiği büyük veri setlerinden edindiği bilgi birikimi, DR teşhisine uyarlanarak daha etkili sonuçlar elde edilmesi amaçlanmıştır.

Çalışmanın literatüre katkısı, mevcut yöntemlerin ötesine geçerek farklı hiper parametrelerin, veri artırma tekniklerinin ve ön işleme adımlarının sınıflandırma performansı üzerindeki etkilerini detaylı olarak sunmasıdır. Bu kapsamlı analiz, göz sağlığı ile ilgili klinik karar destek sistemlerinin geliştirilmesinde yeni bir bakış açısı sunmakta ve DR gibi ciddi hastalıkların teşhisinde daha doğru ve güvenilir yöntemler geliştirilmesine olanak tanımaktadır. Sonuç olarak, bu çalışma, hiper parametre optimizasyonunun ve görüntü işleme tekniklerinin klinik uygulamalarda daha etkin kullanımını teşvik ederek, göz hastalıklarının erken teşhisi ve sınıflandırılmasında önemli bir ilerleme sağlamayı hedeflemektedir.



BİRİNCİ BÖLÜM

KURAMSAL TEMELLER

Bu bölümde, araştırmanın problemi, amacı ve önemi ayrıntılı olarak ele alınacak ve bu bağlamda çalışmanın izleyeceği metodolojik yaklaşım ve yön hakkında bilgi verilecektir. Öncelikle, DR teşhisinde yapay zekâ ve derin öğrenme yöntemlerinin sınıflandırma başarısını artırmaya yönelik problemlere çözüm önerileri sunulacaktır. Sonraki bölümlerde, çalışmanın teorik ve pratik katkıları vurgulanacak, izlenecek yöntemler ve kullanılan veri setlerinin analizi, hiper parametre optimizasyonu ve ön işleme adımlarının etkilerini incelemek üzere nasıl yapılandırılacağı detaylandırılacaktır.

1.1. Araştırmanın Problemi

Bu araştırmanın problemi, DR gibi ciddi bir göz hastalığının erken teşhis ve sınıflandırmasında yapay zekâ tabanlı yöntemlerin optimizasyonuna odaklanmaktadır. Mevcut teşhis süreçlerinin zaman alıcı ve uzman gerektirmesi nedeniyle, büyük veri setleri üzerinde etkili ve doğru bir şekilde çalışan otomatik sistemlerin geliştirilmesi gerekmektedir. Ancak, derin öğrenme modellerinin performansı, modelin yapılandırmasında kullanılan hiper parametreler, veri ön işleme adımları ve optimizasyon stratejilerine bağlı olarak büyük ölçüde değişiklik gösterebilmektedir. Bu çalışmanın temel problemi, farklı hiper parametrelerin, ön işleme adımlarının ve transfer öğrenme yöntemlerinin fundus göz görüntülerinin sınıflandırma başarısı üzerindeki etkilerini değerlendirerek, DR teşhisinde daha doğru ve genellenebilir bir yapay zekâ modelinin nasıl oluşturulabileceğini belirlemektir.

1.2. Araştırmanın Amacı

Bu çalışmanın temel amacı, DR teşhis etmek için yapay zekâ tabanlı bir sınıflandırma modeli geliştirmek ve bu modelin etkinliğini değerlendirmektir. DR teşhisi için erken teşhis ve etkili tedavi önemli bir rol oynamaktadır ve bu çalışma, yapay zekâ teknolojisinin bu alandaki

potansiyelini keşfetmek ve klinik uygulamalarda kullanılabilirliğini değerlendirmek amacıyla gerçekleştirilmiştir. Araştırma, derin öğrenme algoritmaları ve derin sinir ağları kullanarak DR görüntülerinden anlamlı özelliklerin çıkarılması ve sınıflandırma modellerinin oluşturulması için bir yöntem sunmaktadır. Ayrıca ELU, Leaky ReLU ve ReLU gibi aktivasyon fonksiyonlarının yanı sıra SGD, Momentum gibi optimizasyon algoritmaları, öğrenme oranı belirleme yöntemlerinden olan sabit öğrenme oranı, öğrenme oranı planlaması (Cosine Annealing, ReduceLROnPlateau), One Cycle Policy (OneCycleLR), L2 Düzenleme (Regularization), Veri Artırma (Data Augmentation) hiper parametrelerinin karşılaştırmalı analizi yapılarak modelin performansı değerlendirilmiştir.

1.3. Araştırmanın Önemi

Diyabetik retinopati, diyabetik bireylerde görme kaybının önde gelen nedenlerinden biridir ve erken teşhis edilmezse ciddi sonuçlara yol açabilir. Bu nedenle, diyabetik retinopatiyi tespit etmek için hassas ve etkili bir teşhis yöntemi geliştirmek klinik pratikte büyük öneme sahiptir. Yapay zekâ tabanlı sınıflandırma modelleri, büyük veri setlerini analiz ederek hızlı ve doğru teşhisler yapabilme potansiyeline sahiptir. Bu çalışma, DR teşhisinde yapay zekâ teknolojisinin kullanılabilirliğini ve etkinliğini araştırmak amacıyla bu alandaki bilgi ve uygulama boşluklarını doldurmayı amaçlamaktadır.

İKİNCİ BÖLÜM


KAVRAMSAL ÇERÇEVE VE LİTERATÜR TARAMASI

Bu bölümde, DR teşhisinde kullanılan yapay sinir ağları, derin öğrenme algoritmaları ve transfer öğrenme teknikleri ayrıntılı bir şekilde ele alınacak ve bu yöntemlerin fundus göz görüntülerinin analiz ve değerlendirilmesindeki rolü üzerinde durulacaktır. Özellikle, derin öğrenme tabanlı yaklaşımların, karmaşık görsel desenlerin otomatik olarak çıkarılması ve sınıflandırılması süreçlerindeki etkinliği vurgulanacaktır. Transfer öğrenmenin büyük veri setleri gereksinimini azaltarak sınırlı sayıda veri ile daha yüksek doğruluk elde edilmesini nasıl mümkün kıldığı açıklanacaktır. Ayrıca, literatürdeki önde gelen çalışmalar incelenerek, diyabetik retinopatide kullanılan algoritmalarla ilgili çalışmalara yer verilecektir.

2.1. Diyabetik Retinopati Hastalığı

Diyabetik retinopati hastalığı, diabetes mellitusun (DM) en yaygın karşılaşılan komplikasyonlarından biridir. Uzun zamandır mikrovasküler bir hastalık olarak kabul edilmektedir. DR tanısı mikrovasküler lezyonların tespitine dayanır. DR'nin tedavisi zor olmaya devam etmektedir. Anti-vasküler endotelyal büyüme faktörü (VEGF) tedavisinin ortaya çıkışı, DR hastalarında dikkate değer klinik faydalar göstermiştir; ancak hastaların çoğunda klinik olarak anlamlı görsel iyileşme sağlanamamıştır. Bu nedenle, yeni tedavilerin geliştirilmesine acil ihtiyaç vardır (Wang ve Amy, 2018, s. 1). DR başlangıçta asemptomatiktir ve bu nedenle hastaların çoğu, görme yetilerini duygusal olarak kısıtlamadığı sürece durumun farkında değildir. Bu nedenle, daha fazla zorluktan kaçınmak ve hastalığın ilerlemesini kontrol etmek için DR'nin önceden ve tutarlı bir şekilde taranması esastır. DR'nin en önemli semptomlarından biri göz dibi görüntülerinde görülebilen eksudalardır (Dutta vd., 2018, s. 90). Fundus görüntüsü, monoküler bir kamera tarafından 2 boyutlu bir düzlemde çekilen fundus projeksiyonudur. OCT görüntüleri ve anjiyografiler gibi diğer göz taramalarının aksine, fundus görüntüleri invazif olmayan ve uygun maliyetli bir şekilde elde edilebilir, bu da onları büyük ölçekli tarama için daha uygun hale getirir (Li vd., 2021, s. 1). Fundus görüntülerinde, optik


disk, optik kap, makula, fovea, kan damarları ve mikroanevrizmalar, kanamalar, sert eksüdalar ve yumuşak eksüdalar gibi diyabetik retinopati ile ilişkili çeşitli önemli biyobelirteçler tespit edilebilir. Bu biyobelirteçler, glokom, diyabetik retinopati, yaşa bağlı makula dejenerasyonu, katarakt, prematüre retinopatisi ve diyabetik maküler ödem gibi çeşitli oftalmolojik hastalıkların teşhisinde kritik bir rol oynar. Şekil 1’de DR semptomlarını gösteren fundus görüntüleri gösterilmiştir.



Şekil 1. Diyabetik Retinopati Semptomlarını Gösteren Fundus Görüntüleri

2.2. Diyabetik Retinopati Seviyeleri


Diyabetik hastalık gelişimsel seyrinde göz fundusunda polimorfik değişikliklere yol açarak hastaların çoğunda görme fonksiyonunun ardışık olarak ilerlemesine ve önemli ölçüde bozulmasına neden olur. DR, hastalığın ilerlemesine ve retina üzerindeki hasarın derecesine göre farklı şiddet seviyelerine ayrılmıştır. Bu seviyeler, retina üzerindeki hasarın ciddiyetine bağlı olarak sınıflandırılır ve dört ana aşamada incelenir. Her seviyenin kendine özgü klinik özellikleri vardır. Şekil 2’ de görüldüğü üzere DR seviyeleri şiddet derecesine göre verilmiştir.



Şekil 2. Diyabetik Retinopati Şiddet Dereceleri

2.2.1. Sağlıklı DR Görüntüsü


Retina tamamen sağlıklıdır, herhangi bir mikro-anevrizma, kanama veya eksuda yoktur. Diyabetik Retinopati belirtisi yoktur. Retina damarları normal ve sağlıklıdır. Sağlıklı DR görüntüsü Şekil 3’te verilmiştir.



Şekil 3. DR Normal Retina Fundus Görüntüsü

2.2.2. Hafif DR Görüntüsü


Arka plan retinopatisi olarak adlandırılan DR'nin ilk aşaması olan hafif, proliferatif olmayan diyabetik retinopati (NPDR) sırasında retinanın küçük kan damarlarında mikroanevrizma adı verilen küçük şişkinlikler gelişir. Bu çıkıntılar retina içine küçük kan sızıntılarına neden olabilir (Shakibania vd., 2024, s. 1). Orta derecede NPDR, kanamalar, mikro anevrizmalar ve sert eksudaların varlığı veya oluşumunu gösterir (Mansour, 2018, s. 42). Şekil 4’te görüldüğü üzere mikroanevrizma ve noktasal kanamaların olduğu Hafif DR fundus görüntüsü verilmiştir.



Şekil 4. Hafif DR Fundus Görüntüsü

2.2.3. Orta DR Görüntüsü

Hastalık ilerledikçe retinayı besleyen kan damarları şişebilir ve deforme olabilir. Ayrıca kan taşıma yeteneklerini de kaybedebilirler. Her iki durum da retinanın görünümünde karakteristik değişikliklere neden olur, makulanın şişmesine katkıda bulunabilir ve ayrıca daha fazla kılcal kan sızıntısına veya eksüdaya neden olabilir (Pratt, 2020, s. 10-30). Kan damarlarında ciddi hasarlar ve leke oluşumunu gösteren Orta DR görüntüsü Şekil 5’te gösterilmiştir.




Şekil 5. Orta DR Fundus Görüntüsü

2.2.4. Şiddetli DR Görüntüsü

Retinopatinin bu aşamasında, hastalığın şiddeti, kanın retinanın birçok kan damarından geçmesini veya bu damarlara girmesini engeller, bu da kanın retinanın çeşitli bölümlerine ulaşmasını önler. Bu durum ortaya çıktığında, gözün arkasındaki retina yeni kan damarları üretmeye başlar. Ancak, bu yeni damarlar sahip oldukları tuhaf görünüm nedeniyle anormal olarak belirlenir. Bu durum, kılcal damarların yetersizliği olarak adlandırılır. Sonuç olarak, kan


damarlarının tıkanmasıyla hasarlı retina, retinanın arkasında tehlikeli yeni kan damarlarının oluşmasına ve çoğalmasına yol açar, bu da kişinin görüşünün bulanıklaşmasına neden olur (Li ve Li, 2013, s. 454). Kan damarlarında yaygın tıkanmalar ve leke oluşumunu gösteren Şiddetli DR görüntüsü Şekil 6’da verilmiştir.



Şekil 6. Şiddetli DR Fundus Görüntüsü

2.2.5. Proliferatif DR Görüntüsü


PDR (proliferatif diyabetik retinopati), DR'nin ileri bir aşamasıdır; bu aşamada retinanın içindeki kan damarları tıkanmaktadır. Sonuç olarak, retina beslenmeden mahrum kalır ve bu nedenle beslenme için sinyaller gönderir; dolayısıyla retina içinde yeni kan damarları büyür. Yeni damarların doğması zararlı olmasa da kırılgan yapıları nedeniyle sızıntıya, görme kaybına ve hatta körlüğe yol açabilir (Leeza ve Farooq, 2019, s. 523). Hafif NPDR, erken evrelerde kontrol altına alınmazsa zamanla PDR'ye dönüşmektedir. Şekil 7’de gösterildiği üzere retina ve vitreus içinde anormal ve kırılgan yeni kan damarları oluşumunu gösteren Proliferatif DR görüntüsü verilmiştir.



Şekil 7. DR Proliferatif Fundus Görüntüsü

2.3. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), insan beynindeki biyolojik sinir ağlarının çalışma şekline esinlenen, birbirine bağlı düğümlerden veya nöronlardan oluşan hesaplama modelleridir (LeCun vd., 2015, s. 436). Girdi verilerini almak için bir girdi katmanı, hesaplamanın yapıldığı bir veya daha fazla gizli katman ve sonuçları üretmek için bir çıktı katmanından oluşurlar (Goodfellow vd., 2016, s. 19). YSA'lardaki nöronlar, giriş sinyallerini alarak, doğrusal bir dönüşüm uygulayarak (girişlerin ağırlıklı toplamı) ve ardından bir çıktı üretmek için sonucu bir aktivasyon fonksiyonundan geçirerek hesaplamalar yapar (Rosenblatt, 1958, s. 387). Nöronlar arasındaki bağlantılar, eğitim sırasında gradyan iniş gibi optimizasyon algoritmaları kullanılarak ayarlanan ilişkili ağırlıklara sahiptir (Rumelhart vd., 1986, s. 533). Aşağıda görülen Şekil 8'e bakıldığında bir YSA modelinin çalışma mantığı şematize edilmiştir.



Şekil 8. Bir Sinir Hücresinin Matematiksel Modeli

Şekil 8'de dendritler boyunca taşınan sinyaller, her biri bir ağırlık değeri ile ilişkilendirilmiş olan giriş değerleriyle (örneğin, x_0) nörona iletilir. Bu sinyaller, dendritlere giren başka bir nörondan da gelebilir. Giriş değeri (x_0) ve dendritteki ağırlık (w_0) çarpımı ($x_0 \cdot w_0$) nörona iletilir. Nöron, tüm dendritlerden gelen ağırlıklı giriş çarpımlarını toplar. Bu işlem, matematiksel olarak ağırlıklı toplama (weighted summation) olarak bilinir.

Nöronun hesapladığı toplam giriş değeri, aşağıdaki şekilde ifade edilir:


$$z = \sum_i (x_i \cdot w_i) + b$$

Burada, w_i her bir girişin ağırlığı, x_i her bir giriş değeri ve b bias terimidir. Bu toplama işlemi, nöronun tüm dendritlerinden gelen sinyallerin ağırlıklı toplamını ve bias terimini içermektedir. Bu ağırlıklı toplam değeri (z), aktivasyon fonksiyonu olarak adlandırılan bir fonksiyona uygulanır. Aktivasyon fonksiyonu, nöronun çıkışını belirleyen doğrusal olmayan bir dönüşüm sağlar. Aktivasyon fonksiyonu f , aşağıdaki gibi ifade edilir:

$$y = f(z)$$

Burada, y nöronun çıkış değerini temsil eder. Bu çıkış değeri, nihai bir çıktı olabileceği gibi, başka bir nöronun girişi olarak da kullanılabilir. Böylelikle, basit bir matematiksel model elde edilmiş olur.

