



TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

**GENİŞLETİLMİŞ LATERAL İNHİBİSYON
YÖNTEMİYLE OCT VERİLERİ ÜZERİNDEN
RETİNAL HASTALIKLARIN
SINIFLANDIRILMASI**

Ruken ERDEM DEMİR

DOKTORA TEZİ

Prof. Dr. Kemal TURHAN

TRABZON-2025

BEYAN

Bu tez çalışmasının Karadeniz Teknik Üniversitesi Sağlık Bilimleri Enstitüsü Tez Hazırlama ve Yazım Kılavuzu standartlarına uygun olarak yapıldığını ve yazıldığını, tezin akademik ve etik kurallara bağlı kalınarak gerçekleştirilmiş özgün bir bilimsel araştırma eserim olduğunu, tezde yer alan ve bu tez çalışmasıyla elde edilmeyen tüm bilgi ve yorumlara kaynak gösterdiğimi ve kullanılan kaynakların kaynaklar listesinde yer aldığını, tezin çalışılması ve yazımı aşamalarda patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

.../.../2025
Ruken ERDEM DEMİR
(İmza)

İthaf

Bu doktora tezimi, benim bu günlere gelmem için hiçbir fedakârlıktan kaçınmayan ve her zaman yanımda olan sevgili aileme ithaf ediyorum.



TEŞEKKÜR

Doktora eğitimim boyunca tecrübelerinden her zaman faydalandığım, çalışmamda konu, kaynak ve yöntem açısından bana yardımda bulunarak yol gösteren tez danışmanım Sayın Prof. Dr. Kemal TURHAN'a saygı ve teşekkürlerimi sunarım.

Bilgi ve tecrübelerini içtenlikle paylaşan, her konuda desteğini, ilgisini gördüğüm değerli hocalarım Sayın Doç. Dr. Burçin KURT'a, Sayın Dr. Öğr. Üyesi Ayşe KABATAŞ'a,

Bilgi ve tecrübelerini içtenlikle paylaşan, kendilerinden çok şey öğrendiğim Dr. Müslüm YILDIZ'a,

Bana her açıdan destek ve yardımları için Arş. Gör. Dr. Sinem ÖZDEMİR'e, Arş. Gör. Mehmet Erşan KALAYCI'ya,

Üzerimde emeği olan tüm hocalarıma,

Sayılsız fedakârlık ve özverilerle beni bugünlere getiren babama, anneme ve kardeşlerime,

Ve son olarak benden desteğini ve sevgisini hiçbir zaman esirgemeyen eşim Haydar Kutlu DEMİR'e, kızım Fehime Yekbun DEMİR'e ve oğlum Berken Deniz DEMİR'e sonsuz sevgi, saygı ve teşekkürlerimi sunarım.

Ruken ERDEM DEMİR

İÇİNDEKİLER

Sayfa

İÇ KAPAK SAYFASI

ONAY

BEYAN

İthaf

TEŞEKKÜR

İÇİNDEKİLER

vi

TABLolar DİZİNİ

viii

ŞEKİLLER DİZİNİ

ix

KISALTMALAR, SİMGELER ve FORMÜLLER DİZİNİ

xi

ÖZET

xii

ABSTRACT

xiii

1. GİRİŞ ve AMAÇ

1

2. GENEL BİLGİLER

3

2.1. Optik Koherens Tomografi (OCT) ve Retina Görüntüleme

3

2.2. Retinal Hastalıklar ve Klinik Önemi

5

2.3. Bilgisayarlı Görü ve Derin Öğrenme Modelleri

8

2.3.1. Transfer Learning ve Popüler CNN Modelleri

11

2.3.1.1. DenseNet121

11

2.3.1.2. InceptionV3

13

2.3.1.3. ResNet50

14

2.3.1.4. Xception

14

2.4. Lateral İnhibisyon Mekanizması ve Sinirbilimdeki Yeri

16

2.5. Lateral İnhibisyon Temelli Konvolüsyonel Sinir Ağı (LICNN)

18

2.5.1. Mexican Hat Fonksiyonunun LICNN İçindeki Rolü

20

2.6. Literatürdeki Mevcut Çalışmalar ve Açık Araştırma Alanları

21

3. GEREÇ ve YÖNTEM

29

4. BULGULAR

46

4.1. DenseNet121

46

4.2. DenseNet121 + LICNN

51

4.3. InceptionV3

56

4.4. InceptionV3 + LICNN	58
4.5. ResNet50	63
4.6. ResNet50 + LICNN	66
4.7. Xception	70
4.8. Xception + LICNN	73
5. TARTIŞMA ve SONUÇ	78
6. KAYNAKLAR	82
ÖZGEÇMİŞ	91



TABLÖLER DİZİNİ

Tablo No	Sayfa
Tablo 1. DenseNet mimarisi	12
Tablo 2. Eğitim, Doğrulama ve Test setine ait sayısal değerler	33
Tablo 3. Karışıklık matrisi	37
Tablo 4. DenseNet121 modeli ile test veri kümesinden elde edilen sınıflandırma performans metrikleri (Kesinlik, Duyarlılık, F1-Skoru)	47
Tablo 5. DenseNet121 modeli (Lateral inhibisyon entegreli) ile test veri kümesinden elde edilen sınıflandırma performans metrikleri	52
Tablo 6. InceptionV3 modeli ile test veri kümesinden elde edilen sınıflandırma performans metrikleri (Kesinlik, Duyarlılık, F1-Skoru)	56
Tablo 7. InceptionV3 modeli (Lateral inhibisyon entegreli) ile test veri kümesinden elde edilen sınıflandırma performans metrikleri (Kesinlik, Duyarlılık, F1-Skoru)	59
Tablo 8. ResNet50 modeli ile test veri kümesinden elde edilen sınıflandırma performans metrikleri (Kesinlik, Duyarlılık, F1-Skoru)	64
Tablo 9. ResNet50 modeli (Lateral inhibisyon entegreli) ile test veri kümesinden elde edilen sınıflandırma performans metrikleri	66
Tablo 10. Xception modeli ile test veri kümesinden elde edilen sınıflandırma performans metrikleri	70
Tablo 11. Xception modeli (Lateral inhibisyon entegreli) ile test veri kümesinden elde edilen sınıflandırma performans metrikleri	73

ŞEKİLLER DİZİNİ

Şekil No		Sayfa
Şekil 1.	Oftalmoskoplara görülen retinanın görünümü	4
Şekil 2.	Retina hastalıklarına ait OCT görüntüleri	6
Şekil 3.	Yapay zeka, makine öğrenmesi, derin öğrenme, konvolüsyonel sinir ağları ve bilgisayarlı görü arasındaki ilişki	9
Şekil 4.	CNN mimarisi	10
Şekil 5.	InceptionV3 mimarisi	13
Şekil 6.	ResNet50 mimarisi	14
Şekil 7.	Xception mimarisi	16
Şekil 8.	Önerilen sınıflandırma modelinin genel mimarisi	29
Şekil 9.	OCT veri seti dağılımı	31
Şekil 10.	Veri seti dağılımı (Eğitim, Doğrulama, Test)	32
Şekil 11.	Veri seti örnek resimler	33
Şekil 12.	Eğitim, Doğrulama ve Test Setine ait sayısal değerler	34
Şekil 13.	ROC eğrisi	40
Şekil 14.	DenseNet121 modeli için test veri kümesine ait karışıklık matrisi	48
Şekil 15.	DenseNet121 modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri	50
Şekil 16.	DenseNet121 (Lateral inhibisyon entegreli) modeli için test veri kümesine ait karışıklık matrisi	53
Şekil 17.	DenseNet121 modeli (Lateral inhibisyon entegreli) için test verisinde elde edilen ROC eğrileri ve AUC değerleri	54
Şekil 18.	DenseNet121 modeli ve (Lateral inhibisyon entegreli) DenseNet121 skor karşılaştırmaları	55
Şekil 19.	Sınıflandırma modeline ait farklı konvolüsyonel katmanlardan elde edilen saliency map örnekleri	55
Şekil 20.	InceptionV3 modeli için test veri kümesine ait karışıklık matrisi	57
Şekil 21.	InceptionV3 modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri	58
Şekil 22.	InceptionV3 (Lateral inhibisyon entegreli) modeli için test veri kümesine ait karışıklık matrisi	60

Şekil 23.	InceptionV3 (Lateral inhibisyon entegreli) modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri	61
Şekil 24.	Eğitim süreci boyunca epoch bazlı doğruluk ve kayıp değerlerinin değişimi	62
Şekil 25.	InceptionV3 ve InceptionV3 + Lateral CNN modellerinin sınıf bazlı F1-skor ve doğruluk karşılaştırması	63
Şekil 26.	ResNet50 modeli için test veri kümesine ait karışıklık matrisi	65
Şekil 27.	ResNet50 modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri	66
Şekil 28.	ResNet50 (Lateral inhibisyon entegreli) modeli için test veri kümesine ait karışıklık matrisi	67
Şekil 29.	ResNet50 (Lateral inhibisyon entegreli) modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri	68
Şekil 30.	ResNet50 ve ResNet50 + Lateral CNN modellerinin F1-skor ve doğruluk karşılaştırması	69
Şekil 31.	Xception modeli için test veri kümesine ait karışıklık matrisi	71
Şekil 32.	Xception modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri	72
Şekil 33.	Xception (Lateral inhibisyon entegreli) modeli için test veri kümesine ait karışıklık matrisi	74
Şekil 34.	Xception (Lateral inhibisyon entegreli) modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri	75
Şekil 35.	Xception + Lateral Inhibisyon modeli için eğitim sürecine ait doğruluk ve kayıp eğrileri	76
Şekil 36.	Xception ve Xception + Lateral CNN modellerinin F1-skor ve doğruluk karşılaştırması	77
Şekil 37.	Modellere ve sınıflara göre F1 skoru ile genel doğruluk karşılaştırması	77

KISALTMALAR, SİMGELER ve FORMÜLLER DİZİNİ

Kısaltmalar

ANN	Artificial Neural Network (Yapay Sinir Ağı)
AUC	Area Under Curve
CNN	Convolutional Neural Network (Konvolüsyonel Sinir Ağı)
CNV	Choroidal Neovascularization (Koroidal Neovaskülerizasyon)
DL	Deep Learning (Derin Öğrenme)
DME	Diabetic Macular Edema (Diyabetik Maküler Ödem)
DRUSEN	Yaşa Bağlı Maküler Dejenerasyon Bulgusu
FC	Fully Connected (Tam Bağlantılı)
FN	False Negative (Yanlış Negatif)
FP	False Positive (Yanlış Pozitif)
GPU	Graphics Processing Unit (Grafik İşlem Birimi)
KNN	K-Nearest Neighbors (En Yakın K Komşu Algoritması)
LI	Lateral Inhibition (Lateral İnhibisyon)
ML	Machine Learning (Makine Öğrenmesi)
OCT	Optical Coherence Tomography (Optik Koherens Tomografi)
ROC	Receiver Operating Characteristic
SVM	Support Vector Machine (Destek Vektör Makineleri)
TN	True Negative (Doğru Negatif)
TP	True Positive (Doğru Pozitif)

ÖZET

Geniştirilmiş Lateral İnhibisyon Yöntemiyle OCT Verileri Üzerinden Retinal Hastalıkların Sınıflandırılması

Bu tez çalışması, Optik Koherens Tomografi (OCT) görüntüleri üzerinden retinal hastalıkların otomatik olarak sınıflandırılması amacıyla lateral inhibisyon prensibini entegre eden yenilikçi bir derin öğrenme modeli geliştirmeyi hedeflemektedir. Retina hastalıkları, küresel ölçekte ciddi görme kaybına yol açmakta olup, erken ve doğru tanının önemi büyüktür. Geleneksel yöntemlerle OCT görüntülerinin manuel analizi, zaman alıcı ve hata payı yüksek bir süreçtir. Bu durum, makine öğrenimi destekli analiz yöntemlerine olan ihtiyacı belirgileştirmiştir. Son yıllarda derin öğrenme teknikleri, retinal hastalıkların sınıflandırılması görevlerinde yüksek doğruluk oranları sağlamıştır. Ancak biyolojik esinlenmeli yaklaşımların bu alandaki potansiyeli yeterince incelenmemiştir.

Bu çalışmada, biyolojik sinir ağlarında bulunan lateral inhibisyon mekanizmasından esinlenerek, bunun derin öğrenme mimarilerine entegre edilmesiyle, retinal hastalıkların daha etkin sınıflandırılmasına yönelik bir model geliştirilmiştir. DenseNet121, InceptionV3, ResNet50 ve Xception gibi popüler CNN mimarileri kullanılarak elde edilen sonuçlar, lateral inhibisyonun genel model performansını belirgin ölçüde artırdığını göstermiştir. Yapılan karşılaştırmalı analizlerde lateral inhibisyon uygulanan modellerin özellikle CNV ve DME sınıflarında daha yüksek F1-skorları ve doğruluk değerleri elde ettiği tespit edilmiştir.

Sonuçlar, lateral inhibisyon prensibinin derin öğrenme modellerine entegrasyonunun OCT görüntülerinin sınıflandırılmasında önemli bir performans artışı sağladığını ortaya koymaktadır. Bu yaklaşımın klinik ortamlarda retinal hastalıkların erken ve doğru teşhisine katkıda bulunacağı düşünülmektedir. Gelecekte yapılacak çalışmaların, farklı tıbbi görüntüleme yöntemleri ve daha geniş veri setleri üzerinde lateral inhibisyon prensibinin etkisini inceleyerek, bu yöntemin klinik uygulamalarda yaygın olarak kullanılabileceği düşünülmektedir.

Anahtar Kelimeler: Derin Öğrenme, Görüntü Sınıflandırma, Klinik Karar Destek Sistemleri, Konvolüsyonel Sinir Ağları (CNN), Lateral İnhibisyon, Optik Koherens Tomografi (OCT), Retinal Hastalıklar.

ABSTRACT

Classification of Retinal Diseases Based on OCT Data by Extended Lateral Inhibition Method

This thesis aims to develop an innovative deep learning model that integrates the principle of lateral inhibition for the automatic classification of retinal diseases based on Optical Coherence Tomography (OCT) images. Retinal diseases are a major cause of vision loss worldwide, making early and accurate diagnosis critically important. Manual analysis of OCT images using traditional methods is time-consuming and prone to errors, which highlights the need for machine learning-assisted analytical techniques. In recent years, deep learning approaches have achieved high accuracy rates in the classification of retinal diseases. However, the potential of biologically inspired approaches in this domain remains insufficiently explored.

In this study, inspired by the lateral inhibition mechanism found in biological neural networks, a model was developed that integrates this principle into deep learning architectures to achieve more effective classification of retinal diseases. The results obtained using popular CNN architectures such as DenseNet121, InceptionV3, ResNet50, and Xception demonstrate that the inclusion of lateral inhibition significantly enhances overall model performance. Comparative analyses revealed that models incorporating lateral inhibition achieved higher F1-scores and accuracy, particularly in the CNV and DME classes.

The findings indicate that integrating the principle of lateral inhibition into deep learning models leads to a substantial improvement in the classification of OCT images. It is anticipated that this approach will contribute to the early and accurate diagnosis of retinal diseases in clinical settings. Future studies are expected to examine the impact of lateral inhibition across different medical imaging modalities and larger datasets, suggesting that this method could be widely adopted in clinical applications.

Keywords: Clinical Decision Support Systems, Convolutional Neural Networks (CNN), Deep Learning, Image Classification, Lateral Inhibition, Optical Coherence Tomography (OCT), Retinal Diseases.

1. GİRİŞ ve AMAÇ

Görme duyusu, insan hayatının en kritik bileşenlerinden biri olup, bireylerin dünya ile etkileşimini önemli ölçüde belirlemektedir. Retina hastalıkları, görme kaybına ve görme fonksiyonlarında ciddi bozukluklara neden olabilen yaygın rahatsızlıklardır. Özellikle yaşlanma, diyabet, genetik faktörler ve diğer sistemik hastalıklar, retina hastalıklarının ortaya çıkmasında önemli rol oynamaktadır (1, 2). Retina hastalıkları, küresel ölçekte ciddi bir görme kaybı yükü oluşturmakta olup, bu hastalıklara bağlı görme kaybının doğru şekilde tahmin edilmesi, göz sağlığı hizmetlerinin planlanması ve tıbbi kaynakların etkin dağıtımı açısından kritik öneme sahiptir. Koroidal Neovaskülarizasyon (CNV), Diyabetik Maküler Ödem (DME) ve Drusen gibi yaygın retina hastalıkları, erken evrede belirgin semptomlar göstermediğinden genellikle ileri aşamalarda tespit edilmekte ve bu durum hastaları kalıcı görme kaybı riskiyle karşı karşıya bırakmaktadır (3). Bu hastalıkların tespiti ve doğru bir şekilde sınıflandırılması, etkili bir tedavi planının oluşturulması ve görme kaybının önlenmesi için kritik bir adım oluşturmaktadır.

Optik Koherens Tomografi (OCT), retina hastalıklarının tanısında yaygın olarak kullanılan invazif olmayan bir görüntüleme yöntemidir. OCT, retina katmanlarını detaylı bir şekilde analiz etme yeteneğine sahip olup, görme fonksiyonlarını etkileyen hastalıkların erken tespitinde hayati bir rol oynamaktadır. Geleneksel olarak, OCT görüntülerinin analizi, göz uzmanları tarafından manuel olarak yapılmakta ve bu süreç zaman alıcı, maliyetli ve hata payı yüksek bir yaklaşım sunmaktadır (4, 5). Bu nedenle, bilgisayar destekli tespiti ve sınıflandırma sistemleri geliştirme gerekliliği ortaya çıkmıştır. Son yıllarda, yapay zeka ve derin öğrenme modelleri, OCT görüntülerinin otomatik analizi ve hastalıkların sınıflandırılması konusunda umut verici sonuçlar elde etmiştir (6–9).

Görsel algının sinirbilimsel mekanizmalarından biri olan lateral inhibisyon, nöronlar arasındaki etkileşimi düzenleyerek belirginlik ve kontrast oluşturan temel bir mekanizmadır. Lateral inhibisyon, bir nöronun komşu nöronların aktivitesini baskılamasına dayanarak görsel uyaranların algılanmasını kolaylaştırır ve detayların daha belirgin hale gelmesini sağlar (10, 11). Bu biyolojik mekanizma, bilgisayarlı görü alanında henüz yeterince derinlemesine incelenmemiştir. Konvolüsyonel Sinir Ağları'nda (CNN) lateral inhibisyon uygulanması, belirginlik algılama ve görsel dikkat modelleri ile şeffaflık ve hassasiyet artışı sağlayarak sınıflandırma işleminin daha başarılı olmasını destekleyebilir. Lateral inhibisyon

prensibinin Optik Koherens Tomografi görüntülerinin analizine entegre edilmesi, hastalıkların tespit edilmesinde yenilikçi bir yaklaşım sunabilir.

Bu tez çalışması, lateral inhibisyon prensibini genişleterek Optik Koherens Tomografi görüntülerinin analizinde ve retinal hastalıkların sınıflandırılmasında kullanılabilir bir yöntem geliştirmeyi amaçlamaktadır. Geleneksel konvolüsyonel sinir ağı modellerine göre daha hassas ve başarılı sınıflandırma yapmayı hedefleyen bu yöntem, biyolojik temellere dayanan bir hesaplama modeli olarak da öne çıkacaktır. Bu bağlamda, literatüre sağlanacak katkılar aşağıdaki önemli noktalarda toplanabilir:

- OCT görüntülerinin analizine lateral inhibisyon prensibi entegre edilerek daha hassas ve doğru sınıflandırma sağlanması.
- Retina hastalıklarının erken tespitinin otomatize edilmesi sayesinde, tıbbi personelin iş yükünü hafifletmek ve görme kaybının önlenmesine katkı sağlamak.
- Lateral inhibisyon modelinin, bilgisayarlı görü alanında yeni bir hesaplama modeli olarak kullanılması ve literatüre katkı sağlanması.

Retinal hastalıkların sınıflandırılması konusunda yapılan derin öğrenme tabanlı çalışmalar genellikle konvolüsyonel sinir ağı yapıları kullanılarak gerçekleştirilmekte ve biyolojik görme mekanizmalarından esinlenerek modellenmiş yöntemlerden yeterince faydalanmamaktadır. Bu tez, lateral inhibisyon prensibini derin öğrenme modellerine entegre ederek retinal hastalıkların tespiti konusunda yeni bir bakış açısı sunmayı hedeflemektedir. Lateral inhibisyon modelinin uygulanması, mevcut yaklaşımlara yenilikçi bir alternatif oluşturarak retinal hastalıkların erken ve hassas tespitine katkı sağlayacaktır.