YSA kullanım alanı çok çeşitli olmakla beraber, görüntü ve konuşma tanıma, doğal dil işleme, tıbbi teşhis ve otonom araçlar gibi pek çok alanda kullanılmaktadırlar (LeCun vd., 2015, s. 436). Sağlık alanında, YSA'lar tıbbi görüntülerden hastalıkları teşhis etmek ve hasta sonuçlarını tahmin etmek için uygulanmıştır (Esteva vd., 2017, s. 77). Ayrıca, finans alanında, YSA'lar borsa tahmini ve risk değerlendirmesi için kullanılmakta, çok yönlülüklerini ve geniş uygulanabilirliklerini göstermektedir (Zhang, 2003, s. 45). Bu çalışmalar, çeşitli bilimsel ve pratik alanlarda YSA'ları içeren önemli etkiyi ve devam eden araştırmaları vurgulamaktadır. Şekil 9'da tek ve çok katmanlı sinir ağı yapısı görülmektedir.




Şekil 9. Tek Gizli Katmanlı ve Çok Katmanlı Sinir Ağı Yapısı

2.4. Derin Öğrenme

Bilgisayar Bilimcileri, makine öğrenimi alanında 1950'lerden beri çaba sarf etmektedir. Son birkaç on yıldan beri makine öğrenimi alanındaki ilerlemeler için muazzam çabalar sarf edilmektedir. Bu da makinelerden daha yüksek beklentilere yol açmaktadır. Derin öğrenme bu yönde bir girişimdir (Shinde ve Shah, 2018, s. 1). Derin öğrenme, çok katmanlı (tipik olarak

üçten fazla) yapay sinir ağları kullanan bir makine öğrenimi alt kümesidir. Derin öğrenme algoritmaları, genellikle göreve özgü programlama olmaksızın örnekleri dikkate alarak görevleri yerine getirmeyi öğrenir. Bilgisayarla görme ve doğal dil işleme gibi çeşitli alanlarda olağanüstü performans göstermişlerdir (Schmidhuber, 2015, s. 1). Aşağıda Şekil 10'da görüldüğü üzere çok katmanlı bir yapıda veriler giriş katmanından girer daha sonra ara katmanlarda veriler işlenir ve karmaşık ilişkiler kurulur son olarak sonuçların üretilmesi için çıkış katmanına iletilmektedir.



Şekil 10. Çok Katmanlı Yapay Sinir Ağ Model Örneği

Derin öğrenme kütüphaneleri, model oluşturma, otomatik farklılaştırma ve optimizasyon için önceden uygulanmış, optimize edilmiş algoritmalar sağlayarak derin sinir ağlarının geliştirilmesini, eğitimi ve dağıtımını basitleştiren yazılım çerçeveleridir. Çeşitli sinir ağı mimarilerini destekler, GPU'ları ve TPU'ları kullanarak donanım hızlandırmayı kolaylaştırır ve model dağıtımını ve diğer makine öğrenimi iş akışlarıyla entegrasyona yönelik araçlar içerir. Bu kitaplıklar, araştırmacıların ve geliştiricilerin karmaşık modelleri verimli bir şekilde denemelerine, performansını optimize etmelerine ve modelleri üretim ortamlarına dağıtmalarına olanak tanır (TensorFlow Developers, 2023).

Caffe: Berkeley Vision and Learning Center (BVLC) tarafından geliştirilen Caffe hız, modülerlik ve ifade üzerine odaklanan bir derin öğrenme çerçevesidir. Özellikle görüntü sınıflandırma görevleri için popülerdir (Jia vd., 2014, s. 675-678).

TensorFlow: Google Brain tarafından geliştirilen TensorFlow, makine öğrenimi ve derin öğrenme görevleri için yaygın olarak kullanılan açık kaynaklı bir kütüphanedir. Sinir ağları

oluşturmak ve eğitmek için esnek araçlar sağlar ve hem araştırma hem de üretim ortamlarını destekler (TensorFlow Developers, 2023).

PyTorch: Facebook'un AI Araştırma laboratuvarı tarafından geliştirilen PyTorch, onu araştırma amaçları için sezgisel ve esnek kılan dinamik hesaplama grafiğiyle tanınır. Aynı zamanda basitliği ve verimliliği nedeniyle üretim ortamlarında da ilgi görüyor (Paszke vd., 2019).


MXNet: Apache tarafından geliştirilen açık kaynaklı bir derin öğrenme çerçevesi olan MXNet, verimli, esnek ve ölçeklenebilir olacak şekilde tasarlanmıştır. Python, C++ ve R dahil olmak üzere çeşitli dilleri destekler (Chen vd., 2015).

Theano: Theano, çok boyutlu dizileri içeren matematiksel ifadelerin verimli bir şekilde tanımlanmasına, optimize edilmesine ve değerlendirilmesine olanak tanıyan bir Python kütüphanesidir. Genellikle derin öğrenme araştırma çerçeveleri için arka uç olarak kullanılır (Al-Rfou vd., 2016).

Bu çalışmada sağladığı kolaylık ve hem CPU hem de GPU üzerinde entegre çalışabilme özelliğinden dolayı PyTorch kütüphanesi tercih edilmiştir. Veri seti üzerinde yapılan tüm eğitimler GPU üzerinden gerçekleştirilmiştir.

2.5. Evrişimli Sinir Ağları (ESA)

Evrişimli Sinir Ağı, görsel verileri işlemek ve analiz etmek için özel olarak tasarlanmış bir tür derin sinir ağıdır. ESA'lar, bir dizi evrişimsel katman aracılığıyla özelliklerin uzamsal hiyerarşilerini otomatik ve uyarlanabilir olarak öğrenecek şekilde yapılandırılmıştır. Verideki uzamsal ilişkileri ve kalıpları yakalama yeteneklerinden dolayı görüntü sınıflandırması, nesne algılama ve görüntü segmentasyonu gibi görevler için oldukça etkilidirler (Krizhevsky vd., 2012, s. 1097-1105). Bir ESA tipik olarak evrişimli katmanlar, havuzlama katmanları ve tamamen bağlı katmanlar dahil olmak üzere çeşitli katman türlerinden oluşur (Goodfellow vd., 2016, s. 332-336). Şekil 11'de görüldüğü üzere göz fundus görüntüsündeki pikseller giriş katmanında işlenmiş ardından gizli katmanlar aracılığıyla beş farklı DR seviyesine (Normal, Hafif, Orta, Şiddetli, Proliferatif) göre ayrılarak sınıflandırılmıştır.



Şekil 11. ESA Yapısı


2.5.1. Evrişimli Sinir Ağları Giriş Katmanı

Evrişimli Sinir Ağının giriş katmanı, ham giriş verilerini alan ve bunu ağıdaki sonraki katmanlar tarafından işlenmek üzere hazırlayan ilk katmandır. Bu katman, girdinin uzamsal yapısını koruyarak görüntüler gibi çok boyutlu verileri işlemek için tasarlanmıştır (Arel vd., 2010, s. 333-334). Giriş verilerinin tek boyutlu bir vektör halinde düzleştirildiği geleneksel sinir ağlarından farklı olarak ESA'lar, giriş katmanındaki verilerin yapısını korur; bu, pikseller arasındaki ilişkilerin önemli bilgiler taşıdığı görüntüleri içeren görevler için çok önemlidir (Gu vd., 2018, s. 21-22).

2.5.2. Evrişim Katmanı

Evrişimli katmanlar, ESA'nın temel yapı taşlarıdır. Bu katmanlar, girişin kenarlar, dokular ve desenler gibi çeşitli yönlerini yakalayan özellik haritalarını çıkarmak için filtreleri (veya çekirdekleri) kullanarak giriş verileri üzerinde evrişim işlemlerini gerçekleştirir. Bu filtreleri uygulayarak evrişimli katmanlar, pikseller arasındaki ilişkileri korurken yerel özelliklerin tespit edilmesine yardımcı olur (Albawi vd., 2018, s. 1-3).

Evrişim işlemini tipik olarak, ağa doğrusal olmamayı tanıtan ve ağın daha karmaşık modelleri öğrenmesine olanak tanıyan Düzeltilmiş Doğrusal Birim (ReLU) gibi bir aktivasyon fonksiyonunun uygulanması takip eder (Nair ve Hinton, 2010, s. 807-814).



Şekil 12. Evrişim İşlemi


Şekil 12’de görüldüğü üzere evrişim işlemi sırasında filtre, belirtilen dolgu (padding) ve adım (stride) değerleriyle giriş görüntüsüne uygulanır. Filtre, adıma (stride) göre giriş görüntüsü üzerinde kayar ve her konumda, filtrenin nokta çarpımı ve karşılık gelen giriş bölgesi hesaplanır. Dolgu (padding), filtrenin, sınırları da dahil olmak üzere giriş görüntüsünün tamamını kapsayabilmesini sağlarken, adım (stride), ortaya çıkan özellik haritasının çözünürlüğünü ve boyutunu kontrol eder (O’Shea ve Nash, 2015, s. 1-2). Şekil 13’te ResNet derin öğrenme model mimarisinde, modelin derinliğine göre 18, 34, 50, 101 ve 152 farklı katman boyutları ve parametreleri gösterilmiştir.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
conv2_x	56×56	3×3 max pool, stride 2				
		$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

Şekil 13. ResNet Mimari Yapısı

2.5.3. Havuzlama Katmanı

Havuzlama işleminin temel amacı, her filtrenin çıktısını toplayan bir işlevi kullanarak cümlelerin en temsili özelliklerini çıkarmaktır (Suarez ve Segura, 2018, s. 44). ResNet34 modelinde Evrişimsel katmanlar arasına havuzlama katmanları yerleştirilmektedir. Havuzlama katmanları, özellik haritalarındaki değerleri indirgeyerek modelin karmaşıklığını ve parametre sayısını azaltmaya yardımcı olmaktadır. Model, bir penceredeki en yüksek değeri seçen maksimum havuzlama (max pooling) katmanını kullanmaktadır. Şekil 14'te Soldaki görüntü, orijinal görüntüyü temsil etmektedir. Sağdaki görüntüde ise, orijinal görüntüye uygulanan filtre ve havuzlama işlemleri sonucunda elde edilen çıktı göstermektedir.



Şekil 14. Ortalama Havuzlama

Şekil 15'te Soldaki görüntüde, orijinal giriş verisindeki 2x2 küçük bölgeler yer almaktadır. Sağdaki görüntüde ise, bu 2x2 bölgeler üzerinde uygulanan "Maksimum Havuzlama" işleminin sonucu görülmektedir.




Şekil 15. Maksimum Havuzlama

2.5.4. Tam Bağlı Katman

Tam bağlı katmanlar (FC), bir önceki katmandaki her nöronu bir sonraki katmandaki her nörona bağlayan katmanlardır. FC'nin amacı, giriş görüntüsünü eğitim veri kümesine dayalı olarak


çeşitli sınıflara sınıflandırmak için önceki katmanlardan çıkarılan özellikleri kullanmaktır. Son tam bağlantılı katman, her sınıf için bir çıktı üreten bir softmax aktivasyon fonksiyonu ile sona erer. ResNet34 modeli, 1000 sınıfı ayırt edebilen son bir tam bağlantılı katmana sahiptir. Ancak, veri kümemizde sadece 5 sınıfımız bulunmaktadır. Bu nedenle son katman, 5 sınıfı ayırt edebilen yeni bir tam bağlantılı katmanlar zinciri ile değiştirilmiştir. Şekil 16'da görüldüğü üzere tam bağlı katman, önceki katmanlardan gelen işlenmiş bilgileri toplayarak sonuç olarak adlandırılan bir çıkış üretir. Bu çıktı, sınıflandırma, tahmin veya kontrol gibi farklı görevlerde kullanılabilir.



Şekil 16. Tam Bağlantılı Katman

2.6. Transfer Öğrenme

Transfer öğrenme, milyonlarca görüntüyü içeren ImageNet gibi büyük bir veri kümesi üzerinde eğitilmiş bir model olup, ilgili görevdeki bir model için başlangıç noktası olarak kullanılır. Bu yaklaşım, modelin büyük veri kümesi üzerindeki eğitimi sırasında öğrendiği özelliklerden ve gösterimlerden yararlanır. Örneğin, ImageNet üzerinde eğitilmiş bir evrişimli sinir ağının ilk katmanları, kenarlar ve dokular gibi genel özellikleri yakalarken, sonraki katmanlar görüntülerdeki nesnelerle ilgili daha spesifik özellikleri yakalar (Tan vd., 2018, s. 432). Şekil 17'de görüldüğü üzere transfer öğrenme modeli şematize edilmiştir.



Şekil 17. Transfer Öğrenme Modeli


Öğrenilen bu özelliklerin çok daha küçük bir veri kümesiyle tıbbi görüntülerin sınıflandırılması gibi yeni bir göreve aktarılmasıyla model, sıfırdan eğitilmesine kıyasla daha iyi bir performans elde edebilir. Bunun nedeni, önceden eğitilmiş modelin, yeni veri kümesinin belirli özellikleri için ince ayar yapılabilecek çok sayıda yararlı özelliğe zaten sahip olmasıdır (Zhuang vd., 2020, s. 58). ResNet34 modeli, ImageNet veri kümesi üzerinde önceden eğitilmiş olarak gelir ve transfer öğrenme için yaygın olarak kullanılır. ResNet34, atlama bağlantıları ve evrişimsel katmanların bir kombinasyonunu kullanarak görüntü sınıflandırma için güçlü bir yapı oluşturan modellerden bir tanesidir.

2.7. Transfer Öğrenme Modelleri

Son yıllarda çeşitli görüntü tanıma ve sınıflandırma görevlerinde dikkate değer başarılar elde eden Residual bağlantılar ve derin yapıların etkin bir şekilde kullanımıyla geliştirilmiş fonksiyonları içerisinde barındıran, atlama bağlantıları (skip connection) ve evrişimsel katmanların bir kombinasyonunu kullanarak sınıflandırma için kullanılan son zamanların başarılı modellerinden biri olan ResNet çalışma kapsamında tercih edilmiştir.

ResNet, ILSVRC 2015'in kazananı olmuştur. AlexNet'ten yaklaşık 20 kat, VGGNet'ten ise 8 kat daha derin bir ağıdır. ResNet, bir tür "ağ içinde ağ" mimarisi olan, Artık Ağ (RES) adı verilen yeni bir tür katman sunmaktadır. Diğer bir yenilik ise, ağın sonunda tam bağlantılı katmanların yerine küresel ortalama havuzlama katmanlarının kullanılmasıdır. Bu hileler sayesinde ResNet, daha küçük bir model boyutu kullanarak VGGNet'ten daha derindir. ResNet'in giriş katmanı 224×224 piksellik görüntüleri kabul eder (He vd., 2016, s. 770-771). Bu çalışma kapsamında ResNet34 (34 Katmanlı Artık Ağ) modeli kullanılmıştır. ResNet34, 1000 sınıfı ayırt edebilen

son bir tam bağlantılı katmana sahip bir modeldir. Ancak, veri kümemizde sadece 5 sınıfımız bulunmaktadır. Bu nedenle son katman, 5 sınıfı ayırt edebilen yeni bir tam bağlantılı katmanlar zinciri ile değiştirilmiştir. Bu katman, 512 girdiden 256 çıktıya, 256'dan 128, 128'den 64 ve 64'ten 5'e giden ardışık lineer katmanlar ve aktivasyon fonksiyonları ile devam eder. Aşağıda Şekil 18'de görüldüğü üzere kullanılan modelin katmanları görülmektedir.