2. GENEL BİLGİLER

2.1. Optik Koherens Tomografi (OCT) ve Retina Görüntüleme


Optik Koherens Tomografi, biyomedikal görüntüleme alanında devrim niteliğinde bir teknoloji olup, doku yapılarının mikrometre düzeyinde kesitsel görüntülenmesini sağlayan invazif olmayan bir optik görüntüleme yöntemidir. OCT, düşük koherensli interferometri prensibine dayanarak biyolojik dokuların iç yapısını yüksek çözünürlükte inceleyebilme imkânı sunar. Temel olarak, düşük koherensli ışık kaynakları kullanarak doku katmanlarının derinliğine bağlı olarak geri yansıyan ışık dalgalarının interferometrik ölçümlerini yapar. Bu sayede, biyolojik dokuların detaylı ve katmanlı görüntüleri elde edilebilir. OCT'nin temel avantajı, X-ışını, manyetik rezonans görüntüleme (MR) veya ultrason gibi diğer görüntüleme yöntemlerine kıyasla daha yüksek çözünürlük sağlaması ve hastaya herhangi bir zarar vermeden non-invazif bir şekilde uygulanabilmesidir (4, 5, 12).

Oftalmoloji alanında OCT, retinal hastalıkların erken teşhisi ve takibi için yaygın olarak kullanılan bir yöntemdir. Retina tabakalarının ayrıntılı yapısını değerlendirebilme yeteneği sayesinde, özellikle diyabetik retinopati, yaşa bağlı makula dejenerasyonu (AMD) ve glaukom gibi göz hastalıklarının teşhisinde kritik bir rol oynamaktadır. OCT, retina katmanlarındaki değişiklikleri tespit ederek hastalığın erken evrede belirlenmesine ve ilerleyişinin izlenmesine olanak tanır. Geleneksel fundus fotoğrafçılığı veya floresan anjiyografi gibi yöntemlere kıyasla daha ayrıntılı bilgi sağlayan OCT hem nicel hem de nitel analizlere imkân tanıyan bir teknolojidir. Bu bağlamda, retina hastalıklarının takibinde ve tedavi planlarının oluşturulmasında oftalmologlar için vazgeçilmez bir araç haline gelmiştir (13, 14).

OCT görüntülerinin yapısı, retina tabakalarının ince detaylarını içeren kesitsel verilerden oluşur. Bu görüntüler genellikle gri tonlamalı olup, retina katmanlarındaki farklı yapısal özellikleri yansıtır. OCT verileri, derinlik bilgisi sağlayarak her bir retina katmanının kalınlığını, bütünlüğünü ve yapısal değişikliklerini inceleme fırsatı sunar. Tipik bir OCT görüntüsü, retina pigment epiteli, fotoreseptör tabakası, iç ve dış pleksiform tabakalar, gangliyon hücre tabakası gibi farklı anatomik katmanları içerir. Bu katmanların her biri, belirli retinal hastalıkların teşhisinde önemli ipuçları sunmaktadır. Örneğin, diyabetik maküler ödem gibi patolojiler, retina katmanlarının kalınlığında anormal artışa neden olurken, maküler delik gibi durumlar belirli katmanlarda kesintilere sebep olmaktadır. OCT görüntüleri, bilgisayar destekli analiz ve derin öğrenme algoritmaları ile işlenerek

hastalıkların otomatik olarak sınıflandırılmasına ve tanınmasına imkân tanımaktadır (15–17).

Retina, insan görme sisteminin en karmaşık ve işlevsel yapılarından biridir. Retina katmanlarının anatomik ve fizyolojik yapısı, ışığın algılanması ve beyne iletilmesi sürecinde kritik bir rol oynar (Şekil 1). Retina, temel olarak fotoreseptör hücreleri (çubuk ve koni hücreleri), bipolar hücreler, gangliyon hücreleri ve destekleyici hücrelerden oluşur. Fotoreseptör hücreleri, ışığı elektriksel sinyallere dönüştürerek görsel bilginin işlenmesini başlatır (18). Koni hücreleri renkli görmeyi sağlarken, çubuk hücreleri düşük ışık koşullarında görme yetisini destekler. Bipolar hücreler, fotoreseptörlerden gelen sinyalleri gangliyon hücrelerine ileterek görsel bilginin işleme sürecini yönlendirir. Gangliyon hücreleri ise görsel bilgiyi optik sinir aracılığıyla beyne taşır. Retina katmanlarının kalınlığı, hücresel yoğunluğu ve yapısal bütünlüğü, farklı retinal hastalıkların belirlenmesinde önemli bir gösterge niteliğindedir. OCT kullanılarak retina katmanlarının ayrıntılı bir şekilde analiz edilmesi, hastalıkların erken teşhisini ve ilerleyişinin izlenmesini sağlayarak hastaların görme yetisini koruma açısından kritik bir rol oynar (19).



Şekil 1. Oftalmoskopi ile görülen retinanın görünümü (Kolb'dan, 19)

OCT verileri, retinal hastalıkların teşhisi ve sınıflandırılması için büyük önem taşımaktadır. Bu veriler, derin öğrenme tabanlı bilgisayarlı görme sistemleri aracılığıyla analiz edilerek hastalıkların otomatik olarak tespit edilmesine olanak tanır. Geleneksel teşhis yöntemlerine kıyasla daha hızlı ve hassas sonuçlar sağlayan yapay zeka destekli OCT analizleri, özellikle büyük hacimli veri setlerinde etkin bir şekilde çalışarak oftalmologlara tanı koyma sürecinde yardımcı olmaktadır (20, 21). OCT görüntülerinin bilgisayar destekli analizine dayanan sınıflandırma sistemleri, retinal hastalıkların tanınmasını iyileştirme ve hata payını azaltma potansiyeline sahiptir. Bu bağlamda, lateral inhibisyon gibi biyolojik ilkelere dayalı derin öğrenme modellerinin OCT verileri üzerinde uygulanması, teşhis doğruluğunu artıran yenilikçi bir yaklaşım sunmaktadır. Geliştirilecek olan model, retina hastalıklarının erken evrede belirlenmesine katkı sağlayarak klinik karar destek sistemlerine entegre edilebilir.

Sonuç olarak, OCT teknolojisi retina hastalıklarının teşhis ve sınıflandırılmasında devrim niteliğinde bir araç olup, bu teknolojinin gelişmiş görüntü işleme yöntemleri ve derin öğrenme algoritmalarıyla entegrasyonu, oftalmoloji alanında büyük bir ilerleme kaydedilmesini sağlayacaktır. Geliştirilecek yöntemler, OCT görüntülerinin daha doğru analiz edilmesini ve hastalıkların daha erken evrede teşhis edilmesini mümkün kılarak hem araştırmacılar hem de klinik uzmanlar için büyük bir katma değer sunacaktır.


2.2. Retinal Hastalıklar ve Klinik Önemi

Retinal hastalıklar, görme fonksiyonlarını olumsuz etkileyerek ciddi görme kayıplarına neden olabilen yaygın rahatsızlıklardır. Retina, gözün iç katmanında yer alan ve görme fonksiyonunun gerçekleşmesini sağlayan sinir dokularından oluşan kritik bir yapıdır. Retinal hastalıklar, genetik yatkınlık, metabolik hastalıklar, inflamatuvar süreçler, vasküler bozukluklar ve dejeneratif mekanizmalar nedeniyle ortaya çıkabilir. Bu hastalıkların erken tanısı ve doğru bir şekilde sınıflandırılması, etkili bir tedavi yönteminin belirlenmesi ve görme kaybının önlenmesi için büyük önem taşımaktadır (3). Bu bölümde, koroidal neovaskülerizasyon (CNV), diyabetik maküler ödem (DME), Drusen ve diğer yaygın retina bozuklukları ele alınarak retinal hastalıkların klinik önemi ve geleneksel tanı yöntemleri detaylı olarak incelenecektir.

CNV, retinanın alt tabakasında yeni ve anormal kan damarlarının oluşumu ile karakterize edilen ciddi bir patolojik durumdur. CNV, genellikle yaşa bağlı makula dejenerasyonu (AMD) gibi dejeneratif hastalıklar ile ilişkili olup, görme merkezinde ciddi

hasara neden olabilir. Anormal yeni damarlar, retina altında oluşarak sızıntı ve kanama riski taşır. Bu durum, retinanın fonksiyonunu bozarak merkezi görme kaybına neden olur. CNV'nin erken evrede tespiti, anti-VEGF (vasküler endotelyal büyüme faktörü) tedavisi gibi modern farmakolojik yaklaşımların etkinliğini arttırmak açısından kritiktir. CNV tespitinde Optik Koherens Tomografi ve Floresan Anjiyografi gibi ileri görüntüleme teknikleri yaygın olarak kullanılmaktadır (22, 23).

Şekil 2’de, CNV, DME, drusen ve normal retina durumlarına ait tipik OCT görüntüleri sunulmaktadır. Her bir hastalık durumunda retina tabakalarının farklı yapısal değişiklikler gösterdiği gözlenmektedir.



Şekil 2. Retina hastalıklarına ait OCT görüntüleri (Tsuji'den, 23)

DME, diyabetin retinada neden olduđu en yaygın komplikasyonlardan biridir ve diyabetik retinopati ile yakından ilişkili bir durumdur. DME, retina damarlarından sızan sıvının maküla bölgesinde birikmesi sonucu oluşur ve bu durum, görme keskinliğini ciddi şekilde azaltabilir. Diyabetin ilerleyen aşamalarında, retinada kan damarlarının yapısal olarak bozulması ve geçirgenliğini kaybetmesi nedeniyle maküler ödem gelişebilmektedir. DME'nin erken tanısı ve sınıflandırılması, hastalığın ilerlemesini önlemek ve uygun tedavi seçeneklerini belirlemek için önemlidir. Anti-VEGF enjeksiyonları, kortikosteroid implantlar ve lazer fotokoagülasyon gibi tedavi yöntemleri yaygın olarak kullanılmaktadır. OCT, DME'nin saptanmasında ve retina kalınlığındaki değişikliklerin izlenmesinde kritik bir rol oynamaktadır (24).

Drusen, retinanın pigment epitel tabakasında oluşan lipid ve protein birikintileridir. Drusen varlığı, yaşa bağlı makula dejenerasyonunun (AMD) erken belirtisi olarak kabul edilir. Drusen, sert ve yumuşak olmak üzere iki ana kategoriye ayrılır. Sert Drusenler, daha küçük ve keskin sınırlı olup genellikle klinik olarak daha az önemlidir. Yumuşak Drusenler ise daha geniş, birleşik ve daha difüz yapılıdır ve retina pigment epitelinin dejenerasyonuna yol açarak AMD riskini artırabilir. Drusen varlığı, yaşlı bireylerde daha yaygın olup, hastalığın ilerlemesini izlemek için periyodik OCT muayeneleri gerektirir. Klinik olarak, Drusenlerin büyüklüğü ve sayısı, hastalığın ilerleme potansiyelini belirlemek için önemlidir (25).

Retinal hastalıkların tanısında geleneksel yöntemler, göz doktorları tarafından manuel olarak gerçekleştirilen muayeneleri ve görüntüleme tekniklerini içermektedir. Fundus fotoğrafçılığı, Floresan Anjiyografi (FA) ve Optik Koherens Tomografi, retinal hastalıkların tanısında kullanılan en yaygın görüntüleme teknikleri arasındadır. Fundus fotoğrafçılığı, retina ve optik sinirin detaylı renkli görüntülerini sunarken, FA damar yapısındaki anormallikleri ortaya çıkarmakta kullanılır. Ancak bu yöntemler, manuel değerlendirme gerektirdiği için subjektif hatalara ve zaman kaybına yol açabilmektedir. OCT tabanlı bilgisayarlı görme teknikleri ve yapay zeka tabanlı modeller, bu geleneksel yöntemlere alternatif olarak geliştirilmekte olup, daha hızlı ve hassas tanı koyma imkanı sunmaktadır (26, 27).

Sonuç olarak, retinal hastalıkların erken tespiti, hastalığın ilerlemesini yavaşlatmak ve görme fonksiyonlarını korumak açısından kritik öneme sahiptir. Gelişmiş yapay zeka algoritmalarının OCT teknolojisi ile entegrasyonu, retinal hastalıkların daha hassas ve doğru

bir şekilde sınıflandırılmasına imkan tanımaktadır. Ayrıca, bu tür yapay zeka tabanlı tanı modellerinin geliştirilmesi ve uygulanması, sadece retinal hastalıkların değil, çok daha geniş bir yelpazedeki diğer tıbbi hastalıkların tanısına da katkı sunma potansiyeline sahiptir. Bu durum, tıbbi görüntülemenin yapay zeka ile birleştirilmesinin, tıbbın farklı alanlarında zamanında ve doğru klinik kararların desteklenmesinde daha geniş bir öneme sahip olduğunu ortaya koymaktadır.


2.3. Bilgisayarlı Görü ve Derin Öğrenme Modelleri

Bilgisayarlı görü, dijital görüntüleme ve algoritmalar aracılığıyla görsel verilerin analiz edilmesi, anlamlandırılması ve şekillendirilmesini sağlayan bir yapay zeka alanıdır. Bu alan, nesne tanıma, segmentasyon, hareket takibi, desen tanıma ve 3D modelleme gibi çeşitli alt dallardan oluşmaktadır. Bilgisayarlı görü sistemleri, insanların görsel bilgileri işleme yetisini taklit ederek, makinelerin çevreyi algılamasına ve yorumlamasına olanak tanır. Bu bağlamda, görsel bilgilerin yorumlanması ve anlamlı hale getirilmesi için derin öğrenme modelleri önemli bir rol oynamaktadır (28, 29).

Yapay zeka (Artificial Intelligence, AI), insan benzeri bilişsel yeteneklere sahip sistemlerin geliştirilmesini hedefleyen, disiplinler arası bir çalışma alanıdır ve bilgisayar bilimleri, matematik, psikoloji, nörobilim ve dilbilim gibi pek çok alandan beslenmektedir (30). Bu alan, problem çözme, öğrenme, muhakeme yürütme, doğal dil işleme ve görsel algı gibi insana özgü bilişsel fonksiyonları simüle edebilen sistemlerin tasarımını amaçlamaktadır. AI kavramı, genel itibarıyla zeka gerektiren görevleri yerine getirebilen makinelerin veya yazılımların geliştirilmesini kapsarken, bu geniş alan kendi içinde farklı alt dallara ayrılmıştır.

Bu alt dallardan biri olan makine öğrenmesi (Machine Learning, ML), sistemlerin açık bir şekilde programlanmaksızın, deneyimlerden öğrenerek performanslarını iyileştirmelerine olanak tanır. ML algoritmaları, büyük veri kümeleri üzerinde istatistiksel analizler yaparak, belirli örüntüleri tanımlar ve bu örüntüler üzerinden sınıflandırma, tahmin veya karar verme gibi görevleri yerine getirir (31). Bu yönüyle makine öğrenmesi, veriye dayalı karar destek sistemlerinin temelini oluşturmakta ve pek çok sektörde yaygın uygulama alanı bulmaktadır. Finans, sağlık, üretim ve pazarlama gibi alanlarda karmaşık problemleri çözmek için kullanılan ML algoritmaları; doğrusal regresyon, karar ağaçları, destek vektör makineleri ve k-en yakın komşu gibi çeşitli yöntemleri içermektedir.

Makine öğrenmesinin bir alt dalı olan derin öğrenme (Deep Learning, DL) ise, insan beyninin öğrenme biçiminden esinlenerek geliştirilen yapay sinir ağlarını temel alır. Derin öğrenme modelleri, özellikle çok katmanlı mimarileri sayesinde verilerdeki karmaşık, çok boyutlu ilişkileri ortaya çıkarabilme ve yüksek doğrulukla modelleme yapabilme kapasitesine sahiptir. Bu modeller, geleneksel makine öğrenme algoritmalarının gerektirdiği manuel özellik mühendisliği (feature engineering) adımlarına büyük ölçüde ihtiyaç duymaksızın, ham veriden doğrudan anlamlı temsiller çıkarabilmektedir (32, 33). Bu nedenle DL yaklaşımları, özellikle büyük veri (big data) ortamlarında görüntü tanıma, ses işleme, doğal dil işleme ve otonom sistemler gibi uygulamalarda çığır açıcı başarılar elde etmiştir. Derin öğrenmenin başarısı, yalnızca büyük veri kümelerine değil, aynı zamanda yüksek hesaplama gücüne ve optimizasyon tekniklerine de dayanmaktadır.




Şekil 3. Yapay zeka, makine öğrenmesi, derin öğrenme, konvolüsyonel sinir ağları ve bilgisayarlı görü arasındaki ilişki (Kitaguchi'den, 33)

Bilgisayarlı görü, yapay zekanın görsel verilerle çalışan bir alt alanıdır ve çoğunlukla makine öğrenmesi ve derin öğrenme tekniklerinden yararlanır. Bu bağlamda, derin öğrenme modelleri bilgisayarlı görü alanında, geleneksel makine öğrenme algoritmalarına göre daha

hassas ve doğru sonuçlar vermektedir (34). Derin öğrenme, yapay sinir ağlarının bir alt dalı olup, çok katmanlı sinir ağı yapıları sayesinde veriden anlam çıkarma yeteneği sunmaktadır. Özellikle Konvolüsyonel Sinir Ağları (CNN), bilgisayarlı görü alanında yaygın olarak kullanılan bir derin öğrenme modelidir. CNN'ler, girdi görüntülerinden özellikleri otomatik olarak çıkarmak, ayıklamak ve şekillendirmek için konvolüsyon katmanlarını kullanarak geleneksel yaklaşımlara göre çok daha özerk ve etkili bir analiz sağlar (35).

CNN'ler, çok sayıda girdi verisini işleyerek belirli görüntülerdeki örüntüler, kenarlar ve dokular gibi temel özellikleri algılar. Bu yetenek, görüntüler üzerinden nesne tanıma, segmentasyon ve sınıflandırma gibi görevleri başarıyla yerine getirmelerini sağlar. CNN modellerinin katmanlı yapısı, çıktıların daha hassas ve optimize edilmiş olmasına olanak tanır. Bu modeller, biyomedikal görüntüleme gibi hassas alanlarda da yaygın olarak kullanılmaktadır (36). CNN tabanlı modeller, oftalmoloji alanında OCT verilerini analiz etmek ve retinal hastalıkları otomatik olarak sınıflandırmak için kullanılmaktadır.



Şekil 4. CNN mimarisi (Tabian'dan, 36)

CNN'ler, görsel nesne tanıma alanında en yaygın kullanılan ve en başarılı makine öğrenmesi yaklaşımlarından biri haline gelmiştir. İlk olarak yirmi yılı aşkın bir süre önce ortaya atılmış olmalarına rağmen (37), bu ağların derin ve yüksek doğruluk oranına sahip versiyonlarının eğitilmesi, ancak son yıllarda bilgi işlem gücündeki büyük ilerlemeler, grafik işleme birimlerinin (GPU) yaygınlaşması ve daha gelişmiş ağ mimarilerinin tasarlanması ile mümkün hale gelmiştir. CNN'lerin başarısı, katmanlı yapılarının görüntülerden hiyerarşik özellikler çıkarma yeteneğine dayanmakta olup, kenar ve doku gibi düşük seviyeli özelliklerden daha karmaşık nesne temsillerine kadar derinlemesine öğrenme

sağlayabilmektedir (38). Günümüzde derin CNN modelleri, başta tıbbi görüntü analizi, otonom araçlar ve güvenlik sistemleri olmak üzere birçok kritik alanda yaygın olarak kullanılmakta ve bilgisayarlı görü uygulamalarının performansını önemli ölçüde artırmaktadır.

Derin öğrenme modelleri, tıbbi görüntüleme alanında büyük bir dönüşüm sağlamıştır. Geleneksel manuel analiz yöntemlerinin zaman alıcı ve hata payının yüksek olması nedeniyle, derin öğrenme tabanlı otomatik sistemler daha hızlı ve doğru sonuçlar sağlamak için geliştirilmektedir. Bu yöntemler, kanser taramalarından kardiyovasküler hastalıkların belirlenmesine kadar geniş bir yelpazede uygulanmaktadır (39–41). Retina görüntüleme alanında derin öğrenme, hastalıkların erken tespit edilmesi, OCT görüntülerinin analiz edilmesi ve hekime karar destek sistemleri sunulması gibi çeşitli alanlarda kullanılmaktadır. CNN tabanlı sistemler, OCT görüntülerinde retinal katmanları analiz ederek, spesifik hastalık belirteçlerini ortaya çıkarmakta ve hastalıkların sınıflandırılmasında önemli rol oynamaktadır.