Şekil 18. ResNet34 Mimarisi

Şekil 18'de bahsedilen Resnet34 modeli 34 evrişimsel katmandan (Conv) ve 5 ardışık atlama bağlantısından oluşan bir evrişimsel sinir ağı mimarisine sahiptir. Toplamda 34 evrişimsel katman vardır. Her katman, girdi görüntüsünü filtrelerle tarayarak ve her piksel için bir özellik haritası üreterek çalışır. Farklı katmanlar, farklı boyutlarda filtreler ve farklı adımlarla çalışabilir. Evrişimsel katmanlar, görüntülerdeki kenarları, köşeleri ve dokuları gibi önemli özellikleri çıkarmak için kullanılır. Daha sonra evrişimsel katmanlar arasına havuzlama katmanları yerleştirilir. Havuzlama katmanları, özellik haritalarındaki değerleri indirgeyerek modelin karmaşıklığını ve parametre sayısını azaltmaya yardımcı olur. ResNet34'ün temel özelliği ardışık atlama bağlantılarının kullanımıdır. Atlama bağlantıları, bir katmandaki çıktıyı doğrudan bir sonraki katmanın girişine ekler. Bu, modelin daha derin katmanlardan gelen bilgilere erişmesini ve daha iyi özellik temsilleri öğrenmesini sağlar ve son olarak FC, tüm nöronları birbirine bağlar ve modelin görüntüleri sınıflara ayırmayı öğrenmesini sağlar.

2.8. Performans Metrikleri

Bir modelin başarısını ve performansını değerlendirmek amacıyla çeşitli ölçütler kullanılmaktadır. Bu ölçütler arasında karışıklık matrisi, doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), ortalama kesinlik ve F1 skoru bulunmaktadır. Sınıflandırma problemlerinde, bu ölçütlerin temel dayanağı olarak karışıklık matrisi kullanılmaktadır. Karışıklık matrisi, sınıflandırma matrisi veya olasılık tablosu olarak da adlandırılabilir.

Tablo 1. Karışıklık Matrisi

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
	Negatif	Yanlış Negatif (FN)	Doğru Negatif (TN)

Doğru Pozitif (TP): Modelinin pozitif olarak doğru tahmin ettiği sonuç sayısıdır.

Doğru Negatif (TN): Gerçekte negatif olan verileri eğitilen modelin negatif olarak tahmin ettiği doğru sonuç sayısıdır.

Yanlış Pozitif (FP): Gerçekte negatif olan verileri eğitilen modelin yanlış yaparak tahminini pozitif olarak işaretlediği sonuç sayısıdır.

Yanlış Negatif (FN): Gerçekte pozitif olan verileri modelin yanlış yaparak tahminini negatif olarak işaretlediği ettiği sonuç sayısıdır

Karışıklık matrisinden hesaplanabilen, en sık kullanılan metriklerin denklemleri Formül 1, 2, 3, 4'te verilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FN+TN} * 100 \quad (1)$$

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

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

$$\text{F1 - Skor} = \frac{\text{Duyarlılık}}{\text{Kesinlik}+\text{Duyarlılık}} * 2 \quad (4)$$

Kesinlik, doğru tahmin edilen pozitif gözlemlerin tüm tahmin edilen pozitiflere oranıdır. Pozitif tahminlerin ne kadar doğru olduğuna odaklanmaktadır. Örneğin, bir model bir e-postayı spam

olarak tanımlarsa, kesinlik bize işaretlenen e-postaların kaçının gerçekten spam olduğunu söylemektedir.

Duyarlılık (veya geri çağırma), modelin tüm ilgili vakaları belirleme yeteneğini ölçmektedir. Doğru tahmin edilen pozitiflerin tüm gerçek pozitiflere oranıdır. Spam örneğinde, geri çağırma bize modelin tüm gerçek spam e-postalarından kaç spam e-postayı başarıyla yakaladığını belirtmektedir (Yacouby ve Axman, 2020, s. 82-83).

F1 Puanı, kesinlik ve duyarlılık harmonik ortalamasıdır. İki metriği dengeleyerek, özellikle kesinlik ve duyarlılık arasında bir denge olduğunda, bir modelin genel performansını değerlendirmek için tek bir sayı sağlamaktadır. Bu puan, özellikle veri kümesinin dengesiz olduğu durumlarda faydalıdır (Hossin ve Sulaiman, 2015, s. 4).

2.9. Model Eğitiminde Kullanılan ESA Hiper Parametreler

Derin öğrenme mimarisine göre araştırmacı tarafından hazırlanan, veri setlerine göre değişiklik gösteren ve model üzerinde başarılı olmak için kullanılan parametrelere hiper parametre denir. Model eğitiminin başarısında önemli bir rol oynayan hiper parametreler, derin öğrenme çalışmalarında önem arz etmektedir (Huang vd., 2016, s. 45-48). Diyabetik Retinopati hastalığının tespiti için bu çalışmada kullanılan hiper parametreler: eğitim oranı, doğrulama oranı, eğitim tur sayısı, paket boyutu, öğrenme oranı, Cosine Annealing öğrenme oranı, OneCycleLR öğrenme oranı, ReduceLROnPlateau, L2 regularization, aktivasyon fonksiyonları, optimizasyon fonksiyonlarıdır.

2.9.1. Eğitim Oranı

Eğitim seti, bir makine öğrenimi modelini eğitmek için kullanılan veri kümesidir. Bu veri kümesi, modelin parametrelerini (örneğin, ağırlıklar ve biaslar) öğrenmesine ve ayarlamasına olanak tanır. Kullanım amacı modelin, verilen girdilere göre doğru çıktıları üretmeyi öğrenmesi için kullanılır. Bu çalışmada, %80 eğitim seti ve %20 test seti olacak şekilde bir veri kümesi bölünmüştür. Eğitim seti, modelin öğrenmesine ve parametrelerini optimize etmesine imkân tanıyan örneklerden oluşmaktadır.

2.9.2. Doğrulama Oranı

Doğrulama seti, modelin eğitim süreci sırasında performansını değerlendirmek için kullanılan ayrı bir veri kümesidir. Eğitim seti üzerinde öğrenilen modelin, doğrulama seti üzerindeki performansı ölçülür ve bu, modelin genelleme yeteneğini değerlendirmek için kullanılır. Doğrulama seti, eğitim sırasında modelin aşırı öğrenmesini önlemek için önemli bir rol oynar. Bu çalışmada, %80 eğitim seti ve %20 test seti olacak şekilde bir veri kümesi bölünmüştür. Doğrulama seti modelin performansını değerlendirmek için kullanılmıştır.

2.9.3. Eğitim Tur Sayısı

Tur sayısı bir ile sonsuz arasında bir değer alabilir. Literatüre bakıldığında tur sayıları genellikle 100, 200, 500 gibi yüksek değerlerden seçilmektedir (Brownlee, 2018, s. 3-5). Ancak epoch(tur) sayısının yüksek olması ağına daha iyi eğitileceği ya da daha başarılı olacağı anlamına gelmez. Bununla beraber tur sayısı ne kadar yüksekse modelin eğitimi için geçen süre de o derece yüksek olacaktır (Hastomo vd., 2021, s. 1-2). Diğer parametrelerde olduğu gibi uygun tur sayısını seçmek için de sabit kurallar bulunmamaktadır. En uygun tur sayısını belirlemek için farklı değerler denenerek ilerlenebilir. Bu durum da zor ve maliyetli bir uğraştır. Bu çalışmada 30-60 tur arasında model eğitimi gerçekleştirilmiştir.

2.9.4. Paket Boyutu

Bu çalışmada, veri işleme modeli birden fazla girdiden oluşan yapıyı parçalara bölerek işlemeyi tercih etmiştir. Bu sayede, karmaşık veri kümelerinin daha verimli bir şekilde işlenmesi sağlanmıştır. Modelin bir seferde işleyebileceği veri miktarını kontrol eden "paket boyutu" hiper parametresi de dikkatlice ayarlanmıştır. Küçük paket boyutunun daha iyi sonuçlar verdiği gözlemlenmiştir. Büyük paket boyutlarında, model verileri ezberleme eğilimindedir, bu da genelleştirme performansını olumsuz etkiler. Bu nedenle, kayıp işlemini en aza indirmek için paket boyutu 32 olarak seçilmiştir.

2.9.5. Öğrenme Oranı

Yapay zekâ ve makine öğrenmesi modellerinde öğrenme oranı, modelin parametrelerinin güncellenme hızını belirleyen önemli bir hiper parametredir. Bu oran, modelin karmaşıklığına, veri kümesinin boyutuna ve veri setindeki gürültü seviyesine bağlı olarak değişkenlik

gösterebilir. Genellikle, uygun öğrenme oranı deneysel yöntemlerle ve öğrenme oranı planlaması gibi stratejiler veya optimizasyon algoritmaları aracılığıyla otomatik olarak seçilebilir. Bu çalışmada sabit öğrenme oranlarından $1e-2$, $1e-3$ ve $1e-4$ ile, öğrenme oranı planlaması yöntemlerinden ise Cosine Annealing, OneCycleLR ve ReduceLRonPlateau yöntemleri ile denemeler yapılarak model için en başarılı yöntem belirlenmiştir. Çalışmada kullanılan öğrenme oranı planlayıcı yöntemleri aşağıda anlatılmıştır.

2.9.5.1. Cosine Annealing Öğrenme Oranı

Cosine Annealing Learning Rate, derin öğrenme modellerinin eğitim sürecinde öğrenme oranının zamana bağlı olarak bir kosinüs fonksiyonu doğrultusunda ayarlandığı bir tekniktir. Bu yöntem, başlangıçta yüksek bir öğrenme oranı kullanarak başlar ve eğitim süreci ilerledikçe bu oranı kademeli olarak azaltmayı amaçlamaktadır. Bu süreçte öğrenme oranı, bir yarım kosinüs eğrisi boyunca azalarak sifıra yaklaşır; bu durum, modelin daha küçük adımlarla öğrenmesini ve daha hassas bir optimizasyon süreci yürütmesini sağlamaktadır. İlk olarak Loshchilov ve Hutter (2016) tarafından önerilen bu teknik, eğitim sürecinin belirli bir aşamasında öğrenme oranını sifıra yaklaştırarak aşırı uyumu önlemeyi hedeflemektedir (Loshchilov ve Hutter, 2016). Cosine annealing, diğer öğrenme oranı azaltma tekniklerine kıyasla daha yumuşak bir geçiş sunmaktadır. Genellikle, tur sayısına dayalı belirli bir plan çerçevesinde, öğrenme oranının ani bir düşüş yerine kademeli ve yumuşak bir azalma göstermesi sağlanmaktadır. Bu durum, modelin daha doğru bir genelleme yapabilmesine olanak tanımaktadır. Ayrıca, SGD gibi optimizasyon algoritmalarıyla birleştirildiğinde, modelin lokal minimumlardan kaçınmasına yardımcı olabilmektedir. Bu yaklaşımın literatürde, özellikle sinir ağları ve büyük veri kümeleri üzerindeki eğitim süreçlerinde etkili olduğu kanıtlanmıştır (Loshchilov ve Hutter, 2017). Cosine annealing öğrenme oranı, özellikle dil modelleri, görüntü sınıflandırması ve nesne tespiti gibi alanlarda yaygın olarak uygulanmaktadır. Büyük veri kümeleri ve derin öğrenme modellerinde öğrenme oranını optimize etmek genellikle zorlu bir süreç olduğundan, bu yöntem daha hassas ve istikrarlı bir eğitim süreci sağlamaktadır. Ayrıca, öğrenme oranının dinamik bir şekilde yönetilmesi gereken transfer öğrenme senaryolarında da bu yöntem başarıyla kullanılmaktadır (Brigato vd., 2022, s. 627).

2.9.5.2. OneCycleLR Öğrenme Oranı

OneCycleLR, öğrenme oranını eğitim süreci boyunca önce artırıp ardından azaltan bir strateji olarak tanımlanmaktadır. Bu yöntem, eğitim sürecinin başlangıcında öğrenme oranını kademeli olarak yükseltir ve belirli bir noktaya ulaştıktan sonra, azalarak eğitim sürecinin sonuna doğru en düşük seviyeye iner. Bu yaklaşım, Smith (2018) tarafından önerilmiş olup, özellikle SGD gibi optimizasyon algoritmalarıyla birleştirildiğinde etkili sonuçlar elde etmektedir (Smith, 2018). OneCycleLR, öğrenme oranını iki aşamada düzenlemektedir (Xie vd., 2022, s. 7):

İlk Aşama (Artış), eğitim sürecinin ilk yarısında, öğrenme oranı kademeli olarak artırılır. Bu süreç, modelin hızlı bir şekilde optimuma yakın bir noktaya ulaşmasını sağlamaktadır. İkinci Aşama (Azalış), eğitim sürecinin ikinci yarısında ise öğrenme oranı azaltılır. Bu, modelin optimum noktada daha küçük adımlarla daha hassas bir öğrenme gerçekleştirmesine olanak tanımaktadır. Bu yöntem, modelin lokal minimumlara takılmadan daha doğru bir genelleme yapabilmesini desteklemektedir. OneCycleLR, eğitim sürecine yüksek öğrenme oranları ile başlanmasını sağlar; bu durum, modelin hızla öğrenmesine olanak tanımaktadır. Öğrenme oranı yavaşça azaldığında, model daha küçük adımlarla eğitim sürecini tamamlar ve bu da genelleme başarısını artırmaktadır. Eğitim sürecinin sonunda öğrenme oranının azaltılması, modelin aşırı uyum yapma olasılığını önlemektedir. Özellikle büyük veri kümeleri üzerinde gerçekleştirilen çalışmalarda, bu yöntemle modelin daha genel sonuçlar üretmesi sağlanmaktadır (Omidvar ve Tran, 2023).

2.9.5.3. ReduceLROnPlateau

ReduceLROnPlateau, öğrenme oranını modelin eğitim sürecinde belirli bir süre boyunca iyileşme göstermediğinde azaltan bir optimizasyon stratejisi olarak tanımlanmaktadır. Bu teknik, derin öğrenme modellerinde öğrenme sürecini hızlandırırken aşırı uyum riskini azaltmak amacıyla kullanılmaktadır. ReduceLROnPlateau, özellikle kaybın (loss) azalmadığı durumlarda, modelin daha düşük bir öğrenme oranı ile ince ayar yapmasına olanak tanımaktadır (Hinton vd., 2012). ReduceLROnPlateau, kaybın (loss) belirli bir süre boyunca iyileşme göstermediğini tespit ettiğinde devreye giren bir mekanizmadır. Bu süre, genellikle "patience" olarak adlandırılan bir parametre ile ayarlanmaktadır. Kaybın belirlenen bir eşik değerinin altında iyileşmediği durumlarda, öğrenme oranı belirlenen bir faktörle (örneğin, 0.1) çarpılarak azaltılır. Bu süreç, modelin eğitim sürecinin sonlarına doğru daha küçük adımlarla ilerlemesine olanak tanır ve modelin daha hassas bir öğrenme gerçekleştirmesini sağlamaktadır (Durães vd.,

2023, s. 77). ReduceLROnPlateau, kaybın iyileşmediği durumlarda öğrenme oranını daha küçük adımlarla ayarlayarak daha hassas bir öğrenme süreci sağlamaktadır. Bu yaklaşım, eğitim süresini kısaltma potansiyeline sahiptir. Eğitim sırasında öğrenme oranının kademeli olarak azaltılması, modelin aşırı uyum yapma olasılığını önler ve genelleme yeteneğini artırmaktadır (Thakur vd., 2024, s. 14).