2.3.1. Transfer Learning ve Popüler CNN Modelleri

Transfer learning (aktarılabılır öğrenme), önceden büyük veri setleri üzerinde eğitilmiş bir modelin, farklı ancak benzer bir problem üzerine yeniden adapte edilerek kullanılmasıdır. Transfer learning, tıbbi görüntüleme gibi veri sayısının sınırlı olduğu alanlarda modelin başarısını artıran önemli bir tekniktir. Önceden eğitilmiş CNN modelleri, özellikle sınırlı OCT görüntüleriyle çalışırken daha yüksek doğruluk elde edilmesini sağlar. Bu bağlamda, birçok araştırmada farklı transfer learning tabanlı CNN modelleri kullanılmıştır (42–44). Bunlar arasında **DenseNet121**, **Inception**, **ResNet50** ve **Xception** gibi modeller öne çıkmaktadır.

2.3.1.1. DenseNet121

Yoğun Bağlantılı Evrişimli Sinir Ağları (DenseNet'ler), özellikle CNN alanında derin öğrenme mimarilerinde önemli bir ilerleme sağlamaktadır. Geleneksel CNN'lerin katmanlar arası sıralı bağlantı yapısına dayanmasının aksine, DenseNet'ler her katmanı kendisinden önceki tüm katmanlara doğrudan bağlayan yeni bir bağlantı modeli sunarak, özellik yayılımını ve gradyan akışını önemli ölçüde iyileştirmektedir. Bu yoğun bağlantı yapısı, gradyan kaybolma problemini hafifletirken, özellik tekrar kullanımını teşvik eder ve geleneksel derin ağlara kıyasla parametre sayısını önemli ölçüde azaltır. DenseNet modelleri arasında öne çıkan DenseNet121, CNN yapısındaki bilgi kaybını en aza indirmek ve


özelliklerin daha verimli kullanılmasını sağlamak amacıyla geliştirilmiş bir mimaridir. Bu model, her katmanı önceki tüm katmanlarla bağlayarak, öğrenme sürecinde daha etkili bir bilgi paylaşımı ve detaylı özellik çıkarımı sağlar (38). Özellikle OCT görüntülerinin analizinde, DenseNet121'in sağladığı yoğun bağlantılar sayesinde ince detayları daha iyi ayırt etme kabiliyeti ön plana çıkmaktadır. OCT görüntülerindeki karmaşık yapıları yüksek doğrulukla analiz edebilme yeteneği, bu modelin oftalmoloji gibi tıbbi görüntüleme alanlarında geniş bir kullanım alanı bulmasını sağlamaktadır. Ayrıca, CIFAR-10, CIFAR-100, SVHN ve ImageNet gibi temel veri kümeleri üzerinde yapılan deneysel değerlendirmeler, DenseNet'lerin yüksek doğruluk oranlarına ulaşırken aynı zamanda hesaplama verimliliğini de koruduğunu göstermektedir. Parametrik verimliliği ve iyileştirilmiş eğitim dinamikleri sayesinde, DenseNet121, bilgisayarlı görü ve tıbbi görüntü analizi gibi alanlarda ölçeklenebilir ve etkili bir çözüm sunmaktadır (45).

Tablo 1. DenseNet mimarisi (Huang ve ark.'dan, 38)

Layers	Output Size	Desnet-121	Desnet-169	Desnet-201	Desnet-264
Convolution	112×112	7×7 conv, stride 2			
Pooling	56×56	3×3 max pool, stride 2			
Dense Block (1)	56×56	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	56×56	1×1 conv			
	28×28	2×2 average pool, stride 2			
Dense Block (2)	28×28	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	28×28	1×1 conv			
	14×14	2×2 average pool, stride 2			
Dense Block (3)	14×14	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 64$
Transition Layer (3)	14×14	1×1 conv			
	7×7	2×2 average pool, stride 2			
Dense Block (4)	7×7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$
Classification Layer	1×1	7×7 Global average pool			
		1000D fully-connected, softmax			

2.3.1.2. InceptionV3


InceptionV3, farklı boyutlardaki konvolüsyon filtrelerini paralel olarak kullanarak çok ölçekli özellik çıkarımını optimize eden gelişmiş bir CNN mimarisidir. Model, büyük filtrelerin hesaplama maliyetlerini azaltmak için konvolüsyon faktörizasyonu, yardımcı sınıflandırıcılar (auxiliary classifiers) ve etiket düzleştirme (label smoothing) gibi tekniklerden faydalanarak hem doğruluğu artırır hem de hesaplama verimliliğini optimize eder. Çok ölçekli bilgi işleme kapasitesi, modelin geniş kapsamlı görsel verileri tek bir katmanda analiz edebilmesini sağlarken, sınırlı hesaplama kaynaklarıyla bile yüksek performans göstermesine olanak tanır (46). Bu özellik, özellikle optik koherens tomografi (OCT) görüntü analizi gibi tıbbi görüntüleme alanlarında büyük avantaj sunmaktadır. InceptionV3 hem düşük hem de yüksek frekanstaki görsel özellikleri etkin bir şekilde yakalayarak retinal hastalıkların erken teşhisine katkı sağlar. ImageNet, CIFAR ve diğer büyük ölçekli veri kümeleri üzerinde yapılan deneyler, modelin hesaplama maliyetini minimize ederken yüksek doğruluk sunduğunu kanıtlamaktadır. Nesne tanıma, tıbbi görüntü analizi, video sınıflandırma ve diğer bilgisayarlı görü uygulamalarında geniş bir kullanım alanına sahip olan InceptionV3, hesaplama gücü ve doğruluk arasındaki dengeyi başarılı bir şekilde sağlayan güçlü bir derin öğrenme modelidir (47).



Şekil 5. InceptionV3 mimarisi (48)

2.3.1.3. ResNet50

ResNet (Residual Networks), derin sinir ağlarında ortaya çıkan gradyan kaybolması problemini çözmek için artık bağlantılar (residual connections) kullanan bir CNN mimarisidir. Bu yapı, geleneksel ağlardan farklı olarak, öğrenilmesi gereken fonksiyonları doğrudan modellemek yerine rezidüel fonksiyonları modelleyerek optimizasyon sürecini kolaylaştırır. ResNet50, derin özellik çıkarımı sağlayan ve gradyan kaybolmasını önleyen residual blokları içeren bir versiyonudur (49). Özellikle OCT görüntü analizi gibi medikal görüntüleme uygulamalarında, ResNet50'nin sunduğu derinlik ve optimizasyon avantajları, hastalıkların daha ayrıntılı sınıflandırılmasını mümkün kılmaktadır. Daha fazla katmana sahip olmasına rağmen VGG gibi geleneksel derin ağlara kıyasla daha düşük hesaplama karmaşıklığı sunan ResNet, ImageNet, CIFAR-10 ve COCO gibi büyük veri kümelerinde üstün başarı göstermiştir. ILSVRC 2015 yarışmasında sınıflandırma, nesne tespiti ve segmentasyon görevlerinde birincilik kazanan bu model, tıbbi görüntüleme alanında dejeneratif eklem hastalıkları (DJD) gibi karmaşık patolojilerin tespitinde de yüksek doğrulukla özellik çıkarımı yaparak tanı süreçlerine önemli katkılar sunmaktadır (50).



Şekil 6. ResNet50 mimarisi (51)


2.3.1.4. Xception

Xception (Extreme Inception), geleneksel Inception mimarisinin genişletilmiş bir versiyonu olup, derinlemesine ayrıştırılmış konvolüsyonlar (depthwise separable convolutions) kullanarak modelin performansını artıran bir CNN mimarisidir. Bu yapı, klasik konvolüsyonları iki aşamalı olarak bölerek kanal içi (depthwise) ve kanal boyu (pointwise) işlem yapan ayrı konvolüsyon katmanları kullanır. Böylece parametre

verimliliği sağlanırken, hesaplama maliyetleri düşürülmekte ve doğruluk oranı artırılmaktadır (52).

Özellikle OCT görüntü analizi gibi medikal görüntüleme uygulamalarında, Xception modelinin sağladığı derin özellik çıkarımı, retina katmanlarının daha iyi ayrıştırılmasını mümkün kılmaktadır. Geleneksel Inception mimarisinin aksine, Xception, tüm Inception modüllerini derinlemesine ayrıştırılmış konvolüsyonlarla değiştirerek, hem ImageNet hem de büyük ölçekli JFT gibi veri kümelerinde daha yüksek doğruluk oranlarına ulaşmıştır. Inception V3 ile benzer sayıda parametreye sahip olmasına rağmen, daha verimli bir öğrenme süreci sunan bu model, residual bağlantılar ile eğitim sürecini optimize eder ve gradyan akışını iyileştirir. Xception'un hız, doğruluk ve verimlilik avantajları, medikal görüntü işleme başta olmak üzere görsel tanıma ve sınıflandırma alanlarında güçlü bir model olarak öne çıkmasını sağlamaktadır (53).

Sonuç olarak, transfer learning tabanlı derin öğrenme modelleri, OCT görüntüleme ve retinal hastalıkların teşhisi için büyük bir potansiyele sahiptir. DenseNet121, Inception, ResNet50 ve Xception gibi modeller, farklı mimari yaklaşımlar kullanarak, retinal OCT görüntülerinin analizinde yüksek doğruluk oranları sağlamaktadır. Bu modellerin kullanımı, oftalmoloji alanında yapay zeka tabanlı tanı sistemlerinin geliştirilmesini kolaylaştırarak, klinik karar destek mekanizmalarına katkıda bulunmaktadır. Derin öğrenme ve transfer learning tekniklerinin entegrasyonu ile OCT görüntülerinin daha doğru sınıflandırılması sağlanarak, erken teşhis süreçlerinin geliştirilmesi hedeflenmektedir.



Şekil 7. Xception mimarisi (54, 55)

2.4. Lateral İnhibisyon Mekanizması ve Sinirbilimdeki Yeri

Lateral inhibisyon, sinirbilimde duyuşal algıyı iyileştirmek için gelişmiş önemli bir mekanizma olup, bir nöronun komşu nöronların aktivitesini baskılayarak duyuşal girdilerin kontrastını artırmasına dayanmaktadır. Bu mekanizma, beyin tarafından algılanan uyarıların daha net hale getirmek ve bilgi işleme kapasitesini optimize etmek amacıyla kullanılır. Lateral inhibisyon, görsel sistemde öne çıkmakla birlikte, duyuşal algının çeşitli alanlarında da bulunur ve kontrast algılamasının ön planda olduğu görme, dokunma ve işitme gibi duyuşların hassasiyetini belirgin şekilde artırır (10, 11).

Görsel sistemde lateral inhibisyonun temel işlevi, kenar belirginleştirme, kontrast artırma ve görsel keskinliği iyileştirmedir. Retinanın fotoreseptör tabakasında başlayan bu mekanizma, görsel bilgilerin iletilmesi sürecinde birbirine bağlı nöronların komşu sinyalleri baskılamasıyla gerçekleşir. Retinada bulunan horizontal ve amakrin hücreler, lateral inhibisyonun ana oyuncularını olarak kabul edilir. Bu hücreler, retinanın belirli alanlarındaki ışık uyarılarını baskılayarak kontrastı yüksek alanların daha belirgin hale gelmesini sağlar (56).

Görme sisteminde lateral inhibisyonun en büyük etkisi, kenar algılamasında ortaya çıkar. Çevresel görme alanında bulunan bir uyarana yanıt olarak merkezde bulunan nöronların aktivitesi baskılanarak, uyarının kenarlarının daha belirgin hale gelmesi sağlanır. Mach Bantları olarak bilinen optik fenomen, lateral inhibisyonun en belirgin görsel örneklerinden biridir. Bu fenomen, görme sisteminin kenarları vurgulamak ve algılanan görsel bilgileri daha net hale getirmek için lateral inhibisyonu nasıl kullandığını ortaya koyar. Ayrıca, lateral inhibisyon mekanizması renk algılamasında da kritik bir rol oynar; retina, farklı renk dalga boylarına verilen yanıtları düzenleyerek daha hassas renk kontrastı oluşturur (57).

Lateral inhibisyonun bilgisayarlı görme modellerine uyarlanması, biyolojik görme sistemlerinin mekanizmalarından esinlenerek geliştirilen yenilikçi yaklaşımlardan biridir. Derin öğrenme modelleri, özellikle CNN gibi yapay zeka teknikleri, biyolojik görsel algı mekanizmalarından ilham alarak özellik çıkarma ve nesne algılama süreçlerini geliştirmektedir. Lateral inhibisyon tabanlı bilgisayarlı görme sistemleri, görsel dikkat mekanizmalarını taklit ederek belirgin nesnelerin daha etkili bir şekilde algılanmasına ve daha iyi sınıflandırılmasına olanak tanır. Bu mekanizmanın derin öğrenme modellerine entegre edilmesi, bilgisayarlı görme sistemlerinin çok daha doğru ve hassas kararlar vermesini sağlamaktadır (58).

Konvolüsyonel Sinir Ağı (CNN) yapılarına lateral inhibisyonun entegre edilmesi, büyük ölçekte görüntü verisinin daha etkili işlenmesini ve daha ayrıntılı özelliklerin algılanmasını sağlayabilir. Geleneksel CNN modellerinde aktivasyon fonksiyonları, belirli nöronların etkinleştirilmesini sağlarken, lateral inhibisyon tabanlı modeller, bu aktivasyonu optimize ederek ağı çok daha doğru çıktılar üretmesine yardımcı olur. Bu sayede, çevresel gürültü azaltılır ve özellikle tıbbi görüntüleme gibi hassas uygulamalarda görsel bilgiler daha net hale getirilir (59).

Tıbbi görüntüleme alanında, OCT verilerinin analizinde lateral inhibisyon mekanizmasının uygulanması, retinal hastalıkların daha erken ve doğru bir şekilde tespit edilmesine katkı sağlayabilir. Lateral inhibisyon, retina görüntülemelerinde belirli yapıların kontrastını artırarak, patolojik alanların daha belirgin hale gelmesini sağlar. Bu durum, oftalmologlar için karar destek sistemlerinin geliştirilmesine ve otomatik hastalık tespiti algoritmalarının hassasiyetinin artırılmasına katkıda bulunmaktadır (60).

Sonuç olarak, lateral inhibisyon mekanizması, biyolojik görme sistemlerinin temel bir özelliği olup, bilgisayarlı görme ve yapay zeka alanında önemli bir rol oynayabilir. Bilgisayarlı görme modellerine lateral inhibisyonun entegre edilmesi, kontrast artırma, nesne algılama ve görüntü analizinde yeni ufuklar açabilir. Tıbbi görüntüleme uygulamalarında bu mekanizmanın kullanılması, retinal hastalıkların daha erken tespit edilmesine ve tedavi edilmesine büyük katkı sağlayarak, hasta bakımının iyileştirilmesine olanak tanıyacaktır.

2.5. Lateral İnhibisyon Temelli Konvolüsyonel Sinir Ağı (LICNN)

Lateral İnhibisyon Temelli Konvolüsyonel Sinir Ağı (LICNN), biyolojik görme sistemlerinden esinlenerek geliştirilen bir derin öğrenme modelidir. Geleneksel CNN genellikle görsel verileri işlemekte oldukça başarılı olsalar da biyolojik görme mekanizmalarının temel prensiplerini tam olarak yansıtmamaktadırlar. LICNN, bu eksikliği gidermek amacıyla lateral inhibisyon mekanizmasını model içerisine entegre ederek, nöronların belirli bölgelerden gelen sinyalleri baskılamasına ve daha seçici bir şekilde bilgi işlemeye olanak tanır. Bu sayede, modelin öğrenme süreci daha verimli hale gelir ve özellikle kontrastın düşük olduğu veya dikkat dağıtıcı unsurların bulunduğu görüntülerde daha hassas sonuçlar elde edilebilir (59).

LICNN'in çalışma prensibi, konvolüsyonel katmanların geleneksel CNN yapısındaki gibi temel görsel özellikleri çıkarmasına dayansa da, ek olarak lateral inhibisyon mekanizmasını içererek belirli bölgelerdeki nöronların diğerlerinden daha fazla öne çıkmasını sağlar. Biyolojik sistemlerde, lateral inhibisyon komşu nöronların aktivitesini azaltarak belirli özelliklerin daha baskın hale gelmesini sağlarken, LICNN'de bu prensip sinir ağı içerisinde belirgin kenarları, yüksek kontrastlı alanları ve dikkat çeken bölgeleri daha iyi vurgulamak için uygulanmaktadır. Böylece, modelin görsel verileri anlamlandırma kapasitesi artarken, gereksiz bilgi ve gürültünün baskılanması sağlanarak daha net bir analiz süreci oluşturulur (58, 61).

OCT görüntüleri, genellikle karmaşık ve düşük kontrastlı yapılar içerdiğinden, geleneksel CNN modelleri bazı detayları kaçırabilir veya yanlış sınıflandırmalar yapabilir. LICNN, lateral inhibisyon mekanizmasını kullanarak OCT görüntülerindeki belirli yapıları daha net bir şekilde ortaya çıkarır ve hastalık bölgelerinin tespitini kolaylaştırır. LICNN'in OCT görüntüleri üzerindeki uygulanması, özellikle retina katmanlarının ayrıştırılmasını ve patolojik bölgelerin belirlenmesini içermektedir. Geleneksel CNN tabanlı modeller, özellik

ıkarma ve sınıflandırma işlemlerinde başarılı olsa da, retinal hastalıkların OCT görüntüleri üzerindeki analizinde, ince detayları gözden kaçırma riski taşırlar. LICNN, lateral inhibisyon sayesinde düşük kontrastlı bölgelerde bile belirginlik oluşturarak, retina tabakaları arasındaki farkları daha net hale getirmekte ve hastalık tespit süreçlerini iyileştirmektedir (62).

LICNN, geleneksel CNN modelleri ile karşılaştırıldığında birkaç temel avantaja sahiptir. İlk olarak, geleneksel CNN'ler doğrudan ham pikseller üzerinde çalışarak önemli özellikleri belirleme sürecini otomatik hale getirmektedir, ancak belirginlik ve kenar tespiti gibi işlemler genellikle ek ön işleme aşamalarına bağlıdır. LICNN ise bu işlemleri biyolojik sinir sistemlerinden esinlenerek ağıın içine doğrudan entegre etmekte ve bu sayede modelin doğal olarak önemli alanları vurgulamasını sağlamaktadır (58).

İkinci olarak, geleneksel CNN modellerinde aşırı uyum (overfitting) riski daha yüksektir, çünkü model tüm piksellere eşit önem vererek gereksiz detayları da öğrenebilir. LICNN, lateral inhibisyon mekanizması ile gereksiz bilgileri baskılayarak, modelin yalnızca en önemli özelliklere odaklanmasını sağlar ve dolayısıyla daha genel geçer bir öğrenme süreci sunar. Bu, özellikle sınırlı sayıda eğitim verisi bulunan tıbbi görüntüleme uygulamalarında büyük bir avantaj sağlamaktadır (61).

Üçüncü olarak, LICNN modelleri, özellikle OCT gibi yüksek çözünürlüklü ve detay içeren tıbbi görüntülerde geleneksel CNN'lerden daha iyi performans gösterebilir. Retinal OCT görüntülerinde hastalık tespiti yaparken, LICNN'in kenar belirginleştirme ve kontrast artırma yetenekleri sayesinde erken teşhis süreçleri daha güvenilir hale gelmektedir. Özellikle maküler ödem, diyabetik retinopati veya koroidal neovaskülarizasyon gibi hastalıkların erken evrede saptanması için daha detaylı bir analiz sunar. Bu, oftalmologların hastaları daha etkili bir şekilde değerlendirmelerine yardımcı olur ve tedavi planlarını daha bilinçli bir şekilde oluşturmalarına olanak tanır (63).

Sonuç olarak, LICNN'in lateral inhibisyon temelli yapısı, geleneksel CNN'lere kıyasla daha seçici ve odaklanmış bir öğrenme süreci sunarak özellikle tıbbi görüntü analizi gibi hassas alanlarda büyük bir avantaj sağlamaktadır. OCT görüntüleri üzerindeki uygulanabilirliği sayesinde, retina hastalıklarının teşhisi ve takibinde yeni bir yaklaşım sunmaktadır. Bu modelin gelişimi, sadece oftalmoloji alanında değil, genel olarak bilgisayarlı görme ve tıbbi görüntüleme alanlarında da önemli bir yenilik olarak değerlendirilmektedir. LICNN'in geleneksel CNN modelleri ile karşılaştırmalı olarak

değerlendirilmesi, yapay zeka destekli tıbbi teşhis süreçlerini daha hassas ve güvenilir hale getirme potansiyeline sahiptir. Bu nedenle, ilerleyen çalışmalarda LICNN'in farklı tıbbi görüntüleme uygulamalarında da test edilmesi ve optimize edilmesi, bilgisayarlı görme alanındaki yenilikçi yaklaşımlar arasında yer alacaktır.