2.9.6. L2 Regularization

Ridge regularization (düzenlemesi) olarak da bilinen L2 regularization, makine öğrenimi modellerinde, özellikle de sinir ağlarında aşırı uyumu önlemek için kullanılan bir tekniktir. Kayıp fonksiyonuna, model parametrelerinin (ağırlıkların) karesel değerlerinin toplamıyla orantılı olan bir ceza terimi ekleyerek çalışmaktadır. Bu ceza, modelin özelliklere aşırı büyük ağırlıklar atmasını engelleyerek modelin daha sağlam ve genelleştirilmiş olmasını sağlamaktadır (Phaisangittisagul, 2016, s. 175). L2 düzenlemesi terimi $\lambda \sum w^2$ olarak ifade edilmektedir; burada λ düzenlileştirmenin gücünü kontrol eden bir hiper parametre ve w model ağırlıklarını temsil etmektedir. Orijinal kayıp fonksiyonuyla birlikte bu ceza terimini en aza indirerek, modelin ağırlıkları küçük tutması tavsiye edilir ve modelin eğitim verilerine çok yakın uyması ve görünmeyen verilerde kötü performans göstermesi durumunda ortaya çıkan aşırı uyum önlenmektedir (Liu vd., 2019, s. 14). L2 düzenlemesi lojistik regresyon, destek vektör makineleri ve sinir ağları gibi modellerde yaygın olarak uygulanmaktadır. Çok sayıda özellik olduğunda iyi çalışır, çünkü hiçbir özelliği tamamen ortadan kaldırmaz, ancak etkilerini azaltır ve daha düzgün modellere yol açmaktadır. L1 düzenlemesi (bazı ağırlıkları sıfıra çekerek seyrek modellere yol açar) ile karşılaştırıldığında, L2 düzenlemesi çoğu ağırlığın küçük olduğu ancak sıfır olmadığı daha yoğun modeller üretme eğilimindedir (Ng, 2004, s. 12).

2.9.7. Aktivasyon Fonksiyonları

Bu probleme özgü ReLU, Leaky ReLU ve ELU aktivasyon fonksiyonları kullanılmıştır. Kullanılan aktivasyon fonksiyonu algoritmalarının matematiksel fonksiyonları ve grafikleri Tablo 2’de verilmiştir.

Tablo 2. Aktivasyon Fonksiyonları

Aktivasyon Fonksiyonu	Matematiksel Formülü	Grafik
ReLU	$\max(0, x)$	
ELU	$\begin{cases} x & x \geq 0 \\ a(e^x - 1) & x < 0 \end{cases}$	
Leaky ReLU	$\begin{cases} x & x > 0 \\ ax & x \leq 0 \end{cases}$	

2.9.8. Optimizasyon Fonksiyonları

Optimizasyon algoritmaları, makine öğreniminde, model parametrelerini ayarlayarak kayıp fonksiyonunu minimize (veya maximize) etmek için kullanılır. Doğrusal olmayan problemlerin çözümünde optimum değer için optimizasyon yöntemleri kullanılmaktadır. Bu yöntemlerden, katmansal sıralama yapabildiği büyük veri setleri ve yüksek boyutlu parametre alanları ile iyi çalıştığı için SGD ve Momentum optimizasyon algoritmaları çalışmada kullanılmıştır.

2.10. Literatürde Araştırma ile İlgili Çalışmalar

Literatürde görüntü işlemeye yönelik derin öğrenme algoritmaları ile ilgili çalışmalar verilmiştir.

Zaheer ve Shaziya (2018), çalışmalarında yaygın olarak kullanılan aktivasyon fonksiyonlarından dördü, modelin doğruluğu açısından verimliliklerini belirlemek amacıyla analiz etmek ve değerlendirmek üzere seçmişlerdir. Başarılı modellerin çoğunda, Sigmoid, Hiperbolik Tanjant (Tanh), düzeltilmiş doğrusal birim (ReLU) ve üstel doğrusal birim (ELU) aktivasyon fonksiyonları kullanılmıştır. Analiz görevinin gerçekleştirilmesi için, MNIST veri

seti üzerinde bir ESA modeli uygulanmıştır. ESA modelinin eğitim ve test süreçlerini hızlandırmak amacıyla deneyler, Nvidia GPU 940MX üzerinde yürütülmüştür. Sonuçlar, en popüler aktivasyon fonksiyonu olan ReLU'nun, Sigmoid ve Tanh fonksiyonlarından daha iyi performans gösterdiğini ve yeni bir aktivasyon fonksiyonu olan ELU'nun ise ReLU'dan daha üstün performans sergilediğini ortaya koymuştur.

Adem vd., (2016) çalışmalarında optik diskin parlaklık ve dairesellik özelliklerini kullanarak konumunu tespit etmek için üç farklı çözüm önerilmektedir. Bu üç deneyin bulgularının karşılaştırılması sonucunda HSV renk uzayı ile uygulanan Dairesel Hough Dönüşümü yönteminin %99,16 doğrulukla daha başarılı olduğu görülmüş ve bu nedenle optik disk tespiti için uygun bir yöntem olarak önerilmiştir.

Rajput vd., (2022), çalışmalarında, önerilen bir aktivasyon fonksiyonunun matematiksel modellemesi ile bir evrimsel sinir ağı özelleştirilmiştir. 0,97'lik bir hassasiyetle birlikte %99'a varan kayda değer bir tahmin doğruluğu elde edilmiştir. MIAS veri setinin meme kanseri mamogram görüntülerini sınıflandırmak için değiştirilmiş bir VGG-19 derin öğrenme modeli önerilmiştir. Çeşitli aktivasyon fonksiyonları ve önerilen fonksiyon, MIAS veri seti üzerinde LeNet, VGG ve AlexNet gibi çoklu kıyaslama mimarileri üzerinde karşılaştırılmıştır. Deneyimizi karşılaştırmak ve doğrulamak için ReLU, ELU ve Tanh gibi ünlü aktivasyon fonksiyonları kullanılmıştır. Önerilen aktivasyon fonksiyonuna sahip modelin, yaygın olarak kullanılan diğer kıyaslama aktivasyon fonksiyonlarından daha üstün sonuçlar gösterdiği sonucuna varılabilir. Örneğin, modelin doğruluğu beş dönemden kısa bir sürede %90 sınırını aşmış ve yaklaşık 50 dönemde %98,89 test doğruluğuna ulaşmıştır. Bu nedenle, önerilen aktivasyon fonksiyonunun herhangi bir öğrenme problemi için genelleştirilebileceği ve mevcut herhangi bir modeli kesinlikle önemli bir farkla geride bırakabileceği kanıtlanmıştır. Çalışmamızda Modifiye VGG-19 modelini temel modeller olarak AlexNet, VGG-16 ve LeNet ile karşılaştırılmıştır. Sonuçlar VGG-19 modelinin en iyi performansı verdiğini gösterilmiştir.

Dubey vd., (2024) çalışmalarında, derin öğrenme yöntemlerini doğadan ilham alan bir algoritma ile birleştiren hibrit bir yaklaşım önermektedir. Bu yazıda, Crow Arama Optimizasyon Algoritması (CSOA), HRD sınıflandırması için derin öğrenme teknikleriyle entegre edilmiştir. Sınıflandırma, derin sinir ağı (DNN) ve evrimsel sinir ağı algoritmaları kullanılarak gerçekleştirilmiştir. Deneyler iki veri kümesi üzerinde yürütülmüştür: sayısal HRD verilerini içeren Cardio veri kümesi ve HRD ile ilişkili X-ışını görüntülerini içeren NIH göğüs röntgeni görüntü veri kümesi. Sınıflandırma görevi için Momentumlu Stokastik Gradyan İnişi, RMSProp, Adam, Adagrad, Düzenli Lideri Takip Et ve Nadam gibi çeşitli optimize ediciler

değerlendirilmiştir. Daha da önemlisi, CSOA'nın DNN (CSOA-DNN) ile birleşimi, DNN modelinin Cardio veri kümesindeki performansını önemli ölçüde arttırmıştır. Genel olarak, Adam ve Nadam optimize edicileri, hem DNN hem de CNN(Convolutional Neural Network) modellerinde eğitim ve doğrulama sırasında çeşitli performans parametrelerinde sürekli olarak diğer optimize edicilerden daha iyi performans gösterdiği görülmüştür.

Adem (2022), çalışmasında CNN modelindeki aktivasyon fonksiyonunun gerçek dünya problemine ve imajına etkisi araştırmıştır. Görüntü işleme yöntemlerinden dairesel Hough dönüşümü uygulanarak sızıntı bölgelerine benzer yapıya sahip olan OD bölgesi belirlenerek görüntüden çıkarılmış ve ardından CNN modeli kullanılarak sızıntı bölgelerinin tespiti gerçekleştirilmiştir. . CNN modelinde ReLU, ELU, Leaky ReLU, Softplus ve Swish aktivasyon fonksiyonları kullanılarak eksüda tespiti yapıldı ve sonuçlar karşılaştırıldı. DiaretDB0 ve DiaretDB1 veritabanlarındaki deneysel sonuçlar, Swish aktivasyon fonksiyonunun diğerlerine göre daha iyi performansa sahip olduğu görülmüştür.

Toğaçar (2021), çalışmasında rahim kanserine neden olabilecek iyi ve kötü huylu türlerin analizi, yapay zekâ tabanlı bir yaklaşımla gerçekleştirilmiştir. Önerilen yaklaşımın katkılarından biri, sağlık çalışanlarının karar verme sürecinde zaman kaybının önlenmesidir. Bu yaklaşım, kısa sürede çok sayıda görüntünün başarıyla işlenmesini sağlayabilir. Ayrıca, CNN modellerinin tek başına kullanıldığında farklı veri kümeleri için istikrarlı ve başarılı sonuçlar üretemeyebileceği göz önüne alındığında, önerilen yaklaşım bu duruma çözüm sunmaktadır. Önerilen yaklaşım, rahim kanseri türlerine göre 7 farklı CNN modeli arasından en iyi aktivasyon setlerini seçerek performansı artırmaktadır. Bu yaklaşımın dezavantajı, mimari yapısında birden fazla CNN modeli kullanması ve modellerin test süresi boyunca harcadığı zamanın tekli CNN modellerine göre daha fazla olmasıdır. Ancak, önerilen yaklaşımın temel amacı genel başarıyı artırmaktır. Bu çalışmada, genel olarak %99,65 oranında başarılı bir performans elde edilmesiyle bu amaca ulaşılmıştır.

Adweb vd., (2021) çalışmalarında, aktivasyon fonksiyonlarının artıklı bir ağı (ResNet) performansı üzerindeki önemini vurgulamışlardır. Bu nedenle, farklı aktivasyon fonksiyonlarına sahip aynı yapıda üç artıklı ağ oluşturulmuştur. Kullanılan modeller, kolposkopi servikal görüntülerinden oluşan bir veri seti kullanılarak eğitilmiş ve test edilmiştir. Deneysel sonuçlar, tasarlanan artıklanma ağlarının sızdırmalı ve parametrik düzeltilmiş doğrusal birim (Leaky-RELU ve PReLU) aktivasyon fonksiyonları ile neredeyse eşit performans gösterdiğini ve sırasıyla %90,2 ve %100 doğruluk oranlarına ulaştıklarını göstermiştir.

Daşgın vd., (2023) yaptıkları çalışmada transfer öğrenme tabanlı modellerin kullanıldığı bir çalışma gerçekleştirmişlerdir. Kaggle web sitesinde bulunan veri seti üzerinde gerçekleştirilen bu çalışmada, toplamda 906 görüntü kullanılarak DenseNet121, EfficientNetV2M, NasNetMobile, InceptionV3, VGG19 ve InceptionResNetV2 gibi derin öğrenme modelleri değerlendirilmiştir. Deneysel sonuçlara göre, en iyi başarı oranının NasNetMobile modeliyle elde edildiği görülmüştür. Bu modellerle %99,35 doğruluk, %99 kesinlik, %99 geri çağırma ve %99 F1 skorları elde edilmiştir.




ÜÇÜNCÜ BÖLÜM

MATERYAL VE YÖNTEM

Bu bölümde, veri yöntemi, veri setlerinin oluşturulması ve sınıflandırılması, veri ön işleme aşamaları, araştırmada kullanılan kütüphaneler ayrıntılı olarak sunulacaktır. Bunun yanı sıra, araştırmada kullanılan yöntemlerin gerekçesi ve uygulama şekli de açıklanarak derinlik kazandırılacaktır.

3.1. Araştırmanın Yöntemi

Bu çalışmada derin öğrenme yöntemleri kullanılarak DR hastalığının tespit edilmesine yönelik sınıflandırma doğruluğunu artırıcı yöntemler önerilmiştir. Veri seti sınıflandırma başarısını değerlendirmek için veri setinde bulunan fundus görüntüleri üzerinde önerilen yöntem bağlamında gözdeki damar yapısını, özelliklerini RGB (3D) görüntülere kıyasla daha iyi ortaya çıkardığı ve yoğunluk değerlerine odaklanılmasını sağladığı için Gri Tonlamalı (Gray Scale-2D) görüntüye dönüştürülmüştür. Veri setinde yer alan farklı boyutlardaki pek çok renkli fundus görüntüleri veri hazırlama, ön işleme aşamalarında zorluk yaratmaması aynı zamanda farklı boyutlardaki görüntünün işleme aşamasında modele daha fazla hesaplama gücü ihtiyacı doğurmaması için 512x512 boyutunda kırpılmıştır. Kırpılan görüntüler üzerinde son olarak ışık ve parlaklık koşulları tüm resimler üzerinde eşit olmadığı ve gürültülerin giderilmesi amacıyla Maskeleme ve Gaussian Blur (Gauss Bulanıklığı) işlemleri görüntüye uygulanmış olup resmin daire merkez ve yarıçapı hesaplanarak dairesel olarak kırpılarak sınıflandırma işlemine hazır hale getirilmiştir. Sınıflandırma işlemi için transfer öğrenme yaklaşımı ile popüler CNN mimarilerinden biri olan ResNet34 ile veri seti yeniden eğitilmiştir. DR hastalığının tespiti için derin öğrenme mimarisinde farklı hiper parametreler model üzerinde denenmiş olup modelin performansına etkisi karşılaştırılmıştır. Bu çalışmada DR tespiti için kurulan mimari Şekil 19'da verilmiştir.




Şekil 19. Diyabetik Retinopati Tespiti için Kurulan Mimari


3.2. Veri Setlerinin Oluşturulması ve Sınıflanması

Bu çalışmada pek çok alanda çeşitli veri setini içerisinde barındıran Kaggle platformundan yararlanılmıştır. Bu bağlamda çalışmada 2 farklı veri seti kullanılmıştır. Birinci veri seti Kaggle’da “APTOS 2019 Blindness Detection (Körük Tespiti)” ismiyle yayınlanan 3662 adet eğitim ve 1928 adet test verisi olmak üzere toplam 5590 adet fundus görüntüsünden oluşmaktadır. İkinci veri seti olarak “Eyepacs, Aptos ve Messidor” veri tabanlarından toplanan 7915 örnek ile oluşturulan özgün bir veri seti kullanılmıştır. Kullanılan veri seti DR’nin otomatik olarak tanınmasına yardımcı olmak için kırsal alanlardan toplanan fundus görüntülerinden oluşmaktadır (Kaggle,2019).


Veri seti Normal (a), Hafif (b), Orta (c), Şiddetli (d), Proliferatif (e) olmak üzere toplam 5 kategoriden oluşmaktadır. Bu veri setlerine ait örnek görüntüler Şekil 20’de görülmektedir.



Şekil 20. DR Evreleri



Şekil 21. DR Sınıf Dağılım Grafiği 1



Şekil 22. DR Sınıf Dağılım Grafiği 2

“Aptos Blindness Detection” veri setinde, fundus görüntülerinin %80'i (2929) eğitim amacıyla ayrılmış, kalan %20'si (733) ise doğrulama seti olarak kullanılmıştır. "Eyepacs, Aptos ve Messidor" veri tabanlarından oluşturulan ikinci veri setinde ise görüntülerin %80'i (6332) eğitim için, %20'si (1583) ise doğrulama seti olarak belirlenmiştir. Her bir sınıf için veri dağılımı grafiği Şekil 21 ile Şekil 22'de görülmektedir. Bu görüntüler, çeşitli ön işleme adımlarına tabi tutulmuş ve ardından farklı hiper parametrelerle model eğitimi

gerçekleştirilmiştir. Sonuçlar, bu modellerin performansını değerlendirmek için belirlenen ölçütler doğrultusunda incelenmiştir.