2.5.1. Mexican Hat Fonksiyonunun LICNN İçindeki Rolü

LICNN'in temelinde lateral inhibisyon mekanizmasını daha verimli hale getirmek için kullanılan Mexican Hat fonksiyonu bulunmaktadır. Bu fonksiyon, sinir ağı içerisinde nöronların birbiriyle olan etkileşimlerini biyolojik sinir sistemlerinden esinlenerek modellemekte ve görüntü analizi süreçlerinde daha iyi kontrast iyileştirmesi sağlamaktadır. Mexican Hat fonksiyonu, Doğrusal Olmayan Diferansiyel Lateral İnhibisyon (NLDLI) mekanizmasının temelini oluşturarak, nöronal aktivasyonun çevresel nöronlar tarafından dinamik olarak modüle edilmesini sağlar (64, 65).

Matematiksel olarak, Mexican Hat fonksiyonu şu şekilde tanımlanabilir (66, 67):

Mexican Hat fonksiyonunun LICNN içerisinde uygulanması, diferansiyel lateral inhibisyon bölgesi (LIZ) tanımlanarak gerçekleştirilir. Bu bölgede, bir nöronun aktivasyonu, komşu nöronların aktivasyon seviyesine bağlı olarak güncellenir ve şu şekilde formüle edilir:

$$LI_{ij} = \sum_{uv \in LIZ} w_{uv} \cdot x_{uv} - x_{ij} \quad (\text{Eşitlik 1})$$

Burada:

x_{ij} : Merkezi nöronun aktivasyonu

w_{uv} : Mexican Hat fonksiyonuna dayalı ağırlık matrisi

x_{uv} : Komşu nöronların aktivasyon değeri

LI_{ij} : Lateral İnhibisyon etkisi

Bu fonksiyon, **iki temel bileşen** içerir:

1. **Pozitif merkez bölgesi:** Fonksiyonun merkezinde, nöronun aktivasyonunu arttıran bir alan bulunmaktadır. Bu, görsel sistemde bir kenarın veya belirli bir yapının algılanmasını güçlendirmeye yardımcı olur.

2. **Negatif çevresel bölge:** Fonksiyonun çevresel bölgelerinde, aktivasyonu baskılayan negatif ağırlıklı bir alan bulunmaktadır. Bu, lateral inhibisyon prensibiyle uyumlu olarak gereksiz bilgilerin baskılanmasını sağlar ve görüntüde kontrastı artırır.

Bu mekanizma sayesinde, LICNN modeli belirli bölgelerdeki nöronları daha belirgin hale getirirken, çevresel bölgelerdeki gereksiz detayları baskılamaktadır. Mexican Hat fonksiyonunun uygulaması, özellikle OCT gibi tıbbi görüntülerde önemli yapıların daha iyi algılanmasını ve düşük kontrastlı alanların güçlendirilmesini sağlamaktadır.

Mexican Hat fonksiyonunun LICNN içindeki etkileri şunlardır (64):

- **Kontrast Artırma:** Mexican Hat fonksiyonu, belirginlik analizi yaparak düşük kontrastlı bölgeleri öne çıkarmakta ve modelin hassasiyetini artırmaktadır.
- **Gürültü Azaltma:** Kenarların daha iyi tanımlanmasını sağladığı için, özellikle OCT gibi karmaşık yapıları görüntülerde yanlış sınıflandırmaları minimize eder.
- **Özellik Seçiciliği:** Derin öğrenme modelinin yalnızca en kritik bölgelere odaklanmasını sağlayarak, modelin gereksiz bilgileri öğrenmesini önler.

LICNN, lateral inhibisyon mekanizmasını kullanarak geleneksel CNN yapılarının eksikliklerini gidermeyi hedeflemekte ve tıbbi görüntü analizi alanında önemli avantajlar sağlamaktadır. Mexican Hat fonksiyonunun entegrasyonu, modelin görsel özellikleri daha doğru bir şekilde ayrıştırmasını ve hastalık tespitinde daha yüksek doğruluk oranlarına ulaşmasını mümkün kılmaktadır. Bu bağlamda, LICNN'in OCT görüntüleri üzerindeki kullanımı, retinal hastalıkların daha erken evrede ve daha hassas bir şekilde teşhis edilmesine katkı sağlamaktadır.

Mexican Hat fonksiyonunun LICNN içerisine entegrasyonu, biyolojik sinir sistemlerinden ilham alınarak geliştirilen yapay zeka modellerinin, tıbbi görüntüleme gibi hassas alanlarda nasıl daha etkin hale getirilebileceğini göstermektedir. Gelecekte, bu modelin farklı tıbbi görüntüleme modalitelerinde de test edilmesi, yapay zeka tabanlı tanı süreçlerinin daha da ileriye taşınmasına olanak sağlayacaktır.

2.6. Literatürdeki Mevcut Çalışmalar ve Açık Araştırma Alanları

OCT görüntülerinin derin öğrenme tabanlı analizine yönelik son yıllarda çok sayıda çalışma gerçekleştirilmiştir. Bu çalışmalar, oftalmolojik hastalıkların erken tanısı ve sınıflandırılmasının daha doğru ve hızlı bir şekilde yapılmasını amaçlamaktadır. Derin

öğrenme algoritmaları, OCT görüntülerindeki karmaşık desenleri ve patolojik bulguları yakalayarak tanı doğruluğunu önemli ölçüde artırmaktadır.

Rajagopalan ve ark. (7) tarafından yapılan bir çalışma, koroidal neovaskülerizasyon (CNV), Drusen'e Bağlı Makula Dejenerasyonu (DMD) ve diyabetik maküler ödem (DME) gibi üç farklı Drusen maküler Dejenerasyon retinal hastalığının sınıflandırılması için bir CNN modeli önermiştir. Çalışma, modelin hiperparametrelerinin optimize edilmesiyle %97,01 doğruluk oranına ulaştığını göstermiştir (7). Benzer bir çalışma olan Rozhyna ve ark. (68), transfer öğrenme teknikleri kullanarak farklı CNN mimarilerini (VGG16, VGG19, ResNet50, MobileNet, InceptionV3 ve Xception) karşılaştırmış ve bu modellerin OCT görüntülerindeki retina hastalıklarının tanısında etkili olduğunu ortaya koymuştur (68).

Derin sinir ağlarının OCT görüntülerinde kullanılmasını inceleyen diğer bir çalışma olan Khudhur (69), geleneksel CNN modellerinin havuzlama (pooling) katmanları nedeniyle bilgi kaybına neden olabileceğini belirtmiş ve transfer öğrenme ile optimize edilmiş VGG16 modelinin OCT görüntülerinde %97 sınıflandırma doğruluğu sağladığını rapor etmiştir. Bu çalışma, geleneksel CNN mimarilerinin yerine daha optimize edilmiş ve transfer öğrenme ile geliştirilmiş modellerin kullanılmasının avantajlarını vurgulamaktadır.

Chan ve ark. (70) tarafından yapılan bir başka çalışma, transfer öğrenme tekniklerini kullanarak Diyabetik Maküler Ödem (DME) tespitinde önemli ilerlemeler kaydetmiştir. Bu çalışma, önceden eğitilmiş AlexNet modelinin SVM (Support Vector Machine) ile birleştirilmesi sonucunda %96 sınıflandırma doğruluğu elde edildiğini göstermiştir. Saraiva ve ark. (71) tarafından gerçekleştirilen bir başka çalışma ise, k-fold çapraz doğrulama yöntemi kullanarak bir CNN modeli üzerinden OCT görüntülerini sınıflandırmış ve %94,35 doğruluk oranına ulaştığını bildirmiştir.

Kayadibi (72) tarafından yapılan çalışma ise transfer öğrenme teknikleri ile ön işlenmiş OCT görüntülerinde AlexNet modelinin performansını değerlendirmiş ve %99,70 doğruluk oranı elde edildiğini belirtmiştir. Benzer bir çalışma olan Metin ve Karasulu (73), ResNet50 ve MobileNetV2 modellerini kullanarak OCT görüntülerini sınıflandırmış ve doğruluk oranlarının %81 ile %94 arasında değiştiğini rapor etmiştir.

Derin öğrenme modellerinin etkinliğini inceleyen başka çalışmalar da EfficientNet ve Xception gibi modern CNN mimarilerinin OCT verileri üzerinde başarılı olduğunu ortaya koymuştur (74,75). Bu çalışmalar, derin öğrenme modellerinin, OCT görüntülerinden elde

edilen verilerle hastalık sınıflandırma performansını önemli ölçüde artırdığını ortaya koymaktadır.

Esfahani ve ark. (8) tarafından yapılan çalışma, drusen, koroidal neovaskülarizasyon (CNV) ve diyabetik maküler ödem (DME) gibi yaygın retinal patolojilerin tespiti için yapay zeka tabanlı bir model geliştirmiştir. Çalışmada, Kaggle.com üzerinden temin edilen 1.528 OCT görüntüsünden oluşan geniş bir veri seti kullanılarak model eğitilmiş ve değerlendirilen performans metrikleri oldukça yüksek doğruluk oranları elde etmiştir. Geliştirilen model, %99 doğruluk, %96.2 duyarlılık (recall), %98.5 hassasiyet (sensitivity) ve %98.7 özgüllük (specificity) değerleri ile retinal patolojileri ayırt etmede başarılı olmuştur. Çalışmanın bulguları, derin öğrenme tabanlı otomatik sınıflandırma modellerinin, göz hastalıklarının erken teşhisinde önemli bir yardımcı araç olarak kullanılabileceğini göstermektedir. Bununla birlikte, modelin klinik entegrasyonu ve genelleştirilebilirliğini değerlendirmek amacıyla daha fazla bağımsız veri setleri ile doğrulama çalışmalarına ihtiyaç duyulduğu belirtilmektedir. Bu araştırma, oftalmolojik hastalıkların erken teşhisi ve yönetimi açısından derin öğrenmenin klinik karar destek sistemlerine entegrasyon potansiyelini vurgulamaktadır.

Berrimi ve Moussaoui (9) tarafından gerçekleştirilen çalışma, optik koherens tomografi (OCT) görüntüleri kullanılarak retinal hastalıkların otomatik sınıflandırılmasına yönelik derin öğrenme tabanlı bir model önermektedir. Çalışmada, transfer öğrenme teknikleri kullanılarak farklı konvolüsyonel sinir ağı (CNN) mimarileri karşılaştırılmış ve InceptionV3 modelinin %99.27 doğruluk oranı ile en iyi performansı gösterdiği belirlenmiştir. Ayrıca, VGG-16 modelinin mimarisinde yapılan iyileştirmelerle doğruluk oranı %93.5'e yükseltilmiştir. Elde edilen bulgular, derin öğrenme modellerinin retinal hastalıkların erken teşhisinde etkili bir araç olabileceğini ortaya koymaktadır.

Kim ve Tran (6) tarafından yapılan çalışma, optik koherens tomografi (OCT) görüntülerinden retinal hastalıkların sınıflandırılması için derin öğrenme modelleri önermektedir. Çalışmada, koroidal neovaskülarizasyon (CNV), diyabetik maküler ödem (DME), Drusen ve Normal olmak üzere dört kategoriye ayırma işlemi gerçekleştirilmiş ve farklı konvolüsyonel sinir ağı (CNN) modelleri kullanılarak sınıflandırma başarımları karşılaştırılmıştır. Özellikle VGG16, VGG19, ResNet50, ResNet152, DenseNet121 ve InceptionV3 modelleri özellik çıkarıcı olarak kullanılmış ve en iyi performans, belirli hastalıklar için özelleştirilmiş CNN modellerinin birleşimiyle elde edilmiştir. Önerilen

model, %98.7 doğruluk, %98.7 duyarlılık ve %99.6 özgüllük ile yüksek sınıflandırma başarımı göstermiştir. Normal sınıfı için geliştirilen ikili sınıflandırıcı ise %99.9 doğruluk oranına ulaşmıştır. Çalışmanın bulguları, derin öğrenme tabanlı yaklaşımların oftalmologlara yardımcı bir teşhis aracı olarak kullanılabileceğini göstermektedir.

Karri ve ark. (76), transfer öğrenmeye dayalı bir sınıflandırma algoritması geliştirerek, önceden eğitilmiş GoogLeNet modelini ince ayarlamış ve diyabetik maküler ödem (DME) ile kuru tip yaşa bağlı maküler dejenerasyon (Dry-AMD) hastalıklarını OCT görüntüleri üzerinden başarılı bir şekilde tespit etmiştir. Çalışmada, modelin rastgele başlatma ile eğitilmesine kıyasla önceden eğitilmiş ağırlıklarla ince ayarlanmasının daha yüksek doğruluk sağladığı gösterilmiştir. Ayrıca, eğitim sürecinde modelin hangi filtreleri öğrendiğini anlamak amacıyla belirgin yanıtlar analiz edilmiştir. Bu çalışma, tıbbi görüntü sınıflandırma problemlerinde, medikal olmayan veri setleri üzerinde eğitilmiş derin öğrenme modellerinin sınırlı eğitim verisi ile başarılı bir şekilde uyarlanabileceğini ortaya koymaktadır.

Yang ve ark. (77), transfer öğrenme tabanlı açıklanabilir bir topluluk öğrenme yöntemi geliştirerek, OCT görüntülerinde fundus lezyonlarının tespitini gerçekleştirmiştir. Çalışmada, önceden eğitilmiş ImageNet ağırlıklarının kullanılmasıyla model performansının %68.17'den %92.89'a yükseldiği gösterilmiştir. Araştırmacılar, üç farklı CNN modelini bir araya getirerek yumuşak çoğunluk oylaması (soft polling) yöntemiyle en iyi sonuçları elde etmiş ve yaşa bağlı maküler dejenerasyon (AMD), diyabetik maküler ödem (DME) ve sağlıklı retina durumlarını %100 doğrulukla ayırt etmeyi başarmıştır. Ayrıca, modelin karar mekanizmasını açıklamak için Grad-CAM ve CAM teknikleri kullanılarak, modelin lezyon bölgelerini daha doğru bir şekilde vurguladığı gözlemlenmiştir. Bu çalışma, OCT görüntüleri üzerinde transfer öğrenme ve topluluk öğrenme yöntemlerinin hem yüksek doğruluk hem de açıklanabilirlik açısından etkili bir şekilde kullanılabileceğini ortaya koymaktadır.

Son olarak, Aykat (78) tarafından yapılan doktora tezinde, Diyabetik Retinopati ve Yaşa Bağlı Makula Dejenerasyonu hastalıklarının erken teşhisi için hibrit bir derin öğrenme modeli geliştirilmiştir. Kanuni Sultan Süleyman Eğitim ve Araştırma Hastanesi'nden toplanan OCT görüntülerinin analiz edildiği bu çalışma, hiperparametre ayarları yapılarak optimize edilmiş ve geliştirilen hibrit modelin mevcut çalışmaların önüne geçtiğini göstermiştir.

Sonuç olarak, literatürdeki bu çalışmalar, OCT görüntülerinin analizinde derin öğrenme algoritmalarının etkinliğini kanıtlamaktadır. Özellikle transfer öğrenme ve hiperparametre optimizasyonu tekniklerinin kullanılması, bu modellerin klinik ortamda daha yaygın hale gelmesini sağlayacak önemli adımlardır.

Derin öğrenme modellerinin OCT görüntü sınıflandırma süreçlerindeki başarısına rağmen, literatürde halen çeşitli zorluklar ve iyileştirilmesi gereken alanlar bulunmaktadır. Özellikle, eğitim veri setlerinin yetersizliği ve dengesiz sınıf dağılımı, model performansını etkileyen en büyük sorunlardan biridir. OCT görüntülerinin klinik kullanımı sırasında ortaya çıkan düşük kontrastlı yapılar ve ince detayların kaybolması da derin öğrenme modellerinin hata oranlarını artırmaktadır. Bu nedenle, mevcut çalışmalarda veri setlerini çeşitlendirmek ve yapay veri üretme tekniklerini kullanarak modelin genelleme kapasitesini artırmak üzerine yoğunlaşılmaktadır.

Lateral inhibisyon (LI), biyolojik sinir sistemlerinde nöronlar arasındaki rekabetçi etkileşimi düzenleyen temel bir mekanizma olup, görsel korteks başta olmak üzere birçok duysal işleme sürecinde önemli bir rol oynamaktadır. Görme sisteminde, kenar algılama, kontrast artırma ve dikkat mekanizmalarının düzenlenmesi için kullanılır. Son yıllarda, yapay sinir ağları (Artificial Neural Networks- ANN) ve konvolüsyonel sinir ağları (CNN) gibi derin öğrenme modellerinde de lateral inhibisyon prensiplerinin uygulanması üzerine birçok araştırma yapılmıştır. Bu çalışmalarda, görsel dikkat mekanizmaları, nesne algılama, sınıflandırma performansı ve kenar tespiti gibi alanlarda LI temelli yaklaşımların etkisi incelenmiştir.

Cao ve ark. (58), lateral inhibisyonun görsel dikkat ve belirginlik tespiti (saliency detection) üzerindeki etkilerini inceleyen Lateral Inhibition Convolutional Neural Network (LICNN) modelini geliştirmiştir. LICNN modeli, klasik CNN mimarisine lateral inhibisyonu entegre ederek kategorik dikkati artırma ve belirgin nesne tespiti için yeni bir yöntem önermektedir. Model, özellikle ECSSD, HKU-IS, PASCAL-S ve DUT-OMRON veri setleri üzerinde yapılan deneylerde kategori seviyesinde dikkat haritalarını üretmede üstün performans göstermiştir. Bu çalışma, biyolojik tabanlı inhibisyon mekanizmalarının yapay görme sistemlerinde nasıl optimize edilebileceğine dair önemli bir örnek sunmaktadır.

Buna benzer şekilde, Zhuang ve ark. (79), lateral inhibisyon mekanizmasının görüntü sınıflandırma üzerindeki etkisini incelemiştir. Bu çalışmada, görsel kortekste kontrastı artırmak için komşu nöronları baskılayan Mach Band etkisini modelleyen bir CNN mimarisi

önerilmiştir. Önerilen yapıda, lateral inhibisyon düşük geçişli (low-pass) bir filtreyle merkezi ağırlık kaldırılarak simüle edilmiş, ardından bu filtreleme sonucu girişten çıkarılarak kontrastın artırılması sağlanmıştır. Ayrıca, her kanal için öğrenilebilir bir parametre kullanılarak, lateral etkileşimlerin esnek biçimde modellenmesine olanak tanınmıştır. Elde edilen sonuçlarda, AlexNet ve ResNet-18 gibi yaygın CNN modellerine lateral inhibisyon mekanizmasının entegrasyonu ile sırasıyla **%3.68** ve **%0.69** oranında doğruluk artışı sağlandığı gösterilmiştir. Bu çalışma, lateral inhibisyonun özellikle derin öğrenme modellerinde veri temsiliyi iyileştirme ve model performansını artırma potansiyeline sahip olduğunu ortaya koymaktadır.

Denman ve ark. (59), lateral inhibisyonun konvolüsyonel sinir ağlarında nasıl modellenebileceğini inceleyen bir diğer çalışmada, yanal bağlantıların filtreler arasındaki etkileşimleri düzenleyerek daha iyi özellik haritaları oluşturduğunu ortaya koymuştur. Çalışmada, autoassociative lateral inhibition olarak adlandırılan üç farklı strateji önerilmiş ve rekürsif inhibisyon sürecinin analitik olarak istikrarlı bir dağılıma ulaşabileceği gösterilmiştir. Bu yaklaşımın, görüntü sınıflandırma performansını artırırken modelin parametre yükünü artırmadan öğrenme sürecini iyileştirdiği belirlenmiştir. Özellikle, konvolüsyon katmanları arasındaki etkileşimleri düzenleyerek daha verimli özellik ayırımı sağladığı gözlemlenmiştir.

Lateral inhibisyonun kenar tespiti ve nesne belirginliği üzerindeki etkisini inceleyen bir diğer çalışma ise Fu ve Li (80) tarafından yapılmıştır. Çalışmada, görüntülerin kenarlarını daha keskin hale getirmek ve bozulmaları minimize etmek için lateral inhibisyon temelli bir model önerilmiştir. Bu model, biyolojik görme sistemindeki yanal inhibisyon prensiplerini kullanarak, geleneksel LOG (Laplacian of Gaussian) kenar tespit algoritmalarına kıyasla daha yüksek doğruluk sağlamıştır. Önerilen Acyclic Lateral Inhibition Network Model (ALINM), görüntü işleme sürecinde daha fazla detay bilgisini koruyarak, hesaplama hızını artırmak için optimize edilmiştir. Bu çalışma, biyolojik temelli görüntü işleme yaklaşımlarının etkinliğini ortaya koymaktadır.

Marcinek (61) tarafından yapılan bir başka araştırma, lateral inhibisyonun derin öğrenme modellerinde yanlış sınıflandırmalara karşı dayanıklılığı artırma potansiyelini incelemiştir. Çalışmada, LICNN modelinin sınıflandırma sürecinde arka plan piksellerinin etkisini azalttığı ve modelin dikkatini nesneye yönlendirdiği gösterilmiştir. Deneyler, yanlış sınıflandırılan nesnelerin genellikle arka plandaki yapılar nedeniyle bu hataya düştüğünü

ortaya koymuş ve lateral inhibisyonun bu etkiyi azaltarak sınıflandırma doğruluğunu artırdığı gözlemlenmiştir. Bu çalışma, özellikle nesne tespiti ve görsel dikkat mekanizmaları açısından lateral inhibisyonun önemini vurgulamaktadır.

Literatürde yapılan araştırmalar, lateral inhibisyonun derin öğrenme modellerine entegrasyonunun, özellikle görsel dikkat, nesne belirginliği, görüntü sınıflandırma ve kenar tespiti gibi alanlarda önemli faydalar sağladığını göstermektedir. CNN'lere lateral inhibisyon prensiplerinin eklenmesi, modelin kontrast hassasiyetini artırarak daha keskin ve ayrıntılı görüntü analizleri yapmasını sağlamaktadır. Özellikle saliency detection (belirginlik tespiti), rekabetçi nöron etkileşimleri ve görüntü kenar analizleri gibi uygulamalarda lateral inhibisyonun büyük katkılar sunduğu gözlemlenmiştir. Sonuç olarak, biyolojik temelli bu mekanizmanın gelecekte daha gelişmiş yapay görme sistemlerinde etkin bir şekilde kullanılabileceği düşünülmektedir.

Bilgisayarlı görme alanındaki güncel çalışmalara bakıldığında, lateral inhibisyon tabanlı konvolüsyonel sinir ağlarının (LICNN) özellikle tıbbi görüntüleme ve nesne algılama alanlarında umut verici sonuçlar verdiği görülmektedir. Yapılan araştırmalar, bu yaklaşımın özellikle düşük kontrastlı ve karmaşık yapıları görüntülerde, geleneksel CNN tabanlı yaklaşımlara göre daha iyi sonuçlar verdiğini göstermektedir. Lateral inhibisyonun biyolojik sistemlerde kontrast artırma ve bilgi işleme süreçlerini iyileştirme kabiliyeti, bilgisayarlı görme uygulamalarında da etkin bir şekilde kullanılabilmektedir. Ancak, mevcut literatürde lateral inhibisyonun derin öğrenme modellerine entegrasyonuna dair yeterli sayıda çalışma bulunmamaktadır. Bu durum, bu alandaki araştırmaların daha fazla derinleştirilmesi gerektiğini ve yeni modelleme yaklaşımlarına ihtiyaç duyulduğunu ortaya koymaktadır.


Bu tez çalışması, literatüre birkaç kritik açıdan katkı sağlamayı hedeflemektedir. Öncelikle, lateral inhibisyonun konvolüsyonel sinir ağlarına entegrasyonu konusunda kapsamlı bir model geliştirilerek, bu mekanizmanın OCT görüntülerinin analizinde nasıl bir iyileştirme sağlayabileceği detaylı bir şekilde araştırılacaktır. Daha önce yapılan çalışmaların büyük bir kısmı, doğrudan CNN modelleri üzerine yoğunlaşırken, biyolojik sinir ağlarından esinlenerek geliştirilen lateral inhibisyon mekanizmasının, tıbbi görüntü analizinde ne kadar etkili olduğu konusunda sınırlı bilgi sunmaktadır. Bu nedenle, önerilen yöntem, retinal OCT görüntülerinin sınıflandırılmasını daha hassas hale getirerek klinik karar destek sistemlerine katkıda bulunabilir.

Ayrıca, bu çalışmada kullanılacak olan lateral inhibisyon tabanlı derin öğrenme modelinin, geleneksel CNN modellerine kıyasla karşılaştırmalı analizleri yapılarak, modelin avantajları ve sınırlamaları belirginleştirilecektir. Böylece, OCT görüntülerinin daha etkin bir şekilde işlenmesi ve hastalık tespit süreçlerinin daha hassas hale getirilmesi amaçlanmaktadır. Geliştirilecek model, özellikle göz hastalıklarının erken teşhisini desteklemek amacıyla geliştirileceğinden, klinik kullanım alanlarında doğrudan uygulanabilirliği değerlendirilecektir. Bu bağlamda, geliştirilen modelin sadece retinal hastalık teşhisinde değil, diğer tıbbi görüntüleme alanlarında da uygulanabilirliğinin araştırılması, literatüre katkı sağlayacak önemli bir alan olarak öne çıkmaktadır.

Sonuç olarak, literatürdeki mevcut çalışmalar, derin öğrenme tabanlı OCT görüntü analizi ve lateral inhibisyonun bilgisayarlı görme alanındaki kullanımı konusunda önemli gelişmeler sağlamış olsa da, bu iki alanın kesişiminde henüz yeterli çalışma bulunmamaktadır. Bu tez, lateral inhibisyon mekanizmasını CNN tabanlı bir model içerisine entegre ederek, OCT görüntülerinin daha doğru ve güvenilir bir şekilde analiz edilmesine yönelik yenilikçi bir bakış açısı sunmayı amaçlamaktadır. Bu doğrultuda, geliştirilecek modelin oftalmoloji alanında klinik pratiklere doğrudan entegre edilmesi hedeflenmekte ve tıbbi teşhis süreçlerinde yapay zeka destekli karar verme sistemlerinin etkinliğini artırması beklenmektedir.

3. GEREÇ ve YÖNTEM

Bu çalışmada kullanılan derin öğrenme mimarisi, ImageNet veri seti üzerinde önceden eğitilmiş olan bir **pre-trained transfer learning modeli** temel alınarak oluşturulmuştur. Modelin girişine 224×224 ve 299×299 piksel boyutlarında ve üç kanallı (RGB) optik koherens tomografi (OCT) görüntüleri verilmiştir. Transfer öğrenme modeli, sınıflandırma katmanları hariç tutulacak şekilde (`include_top=False`) kullanılmış ve yalnızca evrimsel (convolutional) katmanlardan oluşan özellik çıkarım yapısı değerlendirilmiştir (Şekil 8).



Şekil 8. Önerilen sınıflandırma modelinin genel mimarisi

Görüntü, modelin girişine verildikten sonra, tüm ReLU aktivasyon katmanlarının çıktıları alınmıştır. Bu aktivasyon haritaları, modelin hangi bölgelere daha fazla duyarlı olduğunu analiz edebilmek amacıyla işlenmiştir. Bu noktada, her bir aktivasyon haritası üzerinde kanal bazında maksimum değer hesaplanmış ve ardından lateral inhibisyon (yanal inhibisyon) uygulanmıştır. Lateral inhibisyon işlemi için Mexican Hat çekirdeği kullanılmış ve her aktivasyon haritasına derinlik bazlı evrişim (depthwise convolution) işlemi gerçekleştirilmiştir. Bu yöntem, görüntüdeki belirgin kenarları ve önemli bölgeleri daha da öne çıkararak dikkat haritalarının (saliency map) oluşturulmasına olanak sağlamıştır.


Lateral inhibisyon uygulanan aktivasyon haritaları daha sonra 224×224 ve 299×299 boyutuna yeniden ölçeklendirilmiş ve tüm haritalar `reduce_sum` işlemiyle birleştirilmiştir. Elde edilen birleşik harita, L_2 normalizasyonu ile ölçeklendirilmiş ve sonuç olarak bir dikkat haritası (saliency map) üretilmiştir. Ancak bu harita yalnızca analitik değerlendirme ve modelin odaklandığı bölgelerin görselleştirilmesi amacıyla oluşturulmuş olup, doğrudan sınıflandırma sürecine dahil edilmemiştir.

Ana sınıflandırma akışı, transfer öğrenme modelinin son katmanından elde edilen özellik haritaları üzerine kurulmuştur. Bu çıkış, öncelikle Global Average Pooling (GAP) katmanına aktarılmış, böylece her bir özellik haritasının ortalama değeri elde edilmiştir. Ardından aşırı öğrenmeyi önlemek amacıyla %50 oranında Dropout uygulanmıştır. Bu katmanı, 256 nöronlu ve ReLU aktivasyon fonksiyonlu bir tam bağlantılı (Dense) katman takip etmiştir. İkinci bir Dropout uygulamasının ardından, dört sınıfı temsil eden çıkış birimlerine sahip Softmax aktivasyonlu bir Dense katman kullanılarak son sınıf tahmini gerçekleştirilmiştir.

Model, Adam optimizasyon algoritması kullanılarak ve kayıp fonksiyonu olarak kategorik çapraz entropi (categorical_crossentropy) seçilerek derlenmiştir. Eğitim sırasında veri artırımı (augmentation) teknikleri uygulanarak modelin genelleme kapasitesi artırılmıştır. Ayrıca sınıf dengesizliklerini azaltmak amacıyla, eğitim setindeki sınıf dağılımına göre ağırlıklandırma yapılmıştır (class_weight). Eğitim işlemi 20 epoch boyunca yürütülmüştür.

Modelin performansı, test veri seti üzerinde sınıf doğrulukları karışıklık matrisi (confusion matrix) ve sınıflandırma raporu (classification report) kullanılarak değerlendirilmiştir. Böylece modelin hem genel doğruluk düzeyi hem de her bir sınıfa özgü duyarlılık ve özgüllük gibi performans metrikleri ayrıntılı şekilde raporlanmıştır.


Bu çalışmada, Kermany ve ark. (81), (2018) tarafından oluşturulan OCT 2018 veri seti kullanılmıştır. Bu veri seti, Kaggle platformunda yer alan <https://www.kaggle.com/datasets/paultimothymooney/kermany2018> adresinde yayınlanmış olup, toplamda 84.453 OCT görüntüsünden oluşmaktadır. Veri seti, retinal hastalıklarını sınıflandırmak amacıyla oluşturulmuş olup dört farklı kategori içermektedir (Şekil 9): Koroidal Neovaskülerizasyon (CNV), Diyabetik Maküler Ödem (DME), Drusen ve Normal (sağlıklı) retina görüntüleri. Bu veri seti, oftalmolojik teşhis süreçlerinde yapay zeka tabanlı modellerin geliştirilmesi amacıyla geniş çapta kullanılmaktadır.



Şekil 9. OCT veri seti dağılımı


Modelin etkin bir şekilde eğitilebilmesi ve değerlendirilebilmesi amacıyla, veri seti eğitim, test ve doğrulama olmak üzere üç farklı alt kümeye ayrılmıştır (Şekil 10):

Veri Seti Dağılımı (Eğitim, Doğrulama, Test)



Şekil 10. Veri seti dağılımı (Eğitim, Doğrulama, Test)

- **Eğitim Verisi (%80):** Modelin öğrenme sürecinde kullanılan en büyük veri kümesi olup, derin öğrenme modellerinin parametrelerini optimize etmek için kullanılmıştır.
- **Test Verisi (%19):** Modelin eğitimi tamamlandıktan sonra, genel performansını değerlendirmek için kullanılan veri kümesidir. Test verisi, modelin genelleme yeteneğini ölçmek amacıyla model eğitimi sürecinde kullanılmamıştır.
- **Doğrulama Verisi (%1):** Modelin eğitim sürecinde aşırı uyumu (overfitting) engellemek ve hiperparametre optimizasyonunu sağlamak için kullanılmıştır. Doğrulama kümesi, modelin optimizasyon sürecinde modelin erken durdurulmasına (early stopping) karar verilmesine yardımcı olmuştur.




Şekil 11. Veri seti örnek resimler

OCT Veri Setine ait örnek resimler Şekil 11’de gösterilmiştir. Eğitim, Doğrulama ve Test Setine ait sayısal değerler ve grafik Tablo 2 ve Şekil 12’de gösterilmiştir.

Tablo 2. Eğitim, Doğrulama ve Test setine ait sayısal değerler

Sınıf	Eğitim Seti	Doğrulama Seti	Test Seti
CNV	29964	367	7124
DME	9290	128	2180
DRUSEN	7094	87	1654
NORMAL	21308	267	4990



Şekil 12. Eğitim, Doğrulama ve Test setine ait sayısal değerler

OCT görüntüleri büyük boyutlu olduğu için, modelin eğitimi ve test süreci kişisel bilgisayarlarda gerçekleştirilemeyecek kadar yüksek hesaplama gücü gerektirmiştir. Bu nedenle, tüm veri işleme ve model eğitimi süreçleri Google Colab platformu kullanılarak gerçekleştirilmiştir. Google Colab, yüksek performanslı GPU (Graphics Processing Unit) ve TPU (Tensor Processing Unit) desteği ile büyük ölçekli veri kümeleri üzerinde derin öğrenme modellerinin eğitilmesine olanak tanımaktadır. Model eğitimi sürecinde Google'ın ücretli GPU hizmeti kullanılmıştır. Böylece, karmaşık hesaplamalar hızlandırılmış ve model eğitiminin süresi optimize edilmiştir.

Derin öğrenme modellerinin başarılı bir şekilde eğitilebilmesi için veri ön işleme adımları büyük önem taşımaktadır. Bu çalışmada, Optik Koherens Tomografi görüntülerinin analiz için uygun hale getirilmesi amacıyla çeşitli veri ön işleme teknikleri uygulanmıştır. Bu süreç, modelin doğruluğunu artırmak, veri dengesizliğini gidermek ve modelin genelleme yeteneğini iyileştirmek amacıyla gerçekleştirilmiştir. Bu adımlar aşağıda detaylı olarak açıklanmaktadır:

OCT veri setinde bulunan görüntülerin farklı çözünürlüklerde olması nedeniyle, tüm görüntüler belirli bir standart boyuta ölçeklendirilmiştir. Kullanılan CNN modeline bağlı olarak farklı giriş boyutları belirlenmiştir:

- **DenseNet121 ve ResNet50 modelleri için giriş boyutu: 224x224 piksel**
- **Xception ve Inception modelleri için giriş boyutu: 299x299 piksel**

Bu işlem, konvolüsyonel sinir ağı (CNN) modellerinin giriş katmanlarına uygun hale getirilmesi için gerçekleştirilmiştir. Ölçeklendirme işlemi, görüntülerin belirli bir piksel yoğunluğunda işlenmesini sağlayarak modelin daha doğru sonuçlar üretmesine katkı sağlamaktadır.

Modelin giriş boyutları, kullanılan mimarinin gereksinimlerine göre belirlenmiştir. Bu çalışmada kullanılan CNN mimarilerinden **ResNet50** ve **DenseNet121**, giriş görüntülerinin boyutunun **224×224 piksel** olmasını gerektirmektedir. Bu nedenle, tüm eğitim, doğrulama ve test görüntüleri bu boyutlara yeniden ölçeklendirilmiştir.

Öte yandan, eğer **Xception** veya **Inception** gibi mimariler tercih edilecek olursa, bu mimariler standart olarak **299×299 piksel** boyutlarında giriş beklemektedir. Bu tür durumlar için alternatif boyutlandırma opsiyonları da dikkate alınmıştır.

Derin öğrenme modellerinin daha hızlı ve stabil eğitilmesi için piksel değerleri 0 ile 1 arasına ölçeklendirilmiştir. Bu işlem, görüntülerin farklı parlaklık ve kontrast seviyelerini modelin daha iyi öğrenmesini sağlamak amacıyla uygulanmıştır. Bu amaçla, tüm görüntülerin piksel değerleri 255'e bölünerek normalize edilmiştir.

Modelin genelleme yeteneğini artırmak ve aşırı öğrenme (overfitting) riskini azaltmak amacıyla veri artırma teknikleri kullanılmıştır. Bu teknikler sayesinde, modelin farklı açılardan gelen görüntüleri tanıması sağlanarak gerçek dünyadaki varyasyonlara karşı daha dayanıklı hale getirilmiştir. Uygulanan veri artırma işlemleri aşağıda açıklanmaktadır:

- **Görüntü Çevirme (Horizontal Flip):** Rastgele yatay çevirme işlemi, simetrik özelliklerin korunmasına yardımcı olmaktadır.
- **Döndürme (Rotation):** 15 dereceye kadar rastgele döndürme işlemi, modelin farklı açılardaki retina görüntülerini öğrenmesine katkı sağlamaktadır.
- **Yakınlaştırma (Zoom):** %10 oranında rastgele yakınlaştırma işlemi, retina katmanlarındaki küçük değişimlerin yakalanmasını sağlamak amacıyla uygulanmıştır.
- **Görüntü Kaydırma (Width Shift, Height Shift):** Görüntülerin genişlik ve yükseklik boyunca %20'ye kadar kaydırılması, görüntülerin farklı pozisyonlardaki varyasyonlarına karşı modelin duyarlılığını artırmaktadır.

- **Kesme Dönüştürme (Shear Transformation):** 15 dereceye kadar uygulanarak, retina tabakalarının farklı açılardaki görünümünü taklit etmek için kullanılmıştır.

Modelin eğitim sürecinde **veri seti üç farklı alt kümeye bölünmüştür:**

- **Eğitim Kümesi (Train Set - %80):** Modelin öğrenmesi için kullanılan en büyük veri kümesidir.
- **Doğrulama Kümesi (Validation Set - %1):** Modelin genelleme yeteneğini test etmek ve hiperparametre optimizasyonunu gerçekleştirmek için kullanılmıştır.
- **Test Kümesi (Test Set - %19):** Modelin eğitimi tamamlandıktan sonra gerçek performansını değerlendirmek için ayrılmıştır.

Verilerin eğitim, doğrulama ve test kümelerine uygun bir şekilde ayrılmasını sağlamak için **ImageDataGenerator** kütüphanesi kullanılmıştır:

OCT veri setinde bazı hastalık sınıfları diğerlerine kıyasla daha fazla görüntü içerebilmektedir. Bu dengesizlik, modelin baskın sınıfları daha iyi öğrenmesine ancak nadir görülen sınıfları ihmal etmesine neden olabilir. Bu nedenle, sınıf ağırlıkları hesaplanarak dengesizliğin giderilmesi sağlanmıştır.

Bunun için sklearn kütüphanesindeki `compute_class_weight` fonksiyonu kullanılmıştır.

Bu işlem, modelin nadir görülen sınıfları daha iyi öğrenmesine yardımcı olmaktadır.

Bu çalışmada uygulanan veri ön işleme adımları, OCT veri setinin standart hale getirilmesini, modelin genelleme yeteneğinin artırılmasını ve sınıf dengesizliğinin giderilmesini sağlamıştır. Bu süreçler, modelin eğitimi ve değerlendirilmesi aşamalarında daha sağlıklı sonuçlar elde edilmesine önemli ölçüde katkı sağlamaktadır.

Çalışma kapsamında transfer learning (aktarılabılır öğrenme) yaklaşımı kullanılarak önceden eğitilmiş dört farklı CNN modeli ile sınıflandırma yapılmış ve daha sonra Lateral İnhibisyon Temelli Konvolüsyonel Sinir Ağı (LICNN) uygulanarak sonuçlar karşılaştırılmıştır. Kullanılan modeller şunlardır:

1. **ResNet50:** Derin öğrenme modellerinde gradyan kaybolması sorununu çözmek için artık (residual) bağlantılar içeren bir modeldir. Özellikle derin ağ yapılarında yaygın olarak kullanılmaktadır.

2. **DenseNet121**: Her katmanın önceki katmanlardan gelen bilgileri kullanmasını sağlayarak, daha verimli ve hafif bir yapı sunan CNN modelidir.
3. **Xception**: Geleneksel konvolüsyon yerine ayırık (depthwise separable) konvolüsyon katmanlarını kullanarak parametre verimliliğini artıran bir modeldir.
4. **InceptionV3**: Farklı konvolüsyon filtrelerini aynı anda çalıştırarak, çok ölçekli özellik çıkarımı yapan ve daha yüksek doğruluk oranları sağlayan bir modeldir.

Bu modellerin performansları, **Lateral İnhibisyon Temelli CNN (LICNN)** modeli ile karşılaştırılmış ve sonuçlar **farklı değerlendirme metriği** kullanılarak analiz edilmiştir:

Tablo 3. Karışıklık matrisi

	Tahmin: Pozitif (+)	Tahmin: Negatif (-)
Gerçek: Pozitif (+)	Doğru Pozitif (DP)	Yanlış Negatif (YN)
Gerçek: Negatif (-)	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Yukarıdaki Tablo 3, bir sınıflandırma modelinin çıktılarını değerlendirmek amacıyla kullanılan **karışıklık matrisini** göstermektedir. Bu yapı, modelin tahmin ettiği etiketler ile gerçek sınıflar arasındaki ilişkiyi dört temel bileşen üzerinden özetlemektedir:

- **Doğru Pozitif (DP)**: Gerçek pozitif olan örneklerin model tarafından da pozitif olarak tahmin edildiği durumlar.
- **Yanlış Negatif (YN)**: Pozitif sınıfa ait olmasına rağmen modelin hatalı şekilde negatif olarak tahmin ettiği örnekler.
- **Yanlış Pozitif (YP)**: Negatif sınıfa ait olmasına rağmen modelin hatalı biçimde pozitif olarak sınıflandırdığı örnekler.
- **Doğru Negatif (DN)**: Gerçek negatif örneklerin doğru şekilde negatif olarak sınıflandırılması.