3.3. Veri Ön İşleme Aşamaları

Diyabetik retinopati teşhisinde kullanılacak görüntü veri kümelerini işlemek için ön işleme adımları kritik önem taşımaktadır. Bu adımlar, verilerin model tarafından daha iyi anlaşılmasını ve analiz edilmesini sağlayarak daha doğru sonuçlar elde edilmesine yardımcı olmaktadır.

Önerilen diyabetik retinopati veri seti için bazı önemli ön işleme adımları şunlardır:

3.3.1. Gri Tonlamalı Görüntü (2D)' ye Dönüştürme


Önerilen yöntem bağlamında gözdeki damar yapısını, özelliklerini RGB görüntülere kıyasla daha iyi ortaya çıkardığı ve yoğunluk değerlerine odaklanılmasını sağladığı için Gri Tonlamalı (Gray Scale) görüntüye dönüştürülmüştür. Gri tonlamalı ve orijinal görüntü Şekil 23'te verilmiştir.



Şekil 23. RGB ve Gri Tonlamalı Fundus Görüntüsü

3.3.2. Görüntü Yeniden Boyutlandırma

Farklı boyutlarda çekilen görüntülerin tutarlı bir şekilde işlenmesi için tüm görüntüler sabit bir boyuta (512 x 512 piksel) yeniden boyutlandırılmıştır. Bu, eğitim süresini ve diğer sonraki süreçleri de en aza indirmeye yardımcı olmaktadır. Şekil 24'te yeniden boyutlandırılan görüntü aşamaları verilmiştir.




Şekil 24. DR Görüntü Kırpma

3.3.3. Maskeleme ve Kırpma

Bu yöntem, belirli bir eşik değerine göre maske oluşturur ve bu maskeyi kullanarak orijinal görüntüyü kırpar. Sonuç olarak, kırpılmış bir görüntü elde edilir, bu görüntü orijinal renk veya gri tonlama değerlerini korur. Düşük parlaklık veya gürültü içeren bölgeleri kırparak görüntüyü temizler ve daha odaklı bir analiz sağlamaktadır.


3.3.4. Görüntüye Kontrast ve Bulanıklaştırma (Gaussian Blur) Uygulama

Bu çalışmada Gauss Bulanıklaştırma adı verilen bir gürültü azaltma yöntemi kullanılmıştır. Gauss Bulanıklaştırma, bir görüntünün her pikselinin değerini, komşu piksellerin ortalama değerleriyle değiştirerek çalışır. Bu işlem, görüntüdeki keskin kenarları ve ayrıntıları yumuşatarak gürültünün rastgele ve dağınık doğasını ortalama yoluyla bastırır. Gauss Bulanıklaştırma, DR görüntülerindeki gürültüyü azaltmak için basit ve etkili bir yöntem sunar. Kullanılan sigmaX parametresi, gürültü azaltma seviyesini kontrol etmenizi sağlar. Şekil 25'te Orijinal ve Gauss Bulanıklığı uygulanan fundus görüntüsü gösterilmiştir.



Şekil 25. Gaussian Blur Uygulanmış Fundus Görüntüsü

Çalışmada doğrudan bir kontrast artırma işlemi uygulanmamıştır ancak cv2.addWeighted fonksiyonu kullanılmaktadır. Bu fonksiyon, iki görüntüyü ve bir ağırlık katsayısını kullanarak yeni bir görüntü oluşturur. Bu işlemde, ağırlık katsayısı 4 olarak ayarlanmıştır. cv2.addWeighted fonksiyonunda kullanılan ağırlık katsayısı, yeni görüntünün genel parlaklığını ve kontrastını etkiler. Daha yüksek bir ağırlık katsayısı, görüntünün daha parlak ve yüksek kontrastlı olmasına neden olur. Bu çalışmada, ağırlık katsayısı 4 olarak ayarlanmıştır. Bu, orijinal görüntünün 4 katı parlaklığa sahip yeni bir görüntü oluşturulmasına neden olur. Bu da dolaylı olarak kontrastın artmasına yol açabilir ayrıca Gauss Bulanıklaştırma, görüntünün bazı ayrıntılarını yumuşatarak kontrastı da azaltabilir. Sonuç olarak yapılan çalışmada doğrudan bir kontrast artırma işlemi uygulanmamış olsa da cv2.addWeighted fonksiyonu ve Gauss Bulanıklaştırma kombinasyonu dolaylı olarak kontrastı etkileyebilir. Kullanılan parametreler ve fonksiyonlar, görüntünün türüne ve istenilen sonuca bağlı olarak değiştirilebilir. Şekil 26'da görüldüğü üzere dairesel kırpma ve gauss bulanıklığı uygulanan fundus görüntüsü verilmiştir.



Şekil 26. Dairesel Kırpma ve Gaussian Bulanıklığı Uygulanmış Fundus Görüntüsü

3.3.5. Dairesel Kırpma

Görüntü boyutları kullanılarak dairesel bir maske oluşturulur. Maskenin merkezi, görüntünün merkezine yerleştirilir ve yarıçapı, görüntü genişliğinin veya yüksekliğinin en küçüğü olarak belirlenerek dairesel kırpma maskesi oluşturulur. Maskedeki True değerlerine sahip pikseller, orijinal renkli görüntüden kopyalanarak yeni bir görüntüye aktarılır ve yeni görüntü döndürülür.

3.4. Araştırmada Kullanılan Kütüphaneler

Bu çalışmada, makine öğrenimi ve derin öğrenme uygulamaları için özel olarak tasarlanmış kapsamlı ve gelişmiş kütüphanelere sahip olması sebebiyle Python programlama dili tercih edilmiştir. Söz konusu kütüphaneler, önceden hazırlanmış işlevler ve araçlar sunarak geliştirme sürecini önemli ölçüde kolaylaştırır ve araştırmacıların çalışmalarının temel kavramlarına ve metodolojilerine odaklanmalarını sağlar. Aşağıdaki kullanılan kütüphaneler ve bağımlılıklar listelenmiştir:

- **NumPy:** Büyük, çok boyutlu diziler ve matrisler için destek sağlayan ve bu diziler üzerinde çalışacak geniş bir matematiksel fonksiyon koleksiyonu sağlayan bir Python kütüphanesidir. Bilimsel hesaplama, veri analizi ve makine öğrenimi uygulamalarında yaygın olarak kullanılır.
- **Pandas:** Yüksek performanslı veri işleme ve analiz araçları sağlayan bir Python kütüphanesidir. NumPy üzerine inşa edilmiştir ve veri okuma ve yazma, veri filtreleme, toplama ve birleştirme dahil olmak üzere tablo verileriyle çalışmaya yönelik destek sağlar.
- **Seaborn:** Python programlama dilinde veri görselleştirme için kullanılan bir kütüphanedir. Matplotlib kütüphanesi üzerine kurulu olan Seaborn, istatistiksel verileri görselleştirmeyi kolaylaştırmak ve estetik açıdan hoş grafikler oluşturmak için tasarlanmıştır.
- **Scikit-Learn:** Gözetimli ve gözetimsiz öğrenme görevleri için çeşitli uygulamalar sunan kapsamlı bir makine öğrenimi algoritmaları kütüphanesidir.
- **Matplotlib:** Python'da statik, animasyonlu ve etkileşimli görselleştirmeler oluşturmaya destek sağlayan bir Python kütüphanesidir. Çizgi grafikleri, dağılım grafikleri, çubuk grafikleri ve daha fazlasını içeren çeşitli çizim türleri sağlar. Bilimsel hesaplama, veri analizi ve makine öğrenimi uygulamalarında yaygın olarak kullanılır.
- **Time:** Python programlama dilinde zamanla ilgili işlemler gerçekleştirmek için kullanılan standart bir kütüphanedir. Bu kütüphane, mevcut zamanı alma, zaman damgaları oluşturma, zaman aralıklarını hesaplama, zaman birimlerini dönüştürme ve daha fazlası gibi çeşitli işlevler sunar.
- **PIL:** Python programlama dili için açık kaynak kodlu bir görüntü işleme kütüphanesidir. görüntü açma, kaydetme, düzenleme, format dönüştürme ve daha fazlası dahil olmak üzere çok çeşitli görüntü işleme tekniklerini gerçekleştirmek için kullanılabilir.
- **Torch:** Python programlama dili için açık kaynak kodlu bir makine öğrenimi kütüphanesidir. Yapay zekâ araştırmaları ve uygulamaları için güçlü bir araç seti sunar. Torch, sinir ağları,

evriřimli sinir aęları gibi derin ğrenme modelleri, doęrusal regresyon, karar aęaęları, destek vektör makineleri gibi makine ğrenmesi algoritmaları, bilimsel ve mhendislik uygulamalarında nmerik hesaplamalar, finansal modelleme ve risk analizi iin kullanılabilir.



DÖRDÜNCÜ BÖLÜM

BULGULAR VE SONUÇ

Bu bölümde, deneysel çalışma ortamı ile DR üzerine gerçekleştirilen algoritmaların analiz sonuçları sunulacaktır. Sonuçlar, veri setleri dikkate alınarak sabit öğrenme oranı, öğrenme oranı planlaması ve momentum kullanımına ilişkin analizler şeklinde detaylandırılacaktır.

4.1. Deneysel Çalışma Ortamı

Derin öğrenme mimarileri ve modelleri kullanılarak veri setindeki büyük boyutlu görüntülerin eğitilmesi, yüksek performanslı donanımsal sistemler gerektirmektedir. Bu bağlamda, eğitim süreçlerinin verimli bir şekilde gerçekleştirilebilmesi için güçlü bilgi işlem kaynaklarına ihtiyaç duyulmaktadır. Bu tür derin öğrenme uygulamaları, genellikle grafik işlem birimleri (GPU'lar) ve yüksek işlem kapasiteli makineler gerektirir. Bu çalışmada, Transfer öğrenme modellerin eğitimi ve test işlemleri standart Colaboratory üyeliği ile sunulan 85 GB RAM, 40 GB Tesla A100 GPU ve 170 GB disk alanıyla gerçekleştirilmiştir. Programlama dili olarak Python tercih edilmiştir. Bu çalışmada, ResNet34 modeli üzerinde en çok kullanılan aktivasyon fonksiyonlarından üç tane, optimizasyon algoritmalarından iki tanesi seçilmiştir. Derin öğrenme modelleri performans metriği üzerinde kritik öneme sahip olan öğrenme oranını belirlemek amacıyla literatürde yaygın olarak kullanılan Cosine Annealing, ReduceLROnPlateau, OneCycleLR ve sabit öğrenme oranları birinci veri seti olan “Aptos” üzerinde denenerek performansları model üzerinde değerlendirilmiştir. Daha sonra “Eyepacs, Aptos ve Messidor” veri tabanlarından oluşturulan ikinci veri seti üzerinde veri artırma teknikleri, L2 regülerizasyon uygulanarak optimizasyon ve aktivasyon kombinasyonlarıyla görüntüler üzerinde performans analizleri yapılmıştır. Bu yaklaşım, farklı hiper parametrelerin model performansına etkilerini karşılaştırmalı olarak değerlendirmek amacıyla tasarlanmıştır. Bu eğitimlerde belirlenen ortak parametreler aşağıdaki gibidir;




- ✓ Eğitim tur sayısı (Epoch) = 30-60
- ✓ Paket boyutu (Batch Size) = 32
- ✓ Aktivasyon fonksiyonu = ReLU, Leaky ReLU ve ELU

✓ Optimizasyon algoritması = SGD, Momentum

4.2. Sabit Öğrenme Oranı– ReLU, Leaky ReLU ve ELU-SGD Analiz Sonuçları

Derin öğrenme modelinin performansını etkileyen kritik bir aşama olan öğrenme oranını belirlemek için literatürde yaygın olarak kullanılan bazı yöntem ve tekniklerden olan sabit öğrenme oranlarından $1e-2, 1e-3, 1e-4$ kullanılarak “Aptos” ön işlemeli veri seti üzerinde eğitim boyunca kullanılan üç farklı sabit öğrenme oranının model üzerindeki etkisi incelenmiş ve sonuçlar karşılaştırılmıştır. Tablo 3’te $1e-2$ sabit öğrenme oranının aktivasyon fonksiyonları ile olan karşılaştırmalı performansı değerlendirilmiştir.


Tablo 3. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının $1e-2$ Öğrenme Oranına Göre Doğrulama ve Kayıp Grafikleri

		Eğitim ve Doğrulama Doğruluk Grafığı	Eğitim ve Doğrulama Kayıp Grafığı
Öğrenme Oranı ($1e-2$)	Leaky ReLU-SGD		
	ReLU-SGD		
	ELU-SGD		

Tablo 3’e bakıldığında bu grafikler, farklı hiperparametrelerin model performansı üzerindeki etkisini göstermektedir. Model üzerinde kullanılan öğrenme oranının $1e-2$ olduğu aktivasyon fonksiyonlarının grafikleri incelendiğinde $1e-2$ öğrenme oranı, genellikle iyi bir başlangıç noktası olarak kabul edilebilir. Ne çok hızlı ne de çok yavaş bir öğrenme sağlar. Eğitim doğruluk oranına bakıldığında başlangıçta hızlı bir artış gösterip daha sonra sabitlenmiştir. Doğrulama doğruluğu da sık dalgalanmalar halinde ilerleyip eğitim çizgisinden ayrılmıştır. Eğitim kaybı başlangıçta hızlı bir düşüş göstermekte olup daha sonra düzleşip hafif artmaktadır.

Doğrulama kaybında ise artış ve dalgalanmalar görülmektedir. Bu durum yapay sinir ağının ağırlıklarını güncellerken büyük bir adım atmasından dolayı yerel minimumlara sıkışıp dalgalanma ve kararsızlık durumunu açıklayabilir. Leaky ReLU aktivasyon fonksiyonu $1e-2$ öğrenme oranı, bu model için diğerlerine göre daha iyi sonuçlar vermiştir. Ancak, aşırı öğrenme gibi bazı sorunlar hala mevcuttur. Tablo 4’de $1e-3$ sabit öğrenme oranının aktivasyon fonksiyonları ile olan karşılaştırmalı performansı değerlendirilmiştir.


Tablo 4. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının $1e-3$ Öğrenme Oranına Göre Doğrulama ve Kayıp Grafikleri



Tablo 4’te model üzerinde kullanılan öğrenme oranının $1e-3$ olduğu aktivasyon fonksiyonlarının grafikleri incelendiğinde her üç aktivasyon fonksiyonu için eğitim ve doğrulama doğruluğu, epoch sayısı arttıkça artmaktadır. Bu, modelin eğitim sürecinde öğrenmeye devam ettiğini göstermektedir. Her üç aktivasyon fonksiyonu için de eğitim ve doğrulama kaybı, epoch sayısı arttıkça azalmaktadır. Bu, modelin tahminlerinin giderek daha doğru hale geldiğini göstermektedir. Üç grafikte de eğitim ve doğrulama eğrileri birbirine yakın seyretmektedir. Bu, modelin aşırı öğrenme yapmadığını göstermektedir. Üç aktivasyon fonksiyonu da modelin iyi bir performans göstermesini sağlamıştır. Ancak üç aktivasyon fonksiyonuna bakıldığında doğrulama doğruluğu açısından küçük farklılıklar olduğu

görülmektedir. Tablo 5'te $1e-4$ sabit öğrenme oranının aktivasyon fonksiyonları ile olan karşılaştırmalı performansı değerlendirilmiştir.

Tablo 5. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının $1e-4$ Öğrenme Oranına Göre Doğrulama ve Kayıp Gafikleri



Tablo 5'te model üzerinde kullanılan öğrenme oranının $1e-4$ olduğu aktivasyon fonksiyonlarının grafikleri incelendiğinde Leaky ReLU için eğitim doğruluğu uzun bir süre boyunca sabit kalmakta ve daha sonra ani bir yükselişle maksimum değere ulaşmaktadır. Bu durum, modelin eğitim verisini öğrenmede zorlandığını ve daha sonra bir anda tüm verileri doğru sınıflandırmaya başladığını göstermektedir. Doğrulama doğruluğu ise eğitim doğruluğundan oldukça düşük kalmakta ve son dönemde hafif bir artış göstermektedir. Eğitim kaybı, doğrulama kaybına göre daha hızlı düşmektedir. Yaklaşık 15. epoch'tan sonra doğrulama kaybı, azalmaya devam etmek yerine sabitlenmiştir. Bu durum, modelin yeni verilere genellemediğini göstermektedir. ReLU ve ELU için grafikler incelendiğinde ise hem eğitim hem de doğrulama doğruluğu, epoch sayısı arttıkça artmaktadır. Bu, modelin eğitim süreci boyunca öğrenmeye devam ettiğini göstermektedir. İki eğri arasındaki farkın nispeten az olması, modelin aşırı öğrenme yapmadan genelleme yeteneğini koruduğunu göstermektedir.

Hem eğitim hem de doğrulama kaybı, epoch sayısı arttıkça azalmaktadır. Bu, modelin tahminlerinin giderek daha doğru hale geldiğini göstermektedir. İki eğri arasındaki farkın az olması, doğruluk grafiğiyle tutarlı olarak aşırı öğrenmenin düşük olduğunu göstermektedir. Tablo 6’ da ($1e-2$, $1e-3$, $1e-4$) sabit öğrenme oranının aktivasyon fonksiyonları ile olan karşılaştırmalı performans metrikleri değerlendirilmiştir.

Tablo 6. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının Sabit Öğrenme Oranlarına Göre Performans Analizi

DEĞERLENDİRME METRİKLERİ						
			Cohen Kappa Puanı	Doğruluk	Kesinlik	Duyarlılık
$1e-2$	Eğitim Seti	Leaky ReLU	0,995	0,991	0,991	0,991
		ReLU	0,992	0,987	0,988	0,987
		ELU	0,996	0,992	0,992	0,992
	Doğrulama Seti	Leaky ReLU	0,865	0,806	0,800	0,806
		ReLU	0,845	0,764	0,784	0,764
		ELU	0,864	0,812	0,801	0,812
$1e-3$	Eğitim Seti	Leaky ReLU	0,822	0,705	0,770	0,705
		ReLU	0,862	0,772	0,816	0,772
		ELU	0,902	0,819	0,858	0,819
	Doğrulama Seti	Leaky ReLU	0,790	0,689	0,759	0,689
		ReLU	0,810	0,715	0,754	0,715
		ELU	0,830	0,746	0,772	0,746
$1e-4$	Eğitim Seti	Leaky ReLU	0,007	0,494	0,343	0,494
		ReLU	0,491	0,483	0,496	0,483
		ELU	0,414	0,493	0,624	0,493
	Doğrulama Seti	Leaky ReLU	0,009	0,495	0,425	0,495
		ReLU	0,432	0,446	0,473	0,446
		ELU	0,379	0,477	0,589	0,477


Tabloya detaylı bakıldığında özellikle doğrulama seti üzerindeki performansı göz önünde bulundurursak, $1e-3$ öğrenme oranında sırasıyla ELU 0,746, ReLU 0,715 ve Leaky ReLU 0,689 puanıyla diğer öğrenme oranlarına kıyasla daha iyi sonuçlar vermiştir. Tablonun geneline bakıldığında ELU, bazı durumlarda daha iyi olsa da, Leaky ReLU farklı senaryolarda tutarlı bir şekilde iyi sonuçlar vermiştir. $1e-2$ öğrenme oranında Leaky ReLU, ELU'ya göre aşırı öğrenme problemine karşı daha dirençli olduğu görülmektedir. $1e-2$ ve $1e-4$ öğrenme oranlarının performansı genel olarak değerlendirildiğinde doğrulama setlerinde düşük performanslar elde edilmiştir. Sonuç olarak $1e-3$ öğrenme oranında daha dengeli sonuçlar elde edilmiştir. Doğrulama setindeki performans da daha iyi olduğu için, bu veri seti için $1e-3$ öğrenme oranının daha uygun olduğu görülmektedir.

4.3. Öğrenme Oranı Planlaması ve OneCycleLR – ReLU, Leaky ReLU ve ELU-SGD

Analiz Sonuçları

Öğrenme oranı planlaması yöntemlerinden olan Cosine Annealing ReduceLRonPlateau ve One Cycle Policy yöntemlerinden olan OneCycleLR kullanılarak “Aptos” ön işlemeli veri seti üzerinde eğitim boyunca kullanılan üç farklı yöntemin model üzerindeki etkisi incelenmiş ve sonuçlar karşılaştırılmıştır. Tablo 7’de Cosine Annealing yönteminin aktivasyon fonksiyonları ile olan karşılaştırmalı kayıp ve doğrulama grafikleri değerlendirilmiştir.




Tablo 7. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının Cosine Annealing Yöntemine Göre Doğrulama ve Kayıp Grafikleri



Verilen grafikler, farklı aktivasyon fonksiyonları ve SGD optimizasyon algoritmasının bir sinir ağının performansı üzerindeki etkilerini görselleştirmektedir. Her üç kombinasyonun da hem doğrulama hem de eğitim doğruluğu yüksektir. Aşırı öğrenme belirtisi yoktur. Kayıp değeri de hızlı bir şekilde azalmaktadır. Leaky ReLU, ReLU ve ELU arasında küçük farklar olsa da genel olarak hepsi iyi sonuçlar vermiştir. Leaky ReLU-SGD çifti diğer kombinasyonlara göre daha düşük doğrulama doğruluğuna sahip olsa da Cosine Annealing'in öğrenme oranını

düzenleyerek modelin performansını iyileştirdiği, Leaky ReLU, ReLU ve ELU-SGD gibi kombinasyonların da farklı problemler için uygun olabileceği gözlemlenmiştir. Tablo 8’de OneCycleLR yönteminin aktivasyon fonksiyonları ile olan karşılaştırmalı kayıp ve doğrulama grafikleri değerlendirilmiştir.






Tablo 8. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının OneCycleLR Yöntemine Göre Doğrulama ve Kayıp Grafikleri

	Eğitim ve Doğrulama Doğruluk Grafığı	Eğitim ve Doğrulama Kayıp Grafikği
Leaky ReLU- SGD		
OneCycleLR ReLU-SGD		
ELU-SGD		

Grafikler değerlendirildiğinde eğitim doğruluğu, tüm grafiklerde yüksek olmasına rağmen, doğrulama doğruluğundaki dalgalanmalar, modelin genelleme yeteneğinin farklılık gösterdiğini ortaya koymaktadır. Tüm grafiklerde eğitim doğruluğunun yüksek olması, modelin eğitim verilerine aşırı uyum sağladığını, doğrulama doğruluğunun ise daha düşük ve dalgalı olması, modelin genelleme yeteneğinin sınırlı olduğunu göstermektedir. ReLU-SGD grafiği, en stabil performansı gösterirken, ELU-SGD grafiği diğerlerinden daha fazla aşırı uyum belirtileri taşımaktadır. Her üç algoritmanın kayıp grafiğine bakıldığında ise eğitim kaybının etkili bir şekilde düştüğü görülürken, doğrulama kaybındaki dalgalanmalar ve artışlar, modelin genelleme yeteneğinde sorunlar yaşadığını aşırı öğrenme riski taşıdığını göstermektedir. Tablo





9’da ReduceLROnPlateau (Factor: 0,1) yönteminin aktivasyon fonksiyonları ile olan karşılaştırmalı kayıp ve doğrulama grafikleri değerlendirilmiştir.

Tablo 9. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının ReduceLROnPlateau (Factor: 0.1) Yöntemine Göre Doğrulama ve Kayıp Grafikleri

	Eğitim ve Doğrulama Doğruluk Grafığı	Eğitim ve Doğrulama Kayıp Grafığı
Leaky ReLU-SGD		
ReduceLROnPlateau Factor: 0,1 ReLU-SGD		
ELU-SGD		

ReduceLROnPlateau (Factor : 0,1) için üç grafiğin de doğruluk değerlerinde belirgin bir artış gözlemlenmektedir, ancak ReLU-SGD, bu artışın dengeli ve etkili şekilde sağlandığı, hem eğitim hem de doğrulama doğruluğunda en iyi dengeyi sağlayan grafik olduğu görülmektedir. Eğitim kaybı, her üç grafikte de belirgin bir azalma göstermektedir, bu da modelin eğitim verisi üzerindeki öğrenme sürecinin etkili olduğunu göstermektedir. Doğrulama kaybı (mavi çizgi) tüm grafiklerde başlangıçta yüksektir ancak zamanla düşüş göstermektedir. Ancak kayıpların düşüş hızları ve son değerleri arasında farklılıklar vardır: ReLU ve Leaky ReLU için, doğrulama kaybı eğitim kaybına yakın bir seyir izlerken, ELU için grafik daha yavaş bir düşüş göstermektedir. Tablo 10’da ReduceLROnPlateau(Factor: 0,2) yönteminin aktivasyon fonksiyonları ile olan karşılaştırmalı kayıp ve doğrulama grafikleri değerlendirilmiştir.







Tablo 10. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının ReduceLRonPlateau (Factor: 0,2) Yöntemine Göre Doğrulama ve Kayıp Grafikleri

	Eğitim ve Doğrulama Doğruluk Grafığı	Eğitim ve Doğrulama Kayıp Grafığı	
Leaky ReLU-SGD			
ReduceLRonPlateau Factor: 0,2	ReLU-SGD		
	ELU-SGD		

ReduceLRonPlateau (Factor : 0,2) için eğitim doğruluğu her üç grafikte de belirgin bir artış göstermiştir. Başlangıçta Leaky ReLU ve ELU’da %10 seviyelerinde olan eğitim doğruluğu, ELU-SGD’de %80 seviyelerine kadar ulaşmıştır. Bu, modelin eğitim verisi üzerinde etkili bir öğrenme sağladığını göstermektedir. Doğrulama doğruluğu da her üç grafikte başlangıçta düşük seviyelerde başlamış, fakat zamanla artış göstermiştir. ELU-SGD’de doğrulama doğruluğu %75 seviyelerine ulaşmıştır. Bu, modelin genel performansını artırma potansiyelini göstermektedir. Tüm grafiklerde eğitim kaybı düşmekte, ancak doğrulama kaybı Leaky ReLU-SGD’de daha yüksek kalmaktadır. ReLU ve ELU’da grafiklerde eğitim kaybı daha düşük seviyelere inmiştir, bu da modelin eğitim verisi üzerindeki performansının arttığını göstermektedir. ReLU ve Leaky ReLU için, eğitim kaybı ve doğrulama kaybı arasındaki fark daha az belirginken, ELU için grafikte fark daha belirgin olarak görülmektedir. Eğitim ve doğrulama kaybı arasındaki fark, modelin aşırı uyum riski taşıdığını düşündürebilir, ancak her iki kayıp da zamanla azalmaktadır. Tablo 11’de ReduceLRonPlateau (Factor: 0,5) yönteminin

aktivasyon fonksiyonları ile olan karşılaştırmalı kayıp ve doğrulama grafikleri değerlendirilmiştir.

Tablo 11. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının ReduceLRonPlateau (Factor: 0,5) Yöntemine Göre Doğrulama ve Kayıp Grafikleri

	Eğitim ve Doğrulama Doğruluk Grafığı	Eğitim ve Doğrulama Kayıp Grafığı	
Leaky ReLU- SGD			
ReduceLRonPlateau Factor: 0,5	ReLU-SGD		
	ELU-SGD		

ReduceLRonPlateau (Factor : 0,5) Tüm grafiklerde eğitim doğruluğu başlangıçta düşük başlamış ve zamanla %70 seviyelerine ulaşmıştır.Bu durum modelin eğitim sürecinde zamanla daha iyi bir öğrenme sağladığını göstermektedir.Leaky ReLU’da doğrulama doğruluğu başlangıçta düşük kalmış, %65 civarına yükselmiştir. Eğitim doğruluğuna göre daha düşük kalmıştır.İkinci grafikte doğrulama doğruluğu %65 civarında artış göstermiştir, ancak dalgalanma gözlemlenmiştir. Üçüncü grafikte doğrulama doğruluğu %65 seviyelerinde stabilize olmuş, eğitim doğruluğuna yaklaşmıştır. Leaky ReLU’da daha belirgin olan aşırı uyum riski, sonraki grafiklerde azalmış ve ELU’da eğitim ve doğrulama doğruluğunun birbirine yakın seviyelerde kalması, modelin genelleme yeteneğinin arttığını göstermektedir. Eğitim kaybının doğrulama kaybına göre daha hızlı bir şekilde düşmesi, modelin eğitim verisine iyi uyum sağladığını, ancak doğrulama verisinde daha yavaş bir iyileşme gösterdiğini işaret etmektedir.

Tablo 12’de çalışmada kullanılan öğrenme oranı belirleme yöntemlerinin tamamının aktivasyon fonksiyonları ile olan karşılaştırmalı performans metrikleri değerlendirilmiştir.

Tablo 12. ReLU, Leaky ReLU ve ELU-SGD Algoritmalarının ReduceLRonPlateau- Cosine Annealing- OneCycleLR’e Göre Performans Metrikleri

DEĞERLENDİRME METRİKLERİ			Cohen Kappa Puanı	Doğruluk	Kesinlik	Duyarlılık	F1 Puanı
Cosine Annealing	Eğitim Seti	Leaky ReLU	0,539	0,595	0,719	0,595	0,578
		ReLU	0,630	0,651	0,754	0,651	0,639
		ELU	0,802	0,664	0,767	0,664	0,632
	Doğrulama Seti	Leaky ReLU	0,519	0,577	0,641	0,577	0,542
		ReLU	0,621	0,636	0,662	0,636	0,629
		ELU	0,763	0,629	0,724	0,629	0,609
OneCycleLR	Eğitim Seti	Leaky ReLU	0,987	0,982	0,983	0,982	0,982
		ReLU	0,996	0,991	0,992	0,991	0,992
		ELU	0,994	0,990	0,991	0,990	0,991
	Doğrulama Seti	Leaky ReLU	0,820	0,735	0,770	0,735	0,743
		ReLU	0,859	0,791	0,785	0,791	0,781
		ELU	0,855	0,780	0,786	0,780	0,778
ReduceLRonPlateau Factor: 0,1	Eğitim Seti	Leaky ReLU	0,581	0,677	0,704	0,677	0,644
		ReLU	0,820	0,692	0,773	0,692	0,669
		ELU	0,856	0,747	0,810	0,747	0,746
	Doğrulama Seti	Leaky ReLU	0,599	0,659	0,676	0,659	0,633
		ReLU	0,773	0,645	0,738	0,645	0,630
		ELU	0,799	0,704	0,759	0,704	0,709
ReduceLRonPlateau Factor: 0,2	Eğitim Seti	Leaky ReLU	0,833	0,686	0,770	0,686	0,668
		ReLU	0,845	0,732	0,777	0,732	0,728
		ELU	0,914	0,844	0,869	0,844	0,845
	Doğrulama Seti	Leaky ReLU	0,784	0,649	0,724	0,649	0,638
		ReLU	0,789	0,692	0,737	0,692	0,695
		ELU	0,848	0,765	0,781	0,765	0,768
ReduceLRonPlateau Factor: 0,5	Eğitim Seti	Leaky ReLU	0,780	0,670	0,749	0,670	0,645
		ReLU	0,835	0,694	0,773	0,694	0,679
		ELU	0,857	0,756	0,801	0,756	0,753
	Doğrulama Seti	Leaky ReLU	0,750	0,622	0,712	0,622	0,612
		ReLU	0,795	0,659	0,723	0,659	0,652
		ELU	0,801	0,697	0,737	0,697	0,699

Cosine Annealing performans metrikleri ve Tablo 7’deki doğrulama ve kayıp grafikleri birlikte incelendiğinde, ELU (0,629) ve ReLU (0,636) aktivasyon fonksiyonlarının doğrulama ve eğitim doğruların giderek artması buna paralel olarak eğitim ve doğrulama kayıp çizgilerinin

zamanla azalma göstermesi aynı zamanda diğer fonksiyona göre daha yüksek Cohen Kappa, doğruluk, kesinlik ve duyarlılık değerlerine sahip olduğu görülmektedir.