Bu dört bileşen temel alınarak doğruluk, duyarlılık, kesinlik, F1 skoru gibi performans metrikleri hesaplanabilir.

Bu kapsamda kullanılan temel performans ölçütlerinden biri duyarlılık ya da diğer adıyla hassasiyettir. Duyarlılık, modelin gerçek pozitif örnekleri ne ölçüde doğru sınıflandırabildiğini ifade eder. Matematiksel olarak duyarlılık şu şekilde tanımlanır:

$$Duyarlılık = \frac{DP}{DP+YN} \quad (\text{Eşitlik 2})$$

Özellikle sağlık alanında, yüksek bir duyarlılık değeri (genellikle ≥ 0.80), modelin gerçekten sağlık hizmetine ihtiyaç duyan bireyleri başarılı bir şekilde tespit ettiğini gösterir ve bu sayede yanlış negatiflerin (ihmal edilen vakaların) sayısı azaltılır (82). Sağlık sistemlerinde yanlış negatifler doğrudan müdahale eksikliğine neden olabileceğinden, duyarlılık değeri yüksek modeller klinik olarak daha güvenilirdir.

Kesinlik ise pozitif olarak tahmin edilen örneklerin ne kadarının gerçekten pozitif olduğunu gösterir. Yani modelin yanlış pozitif üretme oranını azaltma kabiliyetini yansıtır. Formülü aşağıdaki gibidir:

$$Kesinlik = \frac{DP}{DP+YP} \quad (\text{Eşitlik 3})$$

Yüksek bir kesinlik oranı, sağlık kaynaklarının gereksiz yere tüketilmesini önler ve yanlış yönlendirmeleri minimize eder. Özellikle sağlık sistemlerinde randevu planlama, önceliklendirme veya erken müdahale gibi süreçlerde kesinliğin yüksek olması, sistem verimliliğini doğrudan artırır (83).

Doğruluk (accuracy), modelin tüm doğru tahminlerinin toplam örnek sayısına oranı olarak tanımlanır ve şu şekilde formüle edilir (84):

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \quad (\text{Eşitlik 4})$$

F1 skoru, duyarlılık ve kesinlik arasındaki dengeyi ölçen bileşik bir metriktir. Bu skor, her iki ölçütü de dikkate alarak modelin genel başarımını özetleyen harmonik ortalamaya dayanır:

$$F1 \text{ Skor} = \frac{2 \text{ Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (\text{Eşitlik 5})$$

F1 skoru özellikle veri sınıfları arasında dengesizlik olduğunda veya yanlış pozitif ve yanlış negatiflerin klinik sonuçları birbirinden farklı ağırlıklara sahip olduğunda önem kazanmaktadır. Bu bağlamda yüksek F1 skorları, modelin hem eksik tespitleri hem de hatalı alarmları dengeleme kabiliyetine sahip olduğunu gösterir (85).


Buna ek olarak, ROC eğrisi altında kalan alan (AUC – Area Under the ROC Curve) metriği, modelin iki sınıfı ayırt etme becerisini ölçer. ROC eğrisi, farklı eşik değerlerine göre doğru pozitif oranı ile yanlış pozitif oranı arasındaki ilişkiyi gösterirken; AUC değeri bu eğrinin altında kalan toplam alanı ifade eder. İlgili oranlar aşağıdaki şekilde tanımlanır:

$$\text{Doğru Pozitif Oranı} = \frac{DP}{DP+YN} \quad (\text{Eşitlik 6})$$

$$\text{Yanlış Pozitif Oranı} = \frac{YP}{YP+DN} \quad (\text{Eşitlik 7})$$

ROC (Receiver Operating Characteristic – Alıcı İşlem Karakteristiği) eğrisi, bir sınıflandırma modelinin performansını pozitif ve negatif sınıflar arasında **duyarlılık (True Positive Rate)** ve **yanlış pozitiflik oranı (False Positive Rate)** üzerinden görselleştirerek değerlendiren bir analiz yöntemidir. ROC eğrisinde yatay eksen **Yanlış Pozitiflik Oranı (1 - Özgüllük)**, dikey eksen ise **Duyarlılık (True Positive Rate)** olarak tanımlanır.

Modelin farklı eşik (threshold) değerlerinde verdiği tahmin sonuçlarına göre, her bir nokta modelin duyarlılık ve özgüllük düzeyine karşılık gelen performansını temsil eder. Düşük eşik değerlerinde model daha fazla pozitif sınıf tahmini yapar; bu durum duyarlılığı artırabilirken yanlış pozitif oranını da yükseltebilir. Tersine, yüksek eşik değerlerinde yanlış pozitif oranı azalırken, duyarlılık düşebilir. Bu değişkenliği değerlendirmek adına ROC eğrisi, modelin tüm eşik değerleri üzerinden genel performansını özetler (Şekil 13).



Şekil 13. ROC eğrisi

Bu eğri altında kalan alan, **AUC (Area Under the Curve – Eğri Altındaki Alan)** olarak ifade edilir ve modelin sınıflar arasında ayırım yapabilme kabiliyetini ölçer.

AUC değeri, hem sınıf dengesizliği durumlarında hem de farklı modellerin karşılaştırılmasında oldukça faydalı bir karşılaştırma metriğidir. Bu nedenle, ROC-AUC analizi, biyomedikal sınıflandırmalardan görüntü işleme uygulamalarına kadar geniş bir yelpazede kullanılmaktadır (86, 87).

Bu performans metrikleri — duyarlılık, kesinlik, doğruluk, F1 skoru ve AUC — makine öğrenimi modellerinin sağlık hizmeti talebini öngörmedeki başarılarını çok boyutlu bir şekilde değerlendirmek için kullanılmaktadır. Her bir metrik, modelin farklı bir yönünü öne çıkarmakta; kimi modeller belirli türdeki hataları minimize etmeye odaklanırken, kimileri genel dengeyi korumaktadır. Bu nedenle, sadece tek bir metrikle değerlendirme yapmak yerine, bu metriklerin birlikte analiz edilmesi model güvenilirliğini artırmakta ve sağlık sistemleri için daha anlamlı karar destek çözümleri sunmaktadır (88).

Modelin çıktılarının açıklanabilirliğini artırmak ve modelin hangi bölgeleri daha önemli gördüğünü analiz etmek amacıyla Saliency Haritaları çıkarılmıştır. Bu haritalar, modelin hangi piksel gruplarına odaklandığını görselleştirerek, sınıflandırma sürecinde hangi bölgelerin belirleyici olduğunu anlamamıza yardımcı olmuştur. Özellikle, LICNN modelinin, lateral inhibisyon mekanizmasını kullanarak görüntülerdeki önemli bölgeleri daha başarılı bir şekilde belirlediği gözlemlenmiştir.

Bu çalışma, oftalmolojik görüntü sınıflandırma süreçlerinde transfer learning tabanlı modeller ve LICNN yaklaşımı kullanılarak derinlemesine bir karşılaştırma sunmaktadır. Kullanılan veri ön işleme teknikleri, modelin doğruluk ve genelleme yeteneğini artırırken, farklı CNN modellerinin performansları detaylı bir şekilde analiz edilmiştir. Özellikle LICNN modelinin, lateral inhibisyon mekanizmasını kullanarak daha belirgin kenarlar oluşturduğu ve düşük kontrastlı alanları daha etkili bir şekilde analiz ettiği görülmüştür. Bu sonuçlar, retinal OCT görüntülerinin analizi için yapay zeka tabanlı modellerin gelecekte nasıl geliştirilebileceğine dair önemli bulgular sunmaktadır.

Lateral inhibisyon (yanal baskılama), biyolojik görsel sistemlerde sinirsel ağlar arasında karşılıklı etkileşimi ifade eden önemli bir mekanizmadır. İlk olarak 19. yüzyılda Ernst Mach (89) tarafından Mach Band fenomeni ile tanımlanan bu mekanizma, görsel uyarıların algısında kontrast artırımı, kenar belirginleştirme ve arka plan-gürültü ayrıştırma görevlerinde temel rol oynamaktadır. Özellikle retina düzeyinde, bir nöronun uyarılması, komşu nöronların aktivasyonunu baskılayarak daha keskin bir duyuusal deneyim oluşturur.

Bu prensip, son yıllarda derin öğrenme alanında dikkat (attention) modellemelerinde kullanılmaya başlanmış ve görsel bilgi işleme sistemlerine entegre edilmiştir. Chunshui Cao ve ark. tarafından önerilen Lateral Inhibition Convolutional Neural Network (LICNN) modeli, bu biyolojik mekanizmayı yapay sinir ağları içinde hesaplamalı olarak taklit etmeyi amaçlamıştır. Bu çalışmada, söz konusu modele dayalı bir dikkat mekanizması geliştirilmiş ve evrimsel sinir ağı (CNN) sınıflandırıcısı içerisine entegre edilmiştir.

CNN mimarisinde her evrişim katmanını takiben ReLU (Rectified Linear Unit) aktivasyon fonksiyonu uygulanarak yalnızca pozitif aktivasyonlar korunmaktadır. Bu aktivasyon haritaları, genellikle giriş görüntüsündeki farklı görsel özelliklerin mekânsal olarak kodlanmış temsilleridir. Ancak, bu katmanlarda elde edilen tüm aktivasyonlar model için eşit derecede anlamlı değildir. Bu nedenle, özellikle dikkat bölgelerini öne çıkarmak ve

anlamsız/önemsiz nöral aktivasyonları bastırmak adına biyolojik temelli bir **lateral inhibisyon işlemi** önerilmiştir.

Model, temel olarak aşağıdaki iki adımı içermektedir:

Her bir ReLU katmanı için, kanal eksenini boyunca maksimum aktivasyonlar hesaplanarak, her mekânsal konumda yalnızca en güçlü cevabı veren nöronun çıktısı korunur. Bu işlem sonucunda elde edilen harita literatürde **Max-C Map** olarak adlandırılır. Bu işlem, $H \times W \times C$ boyutundaki aktivasyon haritasını $H \times W$ boyutuna indirir:

$$x_{ij} = \max_c A_{ijc} \quad (\text{Eşitlik 8})$$

Burada x_{ij} , (i, j) koordinatındaki maksimum kanal cevabını; A_{ijc} ise orijinal aktivasyon haritasındaki değerleri ifade eder.

Max-C haritasına, lateral inhibisyon etkisini taklit eden bir diferansiyel filtre uygulanır. Bu amaçla klasik **Mexican Hat** filtresi kullanılmıştır:

$$K = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix} \quad (\text{Eşitlik 9})$$

Bu çekirdek, merkez pikselin komşulara göre ne kadar farklılık gösterdiğini çıkarımsal olarak modellemektedir. Filtrenin uygulanması, TensorFlow içerisinde `depthwise_conv2d` fonksiyonu aracılığıyla her kanal için ayrı ayrı gerçekleştirilmiştir. Aşağıdaki ifade, inhibisyon işlemi sonrası güncellenmiş aktivasyon değerini vermektedir:

$$y_{ij} = \max(x_{ij} - a \cdot LI_{ij}, b) \quad (\text{Eşitlik 10})$$

Burada:

- $a \in [0,1]$: diferansiyel inhibisyon katsayısıdır; inhibisyonun şiddetini belirler.
- $b \in [0,1]$: minimum aktivasyon sınırıdır.
- LI_{ij} : Mexican Hat ile elde edilen inhibisyon etkisidir.
- y_{ij} : inhibisyon sonrası güncellenmiş değerlerdir.

Inhibisyon haritası LI_{ij} , normalize edilerek önişleme sürecine entegre edilmiştir.

Böylece, yalnızca anlamlı sinyallerin öğrenme sürecine katkı sağlaması amaçlanmıştır.

Yapay sinir ağlarında, özellikle görsel sınıflandırma gibi yüksek boyutlu veri üzerinde çalışan modellerde, bilgi açısından zengin bölgelerin öne çıkarılması ve ilgisiz sinyallerin bastırılması, modelin başarımı açısından kritik bir öneme sahiptir. Bu bağlamda, **lateral inhibisyon (yanal baskılama)** mekanizması, biyolojik görsel sistemlerden ilham alan etkili bir bilgi ön işleme stratejisi olarak karşımıza çıkmaktadır. Görsel kortekste komşu nöronlar arasında gerçekleşen inhibitör etkileşimler sayesinde, merkezi uyarana yanıt veren nöronun aktivitesi korunurken, çevresindeki nöronların aktivitesi bastırılır. Bu mekanizma, görsel kontrastı artırır, kenar tespiti yapar ve dikkat mekanizmalarına katkı sağlar (90, 91).

Bu çalışmada, lateral inhibisyon mekanizması, derin konvolüsyonel sinir ağına (CNN) `lateral_inhibition()` adlı bir fonksiyon ile entegre edilmiştir. Bu fonksiyon, her bir özellik haritası üzerinde uzamsal kontrastı artırarak, semantik olarak anlamlı bölgelerin daha belirgin hale gelmesini sağlar. İşlem, **Mexican Hat** yapısındaki sabit bir konvolüsyon çekirdeğinin uygulanmasıyla başlar. Bu 3×3 matris, merkez pikseli pozitif ağırlıklarla öne çıkarırken çevresindeki komşuları negatif ağırlıklarla baskılar:

Bu çekirdek (Eşitlik 9) `depthwise_conv2d` fonksiyonu ile tüm kanallar boyunca ayrı ayrı uygulanır. Ardından, aktivasyon haritasındaki inhibisyon etkisi `tf.nn.l2_normalize()` ile normalize edilerek denge sağlanır. Elde edilen inhibisyon haritası, orijinal maksimum aktivasyon haritasından çıkartılır ve `tf.maximum()` fonksiyonu ile minimum sınır değeri korunur.

Bu noktada devreye giren iki hiperparametre, $a=0.1$ ve $b=0.9$, lateral inhibisyonun gücünü ve sınırını kontrol etmek amacıyla belirlenmiştir. a katsayısı, inhibisyon etkisinin şiddetini tanımlar. Bu değerin **0.1** gibi düşük bir seviyede tutulması, yalnızca önemsiz düzeydeki sinyallerin bastırılmasını, önemli sinyallerin ise korunmasını sağlamaktadır. Aksi takdirde, agresif baskılama ile bilgi kaybı riski ortaya çıkabilir. Diğer yandan, b değeri çıkış haritasının taban seviyesini belirler. Bu değer, **0.9** olarak belirlenmiştir ki bu da yalnızca yeterince zayıf olan sinyallerin baskılanmasına izin verirken, bilgi taşıyan sinyallerin bastırılmasını engeller (58, 59, 61). Böylece model, hem yüksek

aktivasyonlu bölgelerde anlamlı yapıları korur hem de gürültü içeren alanlardan etkilenmeden öğrenme gerçekleştirebilir.

Bu biyolojik ilhamlı mekanizma, görsel işleme sistemlerinde **kenar tespiti, bölge kontrastı ve dikkat odaklama** gibi işlemleri yapay sinir ağlarına entegre etme açısından oldukça değerlidir. Özellikle **sınıf dengesizliği** barındıran medikal görüntüleme veri setlerinde, sınıflar arası ayrımı güçlendirmekte ve sınıflandırma performansını artırmaktadır (92).

Bu işlem yalnızca bir katmana değil, önceden eğitilmiş DenseNet121, InceptionV3, ResNet50 ve Xception mimarilerinin tüm **ReLU aktivasyon katmanlarına** uygulanmıştır. Her katmandan elde edilen lateral inhibe edilmiş aktivasyon haritaları daha sonra giriş görüntüsü boyutuna ölçeklendirilmiş ve tüm katmanlar boyunca toplanarak **saliency map (dikkat haritası)** oluşturulmuştur:

1. Tüm katmanlardan gelen aktivasyonlar birleştirilmiştir.
2. Aktivasyonlar giriş görüntüsü boyutuna yeniden ölçeklendirilmiştir.
3. Katmanlar arası tüm aktivasyonlar toplanarak tek bir dikkat haritası elde edilmiştir.
4. Harita L_2 normu ile normalize edilmiştir.

Bu işlem ile modelin "nerelere dikkat ettiği" görsel olarak da gözlemlenebilmiş ve modelin karar verme süreçleri daha yorumlanabilir hale getirilmiştir.

Bu yapay dikkat modeli, klasik CNN sınıflayıcı mimarisine doğrudan entegre edilerek aşağıdaki katkıları sağlamıştır:

- **Anlamsız aktivasyonların bastırılması:** Gürültüden kaynaklanan zayıf aktivasyonlar inhibe edilmiştir.
- **Özelliklerin kontrastı artırılmıştır:** Görsel öğelerin sınıf ayrımı açısından daha belirgin hale gelmesi sağlanmıştır.
- **Dikkat haritası üzerinden yorumlanabilirlik sağlanmıştır:** Modelin karar verirken hangi bölgelere odaklandığı gözlemlenebilmiştir.
- **Sınıflandırma başarımı artırılmıştır:** Özellikle benzer görsellere sahip sınıflar arasındaki farkları daha net modelleyerek doğruluk oranlarında iyileşme sağlanmıştır.

Bu mekanizma, özellikle tıbbi görüntü sınıflandırma gibi detayların kritik önemde olduğu görevlerde etkin bir dikkat mekanizması olarak kullanılabilir.



4. BULGULAR

Bu çalışmada, transfer öğrenme tabanlı derin öğrenme modelleri kullanılarak Optik Koherens Tomografi (OCT) görüntüleri üzerinde retinal hastalıkların sınıflandırılması gerçekleştirilmiştir. Deneysel aşamada, yaygın olarak kullanılan dört farklı evrimsel sinir ağı mimarisi olan DenseNet121, InceptionV3, ResNet50 ve Xception, önceden eğitilmiş ağlar (pre-trained models) olarak transfer öğrenme yaklaşımıyla eğitilmiş ve her bir modelin performansı doğruluk, duyarlılık, kesinlik ve F1 skoru gibi temel sınıflandırma metrikleriyle değerlendirilmiştir. Ayrıca, her model için karışıklık matrisi ve ROC eğrisi altındaki alan (AUC-ROC) değerleri analiz edilerek sınıflandırma başarımı detaylı biçimde karşılaştırılmıştır.

Bu modeller üzerinde daha sonra biyolojik sinir sisteminden esinlenerek geliştirilen lateral inhibisyon mekanizması uygulanmış ve her bir mimarinin, bu dikkat temelli düzenleme sonrası elde ettiği performans metrikleri tekrar hesaplanmıştır. Böylece, klasik transfer öğrenme yaklaşımları ile lateral inhibisyon entegre edilmiş modeller arasında istatistiksel ve yapısal farklılıklar karşılaştırmalı olarak incelenmiştir. Lateral inhibisyonun uygulanması ile görsel dikkat alanlarının daha belirgin hale getirilmesi, nöronal gürültünün bastırılması ve sınıflar arası ayırımın güçlendirilmesi sayesinde modellerin genel başarımında önemli gelişmeler gözlemlenmiştir. Aşağıda sunulan tablolar ve görseller, lateral inhibisyon uygulanmadan ve uygulandıktan sonraki model çıktılarının detaylı karşılaştırmasını içermektedir.

4.1. DenseNet121

DenseNet121 modeli üzerinde lateral inhibisyon uygulanmaksızın yapılan sınıflandırma sonucunda genel doğruluk (accuracy) değeri %93 olarak elde edilmiştir. Dört temel sınıf (CNV, DME, DRUSEN, NORMAL) için hesaplanan kesinlik, duyarlılık ve F1-skoru değerleri, modelin sınıflar arası ayırt edici gücünü ortaya koymaktadır (Tablo 4).

Tablo 4. DenseNet121 modeli ile test veri kümesinden elde edilen sınıflandırma performans metrikleri (Kesinlik, Duyarlılık, F1-Skoru)

Sınıf / Ortalama Türü	Kesinlik	Duyarlılık	F1-Skoru	Destek
CNV	1	0.88	0.93	7124
DME	0.79	0.98	0.87	2180
DRUSEN	0.79	0.89	0.84	1654
NORMAL	0.96	0.98	0.97	4990
Doğruluk (Accuracy)	–	–	0.93	15948
Makro Ortalama	0.88	0.93	0.90	15948
Ağırlıklı Ortalama	0.93	0.93	0.93	15948


En yüksek sınıflandırma başarımı, NORMAL sınıfında gözlemlenmiş olup, bu sınıf için kesinlik: 0.96, duyarlılık: 0.98 ve F1-skoru: 0.97 olarak hesaplanmıştır. Benzer şekilde, CNV (Koroidal Neovaskülerizasyon) sınıfında kesinlik değeri 1.00 gibi oldukça yüksek bir seviyeye ulaşmış, ancak duyarlılık değeri 0.88 ile nispeten daha düşük kalmıştır; bu durum, modelin CNV sınıfını tahmin ederken bazı örnekleri yanlış sınıflandırdığını göstermektedir.

DME ve DRUSEN sınıflarında ise modelin başarımı görece daha düşüktür. Özellikle DRUSEN sınıfı için kesinlik: 0.79, duyarlılık: 0.89 ve F1-skoru: 0.84 değerleri, bu sınıfa ait örneklerin model tarafından kısmen karıştırıldığını işaret etmektedir. DME sınıfı için ise yüksek bir duyarlılık değeri (0.98) elde edilmesine rağmen kesinlik değeri (0.79) düşüktür; bu durum, modelin DME sınıfı için daha fazla yanlış pozitif ürettiğini göstermektedir.

Makro ortalama (macro avg) değerleri, tüm sınıflar arasında eşit ağırlıklı ortalamaları gösterirken; ağırlıklı ortalama (weighted avg) değerleri, sınıf örnek sayısına göre ağırlıklandırılmış ortalamalardır. Her iki metrik de F1-score için 0.90 (macro) ve 0.93 (weighted) olarak hesaplanmıştır. Bu sonuçlar, veri setindeki dengesizliklere rağmen modelin genel olarak güçlü ve istikrarlı bir performans sergilediğini göstermektedir.

Bu sonuçlar, lateral inhibisyon mekanizması uygulanmadan elde edilen referans değerleri temsil etmektedir. Bir sonraki aşamada, aynı veri seti ve mimari üzerine lateral inhibisyon uygulandığında elde edilen performans metrikleriyle karşılaştırmalı analiz gerçekleştirilmiş ve biyolojik dikkat mekanizmasının sınıflandırma performansına etkisi detaylı olarak incelenmiştir.

Ayrıca, sınıflandırma performansına ilişkin daha ayrıntılı içgörü elde edebilmek adına her bir model için karışıklık matrisleri analiz edilmiştir. Şekil 14’de sunulan karışıklık matrisi, DenseNet121 modeli kullanılarak lateral inhibisyon uygulanmadan elde edilen sonuçları yansıtmaktadır. Bu matris, modelin her sınıfa ait doğru ve yanlış sınıflandırmalarını sayısal olarak ortaya koymakta ve modelin hangi sınıfları daha başarılı tahmin ettiğini görselleştirmektedir.



Şekil 14. DenseNet121 modeli için test veri kümesine ait karışıklık matrisi


Modelin en yüksek başarıyı gösterdiği sınıf, **NORMAL** sınıfı olup, bu sınıfa ait 4990 örneğin 4881 tanesi doğru sınıflandırılmıştır. Sadece 109 örnek diğer sınıflara yanlış tahsis edilmiştir (özellikle 91 örnek DME olarak sınıflandırılmıştır). Bu durum, modelin sağlıklı retinal görüntüleri oldukça başarılı biçimde tanıyabildiğini göstermektedir.

CNV (Koriyal Neovaskularizasyon) sınıfı için ise 7124 görüntünün 6266'sı doğru sınıflandırılmış, kalan örneklerin çoğunluğu DME (460 örnek) ve DRUSEN (365 örnek) sınıflarıyla karıştırılmıştır. Bu karışıklık, CNV ile DME arasında sınırlı yapısal benzerliklerin model açısından ayırt edici özellikler üzerinden tam olarak ayrıştırılamadığına işaret etmektedir.

DME sınıfı özelinde modelin oldukça başarılı bir sınıflandırma gerçekleştirdiği söylenebilir. 2180 örnekten 2128 tanesi doğru sınıflandırılmış olup, sadece 52 örnek diğer sınıflara yanlış etiketlenmiştir. Bu başarı, daha önce verilen yüksek duyarlılık (0.98) değerini de doğrular niteliktedir.

DRUSEN sınıfı için ise başarı görece düşüktür. Bu sınıfa ait 1654 görüntüden sadece 1478 tanesi doğru sınıflandırılmış, özellikle 141 örnek NORMAL, 24 örnek CNV, 11 örnek DME sınıfları ile karıştırılmıştır. DRUSEN ve NORMAL sınıfları arasındaki bu karışıklık, görüntülerdeki düşük kontrastlı benzerliklerden kaynaklanıyor olabilir. Bu durum, dikkat mekanizmasının daha sonra nasıl bu sorunu giderdiğini analiz etmeyi gerekli kılmaktadır.

Sonuç olarak bu karışıklık matrisi, lateral inhibisyon uygulanmayan temel modelin genel olarak yüksek doğruluk sağladığını, ancak bazı sınıflar arasında (özellikle DRUSEN–NORMAL ve CNV–DME) belirgin sınıflandırma hataları yaptığını göstermektedir. Bu bulgular, dikkat temelli modellerin bu tür karışıklıkları azaltmada etkili olup olmadığını değerlendirmek açısından referans niteliği taşımaktadır.



Şekil 15. DenseNet121 modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri

Modelin sınıflandırma performansını yalnızca kesinlik ve duyarlılık gibi temel metriklerle değil, aynı zamanda karar eşiklerine duyarlı bir şekilde değerlendirebilmek adına Alıcı Operatör Karakteristiği (Receiver Operating Characteristic – ROC) eğrileri hesaplanmış ve her sınıf için AUC (Area Under Curve) değerleri elde edilmiştir. Şekil 15'te yer alan ROC eğrisi, DenseNet121 modeli ile lateral inhibisyon uygulanmaksızın yapılan sınıflandırma sonucunda her bir sınıfın ayırt edilebilirliğini göstermektedir.

Her bir sınıf için ROC eğrileri oldukça başarılı sonuçlar vermiştir: CNV ve DRUSEN sınıflarında AUC değeri 0.99, DME ve NORMAL sınıflarında ise 1.00 olarak elde edilmiştir. Genel mikro ortalama AUC değeri ise 0.99 olup, modelin tüm sınıflarda yüksek doğrulukla çalıştığını göstermektedir.

Bu yüksek AUC değerleri, modelin tüm sınıflar için yüksek ayırt edici güce sahip olduğunu göstermektedir. AUC'nin 1'e yakın olması, modelin pozitif ve negatif örnekleri oldukça isabetli bir şekilde birbirinden ayırt edebildiğini, özellikle DME ve NORMAL sınıflarında ise bu ayrımın neredeyse kusursuz biçimde gerçekleştiğini ortaya koymaktadır.

ROC eğrisi üzerinden elde edilen bu sonuçlar, daha önce açıklanan doğruluk ve karışıklık matrisi analizlerini destekler niteliktedir. Özellikle DRUSEN sınıfı için sınıflandırma metriklerinde görece daha düşük sonuçlar gözlenmesine rağmen AUC değerinin 0.99 olarak ölçülmesi, modelin bu sınıfı tanımada genel olarak başarılı olduğunu ancak karar eşiği seçiminden kaynaklanan sınıflandırma hatalarının var olabileceğini düşündürmektedir.

Bu bağlamda, ROC eğrisi analizleri modelin denge noktaları açısından da oldukça güçlü performans sergilediğini ve karar eşiklerinin dikkatli optimize edilmesi durumunda daha da yüksek sınıflandırma doğruluğu elde edilebileceğini göstermektedir. İlerleyen aşamalarda lateral inhibisyon uygulandığında bu eğrilerin nasıl değiştiği karşılaştırmalı olarak incelenmiş ve dikkat mekanizmasının AUC üzerindeki etkisi değerlendirilmiştir.

4.2. DenseNet121 + LICNN


Lateral inhibisyon mekanizması entegre edilerek oluşturulan DenseNet121 + LICNN modeliyle elde edilen sınıflandırma performansına ait sonuçlar Tablo 5'te sunulmuştur. Model, genel doğruluk açısından %96 gibi oldukça yüksek bir başarı elde etmiştir. NORMAL ve CNV sınıflarında sırasıyla 0.98 ve 0.97 değerinde F1-skoru elde edilmiş olup, bu durum modelin bu iki sınıfı yüksek doğrulukla ayırt edebildiğini göstermektedir. DME sınıfında elde edilen kesinlik (0.95) ve duyarlılık (0.96) değerleri, modelin bu sınıfa ait örnekleri hem doğru hem de eksiksiz şekilde sınıflandırabildiğini ortaya koymaktadır. DRUSEN sınıfında ise F1-skoru değeri 0.88 olarak kaydedilmiş olup, önceki model yapısına kıyasla anlamlı bir iyileşme sağlandığı gözlemlenmiştir. Ayrıca, makro ortalama F1-score'un 0.95, ağırlıklı ortalamanın ise 0.96 olması; modelin tüm sınıflarda dengeli ve başarılı bir performans sergilediğini göstermektedir. Bu bulgular, lateral inhibisyon mekanizmasının DenseNet121 mimarisiyle birleştirildiğinde, sınıflandırma başarımı üzerinde anlamlı ve olumlu bir etki yarattığını ortaya koymaktadır (Tablo 5).

Tablo 5. DenseNet121 modeli (Laterlal inhibisyon entegreli) ile test veri kümesinden elde edilen sınıflandırma performans metrikleri (Kesinlik, Duyarlılık, F1-Skoru)

Sınıf / Ortalama Türü	Kesinlik	Duyarlılık	F1-Skoru	Destek
CNV	0.99	0.96	0.97	7124
DME	0.95	0.96	0.96	2180
DRUSEN	0.85	0.91	0.88	1654
NORMAL	0.97	0.98	0.98	4990
Doğruluk (Accuracy)	–	–	0.96	15948
Makro Ortalama	0.94	0.95	0.95	15948
Ağırlıklı Ortalama	0.96	0.96	0.96	15948


Şekil 16’da sunulan karışıklık matrisi, DenseNet121 modeline lateral inhibisyon uygulandıktan sonra elde edilen tahmin performansını göstermektedir. CNV sınıfında model 6812 doğru sınıflama ile yüksek isabet sağlamıştır. DME ve NORMAL sınıflarında sırasıyla 2096 ve 4913 doğru tahmin ile güçlü bir genel performans sergilenmiştir.

DRUSEN sınıfı örneklerinin özellikle NORMAL ve CNV sınıflarıyla kısmen karıştığı gözlemlense de genel sınıflandırma doğruluğu oldukça yüksektir. Modelin sınıflar arası ayrımı başarılı şekilde gerçekleştirdiği görülmektedir.




Şekil 16. DenseNet121 (Lateral inhibisyon entegreli) modeli için test veri kümesine ait karışıklık matrisi

Şekil 17’de sunulan ROC eğrileri, modelin sınıf bazlı ayırt edicilik performansını ortaya koymaktadır. CNV, DME ve NORMAL sınıfları için AUC değeri 1.00, DRUSEN sınıfı için ise 0.99 olarak hesaplanmıştır. Bu sonuçlar, modelin pozitif ve negatif örnekleri neredeyse kusursuz biçimde ayırt edebildiğini göstermektedir. Eğrilerin sol üst köşeye yakın olması, yüksek duyarlılık ve düşük yanlış pozitif oranlarının bir arada sağlandığını göstermektedir.




Şekil 17. DenseNet121 modeli (Lateral inhibisyon entegreli) için test verisinde elde edilen ROC eğrileri ve AUC değerleri

Elde edilen sınıflandırma sonuçları, temel DenseNet121 mimarisi ile Lateral Inhibition (LICNN) entegrasyonu yapılan modelin karşılaştırmalı performansını ortaya koymaktadır (Şekil 18). Sınıf bazlı F1-skorları incelendiğinde, özellikle **DME** ve **DRUSEN** gibi verisetinde daha az temsil edilen sınıflarda LICNN modelinin dikkate değer iyileştirmeler sağladığı görülmektedir. Örneğin, DME sınıfında temel modelin F1-skoru 0.87 iken, LICNN modeli bu değeri 0.96'ya yükseltmiştir. Benzer şekilde, DRUSEN sınıfında da 0.84'ten 0.88'e bir artış gözlemlenmiştir. CNV ve NORMAL sınıflarında her iki model de yüksek performans sergilemekle birlikte, LICNN modeli bu güçlü performansı daha da ileriye taşımıştır. Genel başarıyı yansıtan makro ve ağırlıklı ortalama F1-skorlarında da LICNN modelinin sırasıyla **0.90 → 0.95** ve **0.93 → 0.96** düzeyinde bir gelişim sağladığı dikkati çekmektedir. Bu bulgular, lateral inhibisyon mekanizmasının, özellikle sınıf dengesizliği bulunan medikal görüntüleme verilerinde, özellik ayıklama sürecini güçlendirerek modelin ayırt edici gücünü artırdığını ortaya koymaktadır.



Şekil 18. DenseNet121 modeli (Lateral inhibisyon entegreli) DenseNet121 skor karşılaştırmaları



Şekil 19. Sınıflandırma modeline ait farklı konvolüsyonel katmanlardan elde edilen saliency map örnekleri

Şekil 19’da gösterilen saliency map’ler, DenseNet121 + LICNN modeline ait farklı konvolüsyonel katmanlardan rastgele seçilen aktivasyon haritalarını temsil etmektedir. Bu haritalar, modelin girdi görüntüleri üzerinde hangi bölgelere daha fazla dikkat ettiğini (yani karar sürecinde hangi alanları önemli bulduğunu) görselleştirmektedir.

Renk skalasında kırmızı alanlar yüksek aktivasyonları, mavi alanlar ise düşük aktivasyonları temsil etmektedir. Görüldüğü üzere bazı katmanlar daha detaylı yapıları öne çıkarırken, bazı katmanlar daha genel yapısal desenlere odaklanmaktadır. Bu çeşitlilik, modelin hem düşük seviyeli (kenar, doku) hem de yüksek seviyeli (anatomik yapı, lezyon) özellikleri yakalayabildiğini göstermektedir.

Bu görselleştirme, modelin karar verme sürecinin yorumlanabilirliğini artırmakta ve modelin "hangi bilgiye dayanarak sınıflandırma yaptığına" dair içgörü sağlamaktadır.

4.3. InceptionV3

InceptionV3 modeli ile gerçekleştirilen sınıflandırma sonuçları Tablo 6'da sunulmaktadır. Model, genel doğruluk açısından %93 düzeyinde başarılı bir performans sergilemiştir. NORMAL sınıfında elde edilen F1-score: 0.97 değeri, modelin sağlıklı retinal görüntüleri güvenilir şekilde tanımlayabildiğini göstermektedir. CNV sınıfında ise kesinlik: 0.99, duyarlılık: 0.89 ve F1-skor: 0.94 değerleri elde edilmiştir. DME sınıfı için yüksek duyarlılık (0.99) oranına karşın kesinlik (0.75) oranı, modelin bazı sınıflar arası karışıklıklar yaşadığını işaret etmektedir. DRUSEN sınıfında ise kesinlik ve duyarlılık değerleri %87 olup model bu sınıfı genel olarak dengeli bir şekilde tahmin etmiştir. Makro ortalama F1-skorum 0.91 olması, modelin tüm sınıflar genelinde güçlü ve istikrarlı bir performans ortaya koyduğunu göstermektedir.

Tablo 6. InceptionV3 modeli ile test veri kümesinden elde edilen sınıflandırma performans metrikleri (Kesinlik, Duyarlılık, F1-Skoru)


Sınıf / Ortalama Türü	Kesinlik	Duyarlılık	F1-Skoru	Destek
CNV	0.99	0.89	0.94	7124
DME	0.75	0.99	0.85	2180
DRUSEN	0.87	0.87	0.87	1654
NORMAL	0.96	0.97	0.97	4990
Doğruluk (Accuracy)	–	–	0.93	15948
Makro Ortalama	0.89	0.93	0.91	15948
Ağırlıklı Ortalama	0.94	0.93	0.93	15948

InceptionV3 modeline ait karışıklık matrisi Şekil 20'de sunulmaktadır. CNV sınıfında, 7124 örnekten 6359'unun doğru sınıflandırılması, modelin bu sınıfta yüksek başarı sağladığını göstermektedir. DME sınıfında 2151, DRUSEN sınıfında ise 1431 örnek doğru şekilde sınıflandırılmıştır. Özellikle NORMAL sınıfına ait 4821 doğru tahmin, modelin bu sınıfta güçlü ve kararlı bir performans ortaya koyduğunu göstermektedir.

DRUSEN sınıfı örneklerinin bir kısmının NORMAL sınıfına (137 örnek) yanlış sınıflandırılması, bu iki sınıf arasında görsel benzerliklerden kaynaklı karışıklıkların devam

ettiğini düşündürmektedir. Benzer şekilde, CNV ve DME sınıfları arasında gözlemlenen karışıklıklar (örneğin 555 örneğin DME olarak sınıflandırılması), sınıflar arası ayırımın daha da iyileştirilebileceği alanları işaret etmektedir.


Genel olarak model, sınıflar arasında yüksek doğruluk oranları elde etmiş; ancak bazı sınıflar arasında gözlemlenen örtüşmeler, ileri model iyileştirmeleri için potansiyel gelişim noktaları sunmaktadır.



Şekil 20. InceptionV3 modeli için test veri kümesine ait karışıklık matrisi

Şekil 21’de sunulan ROC eğrileri, InceptionV3 modelinin sınıf bazlı ayırt edicilik performansını ortaya koymaktadır. Her bir sınıf için AUC (Area Under Curve) değerleri oldukça yüksek seviyelerdedir: CNV ve DRUSEN sınıfları için 0.99, DME ve NORMAL sınıfları için ise 1.00 olarak hesaplanmıştır. Bu sonuçlar, modelin karar eşiklerinden

bağımsız olarak her sınıfta yüksek düzeyde duyarlılık ve özgüllük dengesine ulaştığını göstermektedir. Özellikle DME ve NORMAL sınıflarında gözlemlenen kusursuz AUC değerleri, modelin bu sınıflara ait örnekleri güvenilir şekilde ayırt edebildiğini göstermektedir. Genel olarak model, tüm sınıflarda güçlü ayırt edicilik performansı sergilemiş ve yüksek sınıflandırma başarımı ile tutarlı bir yapı ortaya koymuştur.



Şekil 21. InceptionV3 modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri

4.4. InceptionV3 + LICNN


InceptionV3 modeline lateral inhibisyon entegre edildikten sonra elde edilen sınıflandırma sonuçları Tablo 7’de sunulmuştur. Model genel doğruluk açısından %95 seviyesine ulaşmış ve tüm sınıflarda güçlü bir performans sergilemiştir. NORMAL ve CNV sınıflarında sırasıyla F1-score: 0.97 ve 0.96, DME sınıfında ise 0.94 olarak kaydedilmiştir.

Tablo 7. InceptionV3 modeli (Lateral inhibisyon entegreli) ile test veri kümesinden elde edilen sınıflandırma performans metrikleri (Kesinlik, Duyarlılık, F1-Skoru)

Sınıf / Ortalama Türü	Kesinlik	Duyarlılık	F1-Skoru	Destek
CNV	0.99	0.94	0.96	7124
DME	0.91	0.97	0.94	2180
DRUSEN	0.82	0.93	0.87	1654
NORMAL	0.97	0.97	0.97	4990
Doğruluk (Accuracy)			0.95	15948
Makro Ortalama	0.92	0.95	0.94	15948
Ağırlıklı Ortalama	0.96	0.95	0.95	15948

DRUSEN sınıfı için elde edilen F1-score: 0.87, diğer sınıflara göre daha düşük olmakla birlikte, önceki duruma göre gelişme göstermiştir. Modelin sınıflar arası dengesini yansıtan makro ve ağırlıklı ortalama F1-score değerleri 0.94 ve 0.95 olarak gerçekleşmiştir.


Bu sonuçlar, InceptionV3 modelinin lateral inhibisyon ile birlikte tüm sınıflarda yüksek tutarlılık ve doğruluk düzeyi sunduğunu göstermektedir.



Şekil 22. InceptionV3 (Lateral inhibisyon entegreli) modeli için test veri kümesine ait karışıklık matrisi

Şekil 22’de sunulan karışıklık matrisi, InceptionV3 modeline lateral inhibisyon mekanizması entegre edildikten sonra elde edilen test verisine ait sınıf bazlı tahmin performansını göstermektedir. CNV sınıfında model 6693 örneği doğru sınıflandırarak yüksek bir doğruluk oranı sergilemiştir. DME sınıfında ise 2116 doğru tahmin ile modelin bu sınıfı etkili bir şekilde ayırt edebildiği görülmektedir. NORMAL sınıfında da 4862 doğru sınıflama ile yüksek performans elde edilmiştir.


DRUSEN sınıfında model 1532 örneği doğru sınıflandırmış, ancak bu sınıfa ait bazı örnekler CNV (63) ve NORMAL (54) sınıfları ile karıştırılmıştır. Bu durum, modelin DRUSEN sınıfını diğer sınıflardan ayırmada bir miktar zorlandığını göstermektedir. Buna rağmen genel olarak model, dört sınıf arasında güçlü bir ayırım yeteneği ortaya koymuş ve sınıflar arası ayrımı büyük ölçüde başarılı şekilde gerçekleştirmiştir.