OneCycleLR performans metrikleri ve Tablo 8'deki doğrulama ve kayıp grafikleri birlikte incelendiğinde ELU (0,780) ve ReLU (0,791) aktivasyon fonksiyonlarının daha iyi performans gösterdiği ancak tüm grafikler genel olarak değerlendirildiğinde eğitim kaybının düşmesine rağmen doğrulama kaybının yüksek kalması aynı zamanda kayıp grafiğinin de stabil olmaması modelin aşırı uyum riski taşıdığını göstermektedir. Bu durum, modelin daha iyi genelleme yapabilmesi için iyileştirmelere ihtiyaç duyduğunu ortaya koymaktadır.

ReduceLROnPlateau için performans metrikleri ve Tablo 9,10 ve 11'daki doğrulama ve kayıp grafikleri birlikte incelendiğinde çizgi grafiklerinin arasındaki mesafenin az olması aynı zamanda eğitim ve doğrulama doğruluğunun epoch (tur) sayısına bağlı olarak arttığını kayıp grafiğinin de buna bağlı olarak azalma eğiliminde olduğu görülmektedir.

Factor (0,1)'de ELU (0,704), Leaky ReLU (0,659), ReLU (0,645),

Factor (0,2)'de ELU (0,765), ReLU (0,692), Leaky ReLU (0,649),

Factor (0,5)'de ELU (0,697), ReLU (0,659), Leaky ReLU (0,622)






doğruluk oranıyla üç değer için de en yüksek performans değerini ELU elde etmiştir.

Derin öğrenme modeli eğitim sürecinde; Sabit Öğrenme Oranı, Cosine Annealing, ReduceLROnPlateau ve OneCycleLR yöntemlerinin hepsi daha hızlı ve etkili bir öğrenme sağlamak, aşırı uyumu azaltmak ve genel performansı artırmak için model üzerinde denenmiş olup ReLU-SGD ve Leaky ReLU-SGD kombinasyonu için kullanılacak veri setinde en yüksek değer 1e-3 sabit öğrenme oranı için sırasıyla 0,715 ve 0,689 olduğu ELU-SGD kombinasyonu için de öğrenme oranını dinamik bir şekilde ayarlayan yöntemlerden biri olan ReduceLROnPlateau yönteminin Factor (0,2) parametresinde 0,765 ile en yüksek performansı sergilediği saptanmıştır.

4.4. ReLU, Leaky ReLU ve ELU-Momentum Analiz Sonuçları

Her aktivasyon fonksiyonu için öğrenme oranı seçiminde kullanılan yöntemler içinde bulunan en yüksek değer, Momentum optimizasyon algoritmasıyla beraber tekrar eğitime tabi tutulmuş ve çıkan sonuçlar değerlendirilmiştir.


Tablo 13. ReLU, Leaky ReLU ve ELU-Momentum Algoritmalarının Doğrulama ve Kayıp Grafikleri

	Eğitim ve Doğrulama Doğruluk Grafığı	Eğitim ve Doğrulama Kayıp Grafığı
Leaky ReLU- Momentum		
3662 Veri Seti		
ReLU Momentum		
ELU Momentum		

Yukarıda 3662 ön işlenmiş Aptos diyabetik retinopati fundus görüntüsü Leaky ReLU ve ReLU aktivasyon fonksiyonu $1e-3$ sabit öğrenme oranıyla ELU aktivasyon fonksiyonu ise ReduceLROnPlateau yönteminin Factor (0,2) parametresi ve öğrenme oranı planlamasıyla Momentum optimizasyon algoritması kullanılarak model eğitilmiş olup doğruluk ve kayıp grafikleri elde edilmiştir. Bu sonuca göre değerlendirildiğinde üç grafik için de doğruluk grafiği incelendiğinde performans, zamanla artıyor ancak hala doğrulama doğruluğu, eğitim doğruluğuna ulaşamamıştır. Aynı zamanda oluşan dalgalanma, iyileşme potansiyelini azaltmaktadır. Tüm grafiklerde, eğitim kaybının sürekli düşmesine rağmen doğrulama kaybının dalgalanması ve artması aşırı uyum riskini açıkça göstermektedir. Model, eğitim verilerine çok iyi uyum sağlarken, doğrulama verileri üzerinde zayıf bir performans sergilemektedir.

Grafiklerde gözlemlenen aşırı uyumu önlemek için veri artırma teknikleri, L2 düzenleştirmesi gibi teknikler uygulanarak genelleştirme yeteneğinin artırılması ile ilgili model eğitimi Tablo 14'te verilmiştir.

Tablo 14. ReLU, Leaky ReLU ve ELU-Momentum Algoritmalarının Doğrulama ve Kayıp Grafikleri




7915 diyabetik retinopati fundus görüntülerinden oluşturulan özgün veri seti, Leaky ReLU ve ReLU aktivasyon fonksiyonu $1e-3$ sabit öğrenme oranıyla ELU aktivasyon fonksiyonu ise ReduceLROnPlateau yönteminin Factor (0,2) parametresi ve öğrenme oranı planlamasıyla Momentum optimizasyon algoritması kullanılmıştır. Buna ek olarak Tablo 13'de çıkan aşırı uyum probleminin çözümü için veri artırma teknikleri ve L2 düzenleştirmesi uygulanarak model eğitilmiş olup doğruluk ve kayıp grafikleri elde edilmiştir. Bu bağlamda grafikler değerlendirildiğinde eğitim ve doğrulama doğruluğunda gözlemlenen benzer artış, modelin hem eğitim hem de doğrulama setlerinde iyi bir performans sergilediğini göstermektedir. Grafik

genel olarak, doğrulama kaybının, eğitim kaybına oldukça yakın bir değerde seyrettiğini ve küçük farklılıklar olduğunu göstermektedir. Bu durum, modelin genelleme kabiliyetinin iyi olduğunu ve aşırı öğrenme riskinin düşük olduğunu göstermektedir. Doğrulama doğruluğunun belirli bir seviyede stabil hale gelmesi, modelin öğrenme sürecinin olgunlaştığını ve genelleme yeteneğinin iyi olduğuna işaret etmektedir. Tablo 15'te ReLU, Leaky ReLU ve ELU-Momentum algoritmalarının 7915 veri seti için performans metrikleri verilmiştir.

Tablo 15. ReLU, Leaky ReLU ve ELU-Momentum Algoritmalarının Performans Metrikleri

DEĞERLENDİRME METRİKLERİ							
			Cohen Kappa Puanı	Doğruluk	Kesinlik	Duyarlılık	F1 Puanı
7915 Veri Seti	Eğitim Seti	Leaky ReLU	0,920	0,831	0,837	0,831	0,831
		ReLU	0,941	0,857	0,863	0,857	0,857
		ELU	0,948	0,873	0,873	0,873	0,873
	Doğrulama Seti	Leaky ReLU	0,882	0,751	0,765	0,751	0,751
		ReLU	0,904	0,786	0,793	0,786	0,786
		ELU	0,889	0,766	0,765	0,766	0,765


Yukarıda belirtilen 7915 özgün veri setinden oluşturulan modelin değerlendirme metrikleri incelendiğinde, Tablo 14'teki doğrulama ve kayıp grafikleri de göz önünde bulundurularak, ReLU aktivasyon fonksiyonu 0,786 doğruluk ve F1 skoru ile en yüksek performansı sergilemiştir, Bunun yanı sıra, Leaky ReLU aktivasyon fonksiyonu ise 0,751 doğruluk ve F1 skoru ile takip eden en yüksek değer olarak belirlenmiştir, Şekil 27 ve 28'de ReLU ve Leaky ReLU modeline ait karışıklık matrisi verilmiştir.



Şekil 27. 7915 Veri Seti ReLU-Momentum Karışıklık Matrisi

Şekil 27 incelendiğinde ilk satırda “0-Normal” fundus göz görüntüsü sınıflandırılırken 15 tanesi yanlış, “1-Hafif” için 64’ü yanlış, “2-Orta” sınıfı için 106, “3-Şiddetli” sınıfında 56 ve “4-Proliferatif” sınıfı için ise toplam 98 adet sınıfın yanlış sınıflandırıldığı görülmektedir,

Genel olarak değerlendirildiğinde, model en iyi 0-Normal ve 3-Şiddetli kategorideki örnekleri sınıflandırmayı başarırken, 2-Orta ve 4-Proliferatif kategorisindeki örnekleri daha fazla yanlış sınıflandırma yapmaktadır,



Şekil 28. 7915 Veri Seti Leaky ReLU-Momentum Karışıklık Matrisi

Şekil 28 incelendiğinde ilk satırda “0-Normal” fundus göz görüntüsü sınıflandırılırken 17 tanesi yanlış, “1-Hafif” için 80’i yanlış, “2-Orta” sınıfı için 128, “3-Şiddetli” sınıfında 123 ve “4-Proliferatif” sınıfı için ise toplam 46 adet sınıfın yanlış sınıflandırıldığı görülmektedir. Genel olarak değerlendirildiğinde, model en iyi 0-Normal ve 4-Proliferatif kategorideki örnekleri sınıflandırmayı başarırken, 2-Orta ve 3-Şiddetli kategorisindeki örnekleri daha fazla yanlış sınıflandırma yapmaktadır.

SONUÇ

Diyabetik retinopati, diyabet hastalarında körlüğe yol açabilen önemli bir komplikasyondur, Erken teşhis ve tedavi, görme kaybını önlemede kritik öneme sahiptir, Yapay zekâ teknolojileri, özellikle göz taramaları ve görüntü analizi alanlarında, diyabetik retinopati gibi ciddi görme sorunlarıyla mücadelede etkili çözümler sunabilir, Yapay zekâ tabanlı modeller, diyabetik retinopati riski taşıyan hastaları belirleyerek, zamanında müdahale ve önleyici bakım sağlanmasına yardımcı olabilir, Çalışmada, normal, hafif, orta, şiddetli ve proliferatif fundus göz görüntülerinden oluşan 3662 Aptos veri seti ve 7915 görselden oluşan 5 sınıflı özgün bir veri seti hazırlanmıştır, Çalışmada iki farklı veri seti kullanılarak evrimsel sinir ağı modellerinde bazı hiper parametrelerin sınıflandırma performansı üzerindeki etkileri incelenmiştir, Çalışma için değerlendirilen hiper parametreler; öğrenme oranı belirleme yöntemlerinden olan sabit öğrenme oranı, öğrenme oranı planlaması (Cosine Annealing, ReduceLROnPlateau), One Cycle Policy (OneCycleLR), aktivasyon fonksiyonları, L2 Düzenleme (Regularization), Veri Artırma (Data Augmentation) yöntemlerinden olan rastgele açıyla döndürme, rastgele yatay çevirme, rastgele dikey çevirme işlemleri ve optimizasyon algoritmalarıdır, Veri seti sınıflandırma başarısını değerlendirmek için görüntüye çeşitli (Gri tonlama, yeniden boyutlandırma, Maskeleme ve Gauss Bulanıklığı, Dairesel Kırpm) ön işleme adımları uygulanarak transfer öğrenme yaklaşımı ile eğitim yapılmıştır, Transfer öğrenme bağlamında, ResNet34 modeli kullanılmıştır, İlk olarak Kaggle platformunda yayınlanan 3662 fundus göz görüntüsünden oluşan “Aptos Blindness Detection” veri seti üzerinde Leaky ReLU, ReLU ve ELU aktivasyon fonksiyonu ve SGD optimizasyon algoritması üzerinde yapılan karşılaştırmalar sonucu yüksek başarı sağlayan öğrenme oranı yöntemi kullanılarak model eğitilmiştir, Daha sonra “Eyepacs, Aptos ve Messidor” veri tabanlarından oluşturulan 7915 veri seti üzerinde veri artırma teknikleri, L2 regülerizasyon kullanılarak SGD/Momentum optimizasyon algoritmasıyla tekrar eğitime tabi tutulmuş olup çıkan sonuçlar neticesinde başlangıç değerine göre ReLU % 9,93, Leaky ReLU %8,99 oranında bir yükselme göstermiştir, Bunun sonucunda Resnet34 modeli kullanılarak ön işleme yapılarak oluşturulan özgün veri seti üzerinde eğitilen modelde aktivasyon fonksiyonları içerisinde sırasıyla ReLU 0,786 doğruluk, 0,786 F1-skoru, Leaky ReLU 0,751 doğruluk, 0,751 F1-skoru ile en yüksek başarıyı elde etmişlerdir,

Bu sonuçlar, uygun hiper parametre kombinasyonlarının seçilmesi ve ön işleme adımlarının model performansını artırabileceğini ve doğru aktivasyon fonksiyonu ve optimizasyon algoritmasının seçiminin önemini vurgulamaktadır, Diyabetik retinopati teşhisinde yapay zekâ tabanlı sistemlerin klinik uygulamalarda potansiyel olarak değerli bir rol oynayabileceğini göstermektedir.

Gelecek çalışmalarda görüntüler dışında, biyometrik veriler, hasta geçmişi gibi diğer veri kaynakları da yapay zekâ modellerine entegre edilebilir, Özellikle kırsal alanlardaki hastaların erişimini kolaylaştırmak için gerçek zamanlı ve mobil cihazlarda çalışabilen sistemler geliştirilebilir, Bu yönde yapılacak çalışmalar, DR tespitinde yapay zekâ tabanlı sistemlerin klinik uygulamadaki etkinliğini artırabilir ve görme kaybı riskini azaltmada kritik bir rol oynayabilir, Modelin genelleştirme performansını artırmak için de ek iyileştirmeler yapılması, örneğin evrişimsel katmanların değiştirilmesi, katman ve nöron sayısını modele uygun bir şekilde ayarlanması, ince ayar (fine-tuning) teknikleri kullanılması veya farklı mimariler denenmesi faydalı olabilir, Bu çalışmada olduğu gibi gelecek çalışmalarda uygun hiper parametre kombinasyonlarının seçilmesi, derin öğrenme veya makine öğrenmesi modellerinin performansını önemli ölçüde artırabilir.

KAYNAKÇA

- Adem, K. (2022). Impact of activation functions and number of layers on detection of exudates using circular Hough transform and convolutional neural networks. *Expert Systems with Applications*, 203, 117583. <https://doi.org/10.1016/j.eswa.2022.117583>
- Adem, K., Hekim, M., Comert, O., & Demir, S. (2016). A Novel Approach to Method for the Detection of Optic Disc Location in Retinal Images using Image Processing Techniques. *Journal of New Results in Science*, 5, 41-47. <https://dergipark.org.tr/en/pub/jnrs/issue/27333/287727>
- Adweb, K. M. A., Cavus, N., & Sekeroglu, B. (2021). Cervical cancer diagnosis using very deep networks over different activation functions. *Ieee Access*, 9, 46612-46625. <https://10.1109/ACCESS.2021.3067195>
- Albawi, S., Bayat, O., Al-Azawi, S., & Ucan, O. N. (2018). Social touch gesture recognition using convolutional neural network. *Computational Intelligence and Neuroscience*, 2018(1), 6973103. <https://doi.org/10.1155/2018/6973103>
- Alyoubi, W. L., Shalash, W. M., & Abulkhair, M. F. (2020). Diabetic retinopathy detection through deep learning techniques: A review. *Informatics in Medicine Unlocked*, 20, 100377. <https://doi.org/10.1016/j.imu.2020.100377>
- Arel, I., Rose, D. C., & Karnowski, T. P. (2010). Research frontier: deep machine learning--a new frontier in artificial intelligence research. *IEEE computational intelligence magazine*, 5(4), 13-18. <https://doi.org/10.1109/MCI.2010.938364>
- Bellemo, V., Lim, G., Rim, T. H., Tan, G. S., Cheung, C. Y., Sadda, S., ... & Ting, D. S. W. (2019). Artificial intelligence screening for diabetic retinopathy: the real-world emerging application. *Current Diabetes Reports*, 19, 1-12. <https://doi.org/10.1007/s11892-019-1189-3>
- Brigato, L., Barz, B., Iocchi, L., & Denzler, J. (2022). Image classification with small datasets: Overview and benchmark. *IEEE Access*, 10, 621-630. <https://doi.org/10.1109/ACCESS.2022.3172939>

- Brownlee, J. (2018). What is the Difference Between a Batch and an Epoch in a Neural Network. *Machine learning mastery*, 20. <https://machinelearningmastery.com/difference-between-a-batch-and-an-epoch/>
- Chen, P. N., Lee, C. C., Liang, C. M., Pao, S. I., Huang, K. H., & Lin, K. F. (2021). General deep learning model for detecting diabetic retinopathy. *BMC bioinformatics*, 22, 1-15. <https://doi.org/10.1186/s12859-021-04005-x>
- Chen, T., Li, M., Li, Y., Lin, M., Wang, N., Wang, M., ... & Zhang, Z. (2015). MXNet: A flexible and efficient machine learning library for heterogeneous distributed systems. *Proceedings of Neural Information Processing Systems (NIPS)*. <https://doi.org/10.48550/arXiv.1512.01274>
- Daşgın, A., Adem, K., & Kılıçarslan, S. (2023). Covid19 Yayilimini Azaltmak İçin Yüz Maskesinin Evrişimsel Sinir Ağı Modelleri ile Tespiti. *Journal of the Institute of Science and Technology*, 13(3), 1511-1527. <https://doi.org/10.21597/jist.1251058>
- Dubey, A. K., Sinhal, A. K., & Sharma, R. (2024). Heart disease classification through crow intelligence optimization-based deep learning approach. *International Journal of Information Technology*, 16(3), 1815-1830. <https://doi.org/10.1007/s41870-023-01445-x>
- Durães, D., Veloso, B., & Novais, P. (2023). Violence detection in audio: evaluating the effectiveness of deep learning models and data augmentation, 72-84. <https://doi.org/10.9781/ijimai.2023.08.007>
- Dutta, S., Manideep, B. C., Basha, S. M., Caytiles, R. D., & Iyengar, N. C. S. N. (2018). Classification of diabetic retinopathy images by using deep learning models. *International Journal of Grid and Distributed Computing*, 11(1), 89-106. <http://dx.doi.org/10.14257/ijgdc.2018.11.1.09>
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118. <https://doi.org/10.1038/nature21056>
- Goodfellow, Yoshua Bengio & Aaron Courville. *Deep Learning*. MIT Press, 2016.

- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377. <https://doi.org/10.1016/j.patcog.2017.10.013>
- Hao, W., Yizhou, W., Yaqin, L., & Zhili, S. (2020, 18-20 Aralık). *The role of activation function in CNN* [Bildiri sunumu]. In 2020 2nd International Conference on Information Technology and Computer Application (ITCA), Guangzhou, China.
- Hastomo, W., Karno, A. S. B., Kalbuana, N., & Meiriki, A. (2020, 12-13 Ağustos). *Characteristic parameters of epoch deep learning to predict Covid-19 data in Indonesia* [Bildiri sunumu]. Virtual Conference on Engineering, Science and Technology (ViCEST), Kuala Lumpur, Malaysia.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016, 27-30 Haziran). *Deep residual learning for image recognition*. [Bildiri sunumu]. In Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR), Las Vegas, Nevada, ABD.
- Hinton, G., Srivastava, N., & Swersky, K. (2012). Neural networks for machine learning lecture 6a overview of mini-batch gradient descent. *Cited on*, 14(8), 2. <https://www.cs.toronto.edu/~hinton/coursera/lecture6/lec6.pdf>
- Hossin, M., & Sulaiman, M. N. (2015). A review on evaluation metrics for data classification evaluations. *International journal of data mining & knowledge management process*, 5(2), 1-11. <https://doi.org/10.5121/ijdkp.2015.5201>
- Huang, Q., Hao, B., & Chang, S. (2016). Adaptive digital ridgelet transform and its application in image denoising. *Digital Signal Processing*, 52, 45-54. <https://doi.org/10.1016/j.dsp.2016.02.004>
- Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., & Darrell, T. (2014, 3-7 Kasım). *Caffe: Convolutional architecture for fast feature embedding* [Bildiri sunumu]. In Proceedings of the 22nd ACM international conference on Multimedia, Suzhou, Çin.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25. <https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks>

- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Leeza, M., & Farooq, H. (2019). Detection of severity level of diabetic retinopathy using Bag of features model. *IET Computer Vision*, 13(5), 523-530. <https://doi.org/10.1049/iet-cvi.2018.5263>
- Li, B., & Li, H. K. (2013). Automated analysis of diabetic retinopathy images: principles, recent developments, and emerging trends. *Current Diabetes Reports*, 13(4), 453–459. <https://doi.org/10.1007/S11892-013-0393-9>
- Li, T., Bo, W., Hu, C., Kang, H., Liu, H., Wang, K., & Fu, H. (2021). Applications of deep learning in fundus images: A review. *Medical Image Analysis*, 69, 101971. <https://doi.org/10.1016/j.media.2021.101971>
- Liu, Z., Li, X., Kang, B., & Darrell, T. (2019). Regularization matters in policy optimization. *arXiv preprint arXiv:1910.09191*, 1-44. <https://doi.org/10.48550/arXiv.1910.09191>
- Loshchilov, I., & Hutter, F. (2016). Sgdr: Stochastic gradient descent with warm restarts. *arXiv preprint arXiv:1608.03983*. <https://doi.org/10.48550/arXiv.1608.03983>
- Loshchilov, I., & Hutter, F. (2017). Decoupled weight decay regularization. *arXiv preprint arXiv:1711.05101*.
- Mansour, R. F. (2018). Deep-learning-based automatic computer-aided diagnosis system for diabetic retinopathy. *Biomedical engineering letters*, 8, 41-57. <https://doi.org/10.1007/s13534-017-0047-y>
- Nair, V., & Hinton, G. E. (2010, 21-26 Haziran). *Rectified linear units improve restricted boltzmann machines* [Bildiri sunumu]. In Proceedings of the 27th international conference on machine learning (ICML-10), Haifa, Israil.
- Ng, A. Y. (2004, 4-8 Temmuz). *Feature selection, L_1 vs. L_2 regularization, and rotational invariance* [Bildiri sunumu]. In Proceedings of the twenty-first international conference on Machine learning, Banff, Kanada.
- Omidvar, S., & Tran, T. (2023). Tackling cold-start with deep personalized transfer of user preferences for cross-domain recommendation. *International Journal of Data Science and Analytics*, 1-10. <https://doi.org/10.1007/s41060-023-00467-9>

- O'shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*. <https://doi.org/10.48550/arXiv.1511.08458>
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., ... & Chintala, S. (2019). PyTorch: An imperative style, high-performance deep learning library. *Advances in Neural Information Processing Systems*, 32. <https://pytorch.org/>
- Phaisangittisagul, E. (2016, 18-20 Ocak). *An analysis of the regularization between L2 and dropout in single hidden layer neural network* [Bildiri sunumu]. In 2016 7th International Conference on Intelligent Systems, Modelling and Simulation (ISMS), Bangkok, Tayland.
- Pratt, H. (2020). *PraDeep Learning for Diabetic Retinopathy Diagnosis & Analysis*. (Tez No. 27680826) [Doktora Tezi, The University of Liverpool (United Kingdom)]. ProQuest Dissertations & Theses
- Rajput, G., Agrawal, S., Biyani, K., & Vishvakarma, S. K. (2022). Early breast cancer diagnosis using cogent activation function-based deep learning implementation on screened mammograms. *International Journal of Imaging Systems and Technology*, 32(4), 1101-1118. <https://doi.org/10.1002/ima.22701>
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386-408. <https://doi.org/10.1037/h0042519>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>
- Saleh, M. D., & Eswaran, C. (2012). An automated decision-support system for non-proliferative diabetic retinopathy disease based on MAs and HAs detection. *Computer methods and programs in biomedicine*, 108(1), 186-196. <https://doi.org/10.1016/j.cmpb.2012.03.004>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Shakibania, H., Raoufi, S., Pourafkham, B., Khotanlou, H., & Mansoorizadeh, M. (2024). Dual branch deep learning network for detection and stage grading of diabetic

- retinopathy. *Biomedical Signal Processing and Control*, 93, 106168. <https://doi.org/10.1016/j.bspc.2024.106168>
- Shinde, P. P., & Shah, S. (2018, 16-18 Ağustos). *A review of machine learning and deep learning applications* [Bildiri sunumu]. In 2018 Fourth international conference on computing communication control and automation (ICCUBE), Pune, Hindistan.
- Singh, N., & Tripathi, R. C. (2010). Automated early detection of diabetic retinopathy using image analysis techniques. *International Journal of Computer Applications*, 8(2), 18-23.
- Smith, L. N. (2018). A disciplined approach to neural network hyper-parameters: Part 1-- learning rate, batch size, momentum, and weight decay. *arXiv preprint arXiv:1803.09820*. <https://doi.org/10.48550/arXiv.1803.09820>
- Suárez-Paniagua, V., & Segura-Bedmar, I. (2018). Evaluation of pooling operations in convolutional architectures for drug-drug interaction extraction. *BMC bioinformatics*, 19, 39-47. <https://doi.org/10.1186/s12859-018-2195-1>
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., & Liu, C. (2018, 5-7 Eylül). *A Survey on Deep Transfer Learning* [Bildiri sunumu]. In International Conference on Artificial Neural Networks, Rhodes, Yunanistan.
- Team, T. T. D., Al-Rfou, R., Alain, G., Almahairi, A., Angermueller, C., Bahdanau, D., ... & Zhang, Y. (2016). Theano: A Python framework for fast computation of mathematical expressions. *arXiv preprint arXiv:1605.02688*. <https://doi.org/10.48550/arXiv.1605.02688>
- TensorFlow Developers. (2023, 10 Haziran). “*TensorFlow (Version 2.10)*”. Erişim: 10.06.2024. <https://www.tensorflow.org/>
- Thakur, A., Gupta, M., Sinha, D. K., Mishra, K. K., Venkatesan, V. K., & Guluwadi, S. (2024). Transformative breast Cancer diagnosis using CNNs with optimized ReduceLROnPlateau and Early stopping Enhancements. *International Journal of Computational Intelligence Systems*, 17(1), 1-18. <https://doi.org/10.1007/s44196-023-00397-1>

- Ting, D. S., Peng, L., Varadarajan, A. V., Keane, P. A., Burlina, P. M., Chiang, M. F., ... & Wong, T. Y. (2019). Deep learning in ophthalmology: the technical and clinical considerations. *Progress in retinal and eye research*, 72, 100759. <https://doi.org/10.1016/j.preteyeres.2019.04.003>
- Toğaçar, M. (2021). Detection of segmented uterine cancer images by Hotspot Detection method using deep learning models, Pigeon-Inspired Optimization, types-based dominant activation selection approaches. *Computers in Biology and Medicine*, 136, 104659. <https://doi.org/10.1016/j.combiomed.2021.104659>
- Wang, W., & Lo, A. C. (2018). Diabetic retinopathy: pathophysiology and treatments. *International journal of molecular sciences*, 19(6), 1816. <https://doi.org/10.3390/ijms19061816>
- Xie, M. K., Xiao, J., & Huang, S. J. (2022, 28 Kasım- 9 Aralık). *Label-aware global consistency for multi-label learning with single positive labels* [Bildiri sunumu]. Advances in Neural Information Processing Systems, New Orleans, Louisiana, ABD.
- Yacoub, R., & Axman, D. (2020, 16-20 Kasım). *Probabilistic extension of precision, recall, and f1 score for more thorough evaluation of classification models* [Bildiri sunumu]. In Proceedings of the first workshop on evaluation and comparison of NLP systems.
- Zaheer, R., & Shaziya, H. (2018, 18-19 Ocak). *GPU-based empirical evaluation of activation functions in convolutional neural networks* [Bildiri sunumu]. In 2018 2nd international conference on inventive systems and control (ICISC), Coimbatore, Hindistan.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)
- Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., ... & He, Q. (2020). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), 43-76. <https://doi.org/10.1109/JPROC.2020.3004555>

AKSARAY ÜNİVERSİTESİ TEZ DEĞERLENDİRME FORMU		
Öğrencinin Adı Soyadı:		Evet
Kapak		
1	Tez Başlığı tutanaktaki başlıkla aynı mı?	
2	Kapaktaki ay ve yıl savunmaya girilen tarihle tutarlı mı?	
3	Kapak format kılavuzdaki kapak formatına uygun mu?	
4	Kapakta yazılan tüm yazılar doğru olarak verilmiş mi?	
İçindekiler		
5	Sayfa numaraları tam verilmiş mi?	
6	Şekil, Çizelge vb. listeleri verilmiş mi? Sıralaması doğru mu?	
7	Özet, Abstract, Giriş, Sonuçlar vb. bölümler var mı?	
8	Yazım hataları kontrolü yapıldı mı?	
Giriş		
9	Hazırlanan tezin önemini anlatıyor mu?	
10	İkinci ve Üçüncü dereceden başlık içermemeli kuralına uyuldu mu?	
Özet/Abstract		
11	Kılavuza uygun mu?	
12	Ay ve yıl savunmaya girilen tarihle tutarlı mı?	
13	Özet; tek sayfa, tek aralık, tek paragraf kuralına uygun olarak yazıldı mı?	
14	Bilim kodu, sayfa adedi, anahtar kelimeler ve tez danışmanı yazıldı mı?	
Kaynakça		
15	Kaynakların tamamına metin içinde atıf yapıldı mı?	
16	Kaynak formatı kılavuzdaki kaynak formatına uygun olarak hazırlanmış mı?	
17	Atıf formatı kılavuzdaki atıf formatına uygun mu?	
Atıf Yöntemi APA 7 ☐ CMS ☐ İSNAD ☐		
Genel Değerlendirme		
18	Etik Beyan açıklaması okundu, uyuldu ve imzalandı mı?	
19	Kabul/Onay sayfası kılavuzdaki formata uygun olarak düzenlenmiş mi?	
20	Kabul /Onay sayfasında belirtilen oy birliği/oy çokluğu seçeneklerinden uygun olanı savunmayla tutarlı olacak şekilde belirlenmiş mi?	
21	Sayfa kenar boşlukları ve sayfa numaraları kılavuzdaki formatına uygun mu?	
22	Paragraf boşlukları ve metin satır aralığı kılavuza uygun olacak şekilde düzenlenmiş mi?	
23	Başlık yazımları kılavuzdaki başlık formatlarına uygun mu?	
24	Yazı tipi ve boyutu kılavuzdaki yazı tipi ve boyutu formatına uygun mu?	
25	Şekil, Çizelge vb. açıklama ve numaralandırmaları kılavuzdaki formata uygun olarak yazılmış mı?	

Danışman Adı Soyadı

İmza