Şekil 23. InceptionV3 (Lateral inhibisyon entegreli) modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri

Şekil 23'te yer alan ROC eğrileri, modelin sınıf bazlı ayırt etme başarısını göstermektedir. CNV, DME ve NORMAL sınıfları için AUC değeri 1.00, DRUSEN sınıfı için ise 0.99 olarak hesaplanmıştır. Bu sonuçlar, modelin yüksek doğruluk ve düşük yanlış pozitif oranı ile tüm sınıfları başarılı bir şekilde ayırt edebildiğini göstermektedir.

Eğrilerin ideal çizgiye yakın seyretmesi, modelin sınıflar arası ayrımı oldukça güvenilir şekilde gerçekleştirdiğini doğrulamaktadır.




Şekil 24. Eğitim süreci boyunca epoch bazlı doğruluk ve kayıp değerlerinin değişimi

Şekil 24’te, önerilen modelin eğitim süreci boyunca elde edilen eğitim ve doğrulama doğruluğu (sol) ile kayıp değerleri (sağ) epoch bazında gösterilmektedir.

Sol grafikte görüldüğü üzere, eğitim doğruluğu genel olarak yüksek seyretmiş (%90 üzeri), ancak epoch’lar arasında dalgalanma göstermiştir. Doğrulama doğruluğunda da benzer şekilde yüksek değerler gözlemlenmiştir, fakat bazı epoch’larda ani düşüşler yaşanmıştır (örneğin epoch 10 ve 17 civarı). Bu dalgalanmalar, doğrulama verisindeki örneklerin dağılımından veya küçük veri setlerinde görülebilecek varyanstan kaynaklanabilir.

Sağdaki kayıp grafiğinde, eğitim kaybının istikrarlı bir şekilde azaldığı, ancak doğrulama kaybının zaman zaman arttığı ve yüksek sıçramalar gösterdiği dikkat çekmektedir. Bu durum, modelin bazı epoch’larda overfitting (aşırı öğrenme) eğiliminde olabileceğini göstermektedir. Özellikle epoch 17 civarındaki doğrulama kaybı, bu durumu açıkça işaret etmektedir.

Genel olarak modelin doğruluk düzeyi yüksek olsa da, bazı epoch’larda doğrulama performansındaki dengesizlikler, erken durdurma (early stopping) veya düzenleme (regularization) gibi yöntemlerle daha dengeli bir hale getirilebilir.



Şekil 25. InceptionV3 ve InceptionV3 + Lateral CNN modellerinin sınıf bazlı F1-skor ve doğruluk karşılaştırması

Şekil 25, InceptionV3 modeline lateral inhibisyon mekanizmasının entegre edilmesinin sınıflandırma performansına olan etkisini göstermektedir. F1-skor ve genel doğruluk açısından yapılan karşılaştırma, özellikle **DME** ve **CNV** sınıflarında anlamlı bir performans artışına işaret etmektedir. DME sınıfında F1-skoru 0.85'ten 0.94'e yükselmiş, genel doğruluk ise %93'ten %95'e çıkmıştır. Bu artışlar, lateral inhibisyon mekanizmasının modelin sınıflar arası ayrımı daha etkin bir şekilde öğrenmesini sağladığını göstermektedir. **DRUSEN** ve **NORMAL** sınıflarında da benzer şekilde yüksek skorlar korunmuş, böylece modelin genel dengesini ve doğrulama güvenilirliğini koruduğu gözlemlenmiştir. Bu bulgular, lateral inhibisyonun yalnızca bazı sınıflar üzerinde değil, modelin genel başarımı üzerinde de olumlu etkiler sağladığını göstermektedir.

4.5 ResNet50

ResNet50 modeline ait sınıflandırma sonuçları Tablo 8'de sunulmaktadır. Modelin genel doğruluğu %90 olup, özellikle **NORMAL** sınıfında elde edilen F1-score: 0.97, modelin bu sınıfı oldukça başarılı bir şekilde ayırt edebildiğini göstermektedir. **CNV** sınıfında kesinlik: 1.00, duyarlılık: 0.83 ve F1-skor: 0.90 değerleri elde edilmiştir; bu da

modelin CNV'yi seçici şekilde tahmin ettiğini ancak bazı örnekleri atladığını göstermektedir.

DME sınıfı için duyarlılık değeri 0.98 gibi yüksek bir seviyede gerçekleşmişken, kesinlik oranı 0.70 seviyesindedir; bu durum, modelin DME sınıfına ait olmayan örnekleri de zaman zaman bu sınıfa dahil ettiğini göstermektedir. DRUSEN sınıfında ise F1-skor: 0.84, dengeli ancak orta düzeyde bir performansı işaret etmektedir.

Makro ortalama F1-skorun 0.88 ve ağırlıklı ortalamanın 0.91 olması, modelin sınıflar arası performans dengesini koruyabildiğini göstermektedir.


Tablo 8. ResNet50 modeli ile test veri kümesinden elde edilen sınıflandırma performans metrikleri (Kesinlik, Duyarlılık, F1-Skoru)

Sınıf / Ortalama Türü	Kesinlik	Duyarlılık	F1-Skoru	Destek
CNV	1	0.83	0.9	7124
DME	0.7	0.98	0.82	2180
DRUSEN	0.78	0.9	0.84	1654
NORMAL	0.96	0.98	0.97	4990
Doğruluk (Accuracy)	–	–	0.9	15948
Makro Ortalama	0.86	0.92	0.88	15948
Ağırlıklı Ortalama	0.92	0.9	0.91	15948

Şekil 26'da sunulan karışıklık matrisi, ResNet50 modelinin sınıflandırma doğruluğunu sınıf bazında göstermektedir. CNV sınıfında model, 7124 örnekten 5902'sini doğru sınıflandırmış, ancak 801 örneği DME ve 395 örneği DRUSEN olarak tahmin etmiştir. DME sınıfında doğru sınıflama sayısı 2136, DRUSEN sınıfında ise 1495 olarak kaydedilmiştir.

NORMAL sınıfında ise model 4876 doğru tahmin yaparak güçlü bir performans göstermiştir. En dikkat çeken karışıklık, CNV sınıfındaki örneklerin özellikle DME ile karıştırılmasıdır. Benzer şekilde, DRUSEN sınıfına ait örneklerin bir kısmı NORMAL sınıfına yönlendirilmiştir.


Genel olarak model, sınıflar arasında başarılı bir ayırt edicilik sağlasa da bazı sınıflar arası örtüşmeler gözlemlenmiştir.



Şekil 26. ResNet50 modeli için test veri kümesine ait karışıklık matrisi

Şekil 27’de gösterilen ROC eğrileri, ResNet50 modelinin sınıf bazlı ayırt edicilik performansını yansıtmaktadır. AUC (Area Under Curve) değerleri CNV ve NORMAL sınıfları için 1.00, DME ve DRUSEN sınıfları için ise 0.99 olarak hesaplanmıştır.

Bu yüksek AUC değerleri, modelin tüm sınıflarda güçlü bir doğrulama performansına sahip olduğunu göstermektedir. ROC eğrileri genel olarak sınıflar arası ayırımın başarılı bir şekilde yapıldığını, yanlış pozitif oranlarının düşük seviyelerde tutulduğunu ortaya koymaktadır.



Şekil 27. ResNet50 modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri

4.6. ResNet50 + LICNN


Tablo 9. ResNet50 modeli (Lateral inhibisyon entegreli) ile test veri kümesinden elde edilen sınıflandırma performans metrikleri

Sınıf / Ortalama Türü	Kesinlik	Duyarlılık	F1-Skoru	Destek
CNV	0.99	0.89	0.94	7124
DME	0.9	0.97	0.93	2180
DRUSEN	0.71	0.93	0.8	1654
NORMAL	0.97	0.98	0.97	4990
Doğruluk (Accuracy)			0.93	15948
Makro Ortalama	0.89	0.94	0.91	15948
Ağırlıklı Ortalama	0.94	0.93	0.93	15948

ResNet50 modeline lateral inhibisyon entegre edildikten sonra modelin genel doğruluğu %93 olarak elde edilmiştir. NORMAL sınıfında F1-score: 0.97, CNV sınıfında ise 0.94 değeriyle model yüksek doğruluk sergilemiştir. DME sınıfı için kesinlik: 0.90 ve duyarlılık: 0.97 oranları, sınıfa ait örneklerin çoğunluğunun doğru şekilde sınıflandırıldığını göstermektedir.

DRUSEN sınıfı ise modelin en zayıf kaldığı sınıf olmuş; F1-skor: 0.80 ile diğer sınıflara kıyasla daha düşük performans göstermiştir. Bu duruma rağmen genel sınıflandırma başarımı yüksektir.


Makro ortalama F1-score: 0.91, ağırlıklı ortalama ise 0.93 olarak gerçekleşmiştir. Bu veriler, modelin sınıflar arası dengesini genel anlamda koruduğunu göstermektedir.



Şekil 28. ResNet50 (Lateral inhibisyon entegreli) modeli için test veri kümesine ait karışıklık matrisi

Şekil 28’de sunulan karışıklık matrisi, ResNet50 modeline lateral inhibisyon eklendikten sonra elde edilen sınıflandırma performansını yansıtmaktadır. Model, CNV sınıfında 6326 doğru sınıflama, DME sınıfında 2106, NORMAL sınıfında ise 4909 doğru tahmin ile yüksek başarı sergilemiştir.

DRUSEN sınıfında doğru sınıflama sayısı 1531 olup, özellikle NORMAL sınıfı ile yaşanan karışıklık (103 örnek) dikkat çekmektedir. Bu karışıklığa rağmen genel doğruluk oranı yüksek seviyede korunmuştur.




Şekil 29. ResNet50 (Lateral inhibisyon entegreli) modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri

Şekil 29’da gösterilen ROC eğrileri, ResNet50 modeline lateral inhibisyon eklendikten sonra sınıf bazlı ayırt edicilik performansını ortaya koymaktadır. CNV, DME ve NORMAL sınıfları için AUC değeri 1.00 olup, modelin bu sınıfları yüksek doğrulukla

ayırt ettiğini göstermektedir. DRUSEN sınıfı için elde edilen AUC: 0.99, ayırt edicilik düzeyinin oldukça yüksek olduğunu ortaya koymaktadır.

Tüm eğrilerin ideal eğriye yakın seyretmesi, modelin genel olarak güçlü sınıflandırma yeteneğine sahip olduğunu ve yanlış pozitif oranlarını minimumda tuttuğunu göstermektedir.



Şekil 30. ResNet50 ve ResNet50 + Lateral CNN modellerinin F1-skor ve doğruluk karşılaştırması

Şekil 30'da, ResNet50 modeline lateral inhibisyon mekanizmasının entegre edilmesinin sınıflandırma performansına olan etkisi gösterilmektedir. CNV ve DME sınıflarında F1-skorlarında gözle görülür artışlar sağlanmış; CNV için skor 0.90'dan 0.94'e, DME için ise 0.82'den 0.93'e yükselmiştir. Bu durum, lateral inhibisyonun özellikle bu sınıfların ayırt edilmesinde modelin performansını anlamlı biçimde artırdığını göstermektedir. DRUSEN sınıfında ise temel modelin (0.84) daha iyi sonuç verdiği, ancak farkın görece az olduğu dikkat çekmektedir. NORMAL sınıfında her iki model de 0.97 ile yüksek bir başarı sergilemiştir. Genel doğruluk değerinde ise lateral inhibisyon içeren model %93 ile temel modelin %90'lık performansını aşmıştır. Bu sonuçlar, lateral inhibisyonun

ResNet50 mimarisine entegre edildiğinde genel sınıflandırma başarısını artırdığını ortaya koymaktadır.

4.7. Xception


Xception modeline ait sınıflandırma sonuçları Tablo 10’da sunulmaktadır. Model, genel doğruluk açısından %94 ile en yüksek başarıyı elde eden yapılar arasında yer almıştır. NORMAL sınıfında F1-skor: 0.97, CNV sınıfında ise F1-score: 0.95 değeriyle oldukça güçlü bir performans sergilenmiştir.

DME sınıfı için hem kesinlik (0.91) hem de duyarlılık (0.96) değerleri yüksektir; bu da modelin bu sınıfa ait örnekleri yüksek isabetle tahmin ettiğini göstermektedir. DRUSEN sınıfında ise F1-skor: 0.82, önceki modellere kıyasla görece daha düşük kalmış; bu durum sınıfın görsel benzerlik nedeniyle diğer sınıflarla daha sık karıştırıldığını düşündürmektedir.

Makro ortalama F1-skorun 0.92, ağırlıklı ortalamanın ise 0.94 olması, modelin genel anlamda sınıflar arasında dengeli ve güçlü bir performans ortaya koyduğunu göstermektedir.

Tablo 10. Xception modeli ile test veri kümesinden elde edilen sınıflandırma performans metrikleri

Sınıf / Ortalama Türü	Kesinlik	Duyarlılık	F1-Skoru	Destek
CNV	1	0.9	0.95	7124
DME	0.91	0.96	0.94	2180
DRUSEN	0.74	0.93	0.82	1654
NORMAL	0.96	0.99	0.97	4990
Doğruluk (Accuracy)	–	–	0.94	15948
Makro Ortalama	0.9	0.95	0.92	15948
Ağırlıklı Ortalama	0.95	0.94	0.94	15948




Şekil 31. Xception modeli için test veri kümesine ait karışıklık matrisi

Şekil 31’de sunulan karışıklık matrisi, Xception modelinin sınıf bazlı tahmin performansını göstermektedir. CNV sınıfında bulunan 7124 örneğin 6407’si doğru sınıflandırılmış olup, kalan örneklerin özellikle DRUSEN (514 örnek) ve DME (175 örnek) sınıfları ile karıştırıldığı görülmektedir. DME sınıfında yer alan örneklerin 2101’i doğru tahmin edilmiş, bu sınıfta modelin oldukça başarılı bir ayırt edicilik sergilediği gözlemlenmiştir.

DRUSEN sınıfında 1546 doğru sınıflama yapılmış; ancak 95 örneğin NORMAL sınıfına, 10 örneğin ise CNV sınıfına yanlış atandığı görülmektedir. NORMAL sınıfında ise 4923 örnek doğru olarak sınıflandırılmış ve model bu sınıfta en yüksek başarı oranlarından birini elde etmiştir. Genel olarak Xception modeli, dört sınıf arasında yüksek doğruluk oranları sağlamış; ancak CNV–DRUSEN ve DRUSEN–NORMAL sınıf çiftleri arasında

sınırlı düzeyde karışıklık gözlemlenmiştir. Bu durum, sınıflar arası görsel benzerliklerin model performansını kısmen etkileyebileceğini düşündürmektedir.



Şekil 32. Xception modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri

Şekil 32’de sunulan ROC eğrileri, Xception modelinin sınıf bazlı ayırt edicilik performansını ortaya koymaktadır. AUC (Area Under Curve) değerleri, **CNV ve NORMAL** sınıfları için **1.00**, **DME ve DRUSEN** sınıfları için ise **0.99** olarak hesaplanmıştır.

Bu sonuçlar, modelin tüm sınıflarda yüksek doğrulukla pozitif ve negatif örnekleri ayırt edebildiğini göstermektedir. Özellikle eğrilerin sol üst köşeye yakın seyretmesi, düşük yanlış pozitif oranı ile yüksek doğru pozitif oranının bir arada sağlandığını göstermektedir.

Genel olarak, ROC eğrileri modelin güçlü ayrıştırma kapasitesine sahip olduğunu ve sınıflandırma kararlarını güvenilir biçimde verdiğini göstermektedir.

4.8. Xception + LICNN


Xception modeline lateral inhibisyon entegre edildikten sonra elde edilen sınıflandırma sonuçları Tablo 11’de sunulmaktadır. Modelin genel doğruluğu %94 olarak gerçekleşmiştir. NORMAL (F1-score: 0.97) ve CNV (F1-score: 0.95) sınıflarında oldukça yüksek başarı sağlanmıştır. DME sınıfında da model, F1-score: 0.93 ile güçlü bir performans sergilemiştir.

Tablo 11. Xception modeli (Lateral inhibisyon entegreli) ile test veri kümesinden elde edilen sınıflandırma performans metrikleri

Sınıf / Ortalama Türü	Kesinlik	Duyarlılık	F1-Skoru	Destek
CNV	0.99	0.91	0.95	7124
DME	0.91	0.96	0.93	2180
DRUSEN	0.75	0.94	0.83	1654
NORMAL	0.97	0.98	0.97	4990
Doğruluk (Accuracy)			0.94	15948
Makro Ortalama	0.90	0.95	0.92	15948
Ağırlıklı Ortalama	0.95	0.94	0.94	15948

DRUSEN sınıfında ise F1-skor: 0.83 olarak kaydedilmiş, ancak duyarlılık değeri %94 ile oldukça yüksek çıkmıştır. Bu durum, modelin DRUSEN sınıfına ait örnekleri tespit etme konusunda başarılı olduğunu ancak bazı karışıklıkların kesinlik değerini düşürdüğünü göstermektedir.

Makro ortalama F1-skor: 0.92, ağırlıklı ortalama ise 0.94 olup, modelin genel başarımının hem dengeli hem de yüksek olduğunu ortaya koymaktadır.




Şekil 33. Xception (Lateral inhibisyon entegreli) modeli için test veri kümesine ait karışıklık matrisi

Şekil 33'te sunulan karışıklık matrisi, Xception modeline lateral inhibisyon mekanizması entegre edildikten sonra elde edilen sınıf bazlı tahmin performansını göstermektedir.

CNV sınıfında model 6488 örneği doğru sınıflandırmış; geri kalan örneklerin çoğunluğu DRUSEN (457 örnek) ve DME (153 örnek) ile karıştırılmıştır. DME sınıfında 2098 doğru sınıflama yapılmış, bu sınıfta 67 örnek NORMAL ile karışmıştır.

DRUSEN sınıfında model 1554 örneği doğru sınıflandırmış olup, özellikle NORMAL sınıfına ait 73 örnek ile karışıklık yaşanmıştır. NORMAL sınıfında ise 4875 örnek doğru tahmin edilmiş; model bu sınıfta da yüksek bir ayırt edicilik performansı göstermiştir. Özellikle DRUSEN–NORMAL sınıfları arasındaki 73 örneklilik karışıklık, bu


iki sınıf arasındaki görsel benzerliklerin model performansını etkileyebileceğini göstermektedir. Bununla birlikte, model genel anlamda tüm sınıflarda yüksek doğruluk düzeyini koruyarak başarılı bir sınıflandırma performansı sergilemiştir.



Şekil 34. Xception (Lateral inhibisyon entegreli) modeli için test verisinde elde edilen ROC eğrileri ve AUC değerleri


Şekil 34'te sunulan ROC eğrileri, Xception modeline lateral inhibisyon entegre edildikten sonra elde edilen sınıf bazlı ayırt edicilik performansını göstermektedir. CNV, DME ve NORMAL sınıfları için AUC değeri 1.00 olup, modelin bu sınıflarda kusursuza yakın bir ayırım gerçekleştirdiği görülmektedir. DRUSEN sınıfı için AUC değeri ise 0.99 olarak hesaplanmış ve bu da oldukça yüksek bir ayırt edicilik performansına işaret etmektedir.

ROC eğrilerinin tamamı ideal eğriye oldukça yakın seyretmekte olup, modelin genel doğruluk ve güvenilirlik düzeyini görsel olarak da desteklemektedir.




Şekil 35. Xception + Lateral Inhibisyon modeli için eğitim sürecine ait doğruluk ve kayıp eğrileri

Şekil 35’te, modelin eğitim süreci boyunca doğruluk (sol) ve kayıp (sağ) değerlerinin epoch bazlı değişimi gösterilmektedir. Eğitim ve doğrulama doğruluklarının yüksek seviyelerde seyrettiği ve birbirine yakın değerler gösterdiği gözlemlenmektedir; bu durum modelin iyi genelleme kapasitesine sahip olduğunu düşündürmektedir. Kayıp eğrilerinde özellikle eğitim verisi için belirli epoch’larda dalgalanmalar gözlemlense de, her iki eğrinin de genel olarak düşük seviyelerde kalması ve birbirine yakınsaması, modelin aşırı öğrenme (overfitting) eğiliminde olmadığını ortaya koymaktadır. Bu bulgular, modelin hem eğitim hem de doğrulama verisi üzerinde genel olarak başarılı bir öğrenme performansı sergilediğini göstermektedir.



Şekil 36. Xception ve Xception + Lateral CNN F1-skor ve doğruluk karşılaştırılması

Şekil 36’da Xception modeli ile referans olarak alınan diğer modelin sınıf bazlı F1-skor ve genel doğruluk (accuracy) performansları karşılaştırılmaktadır. CNV ve NORMAL sınıflarında her iki model de benzer ve yüksek başarı göstermiştir (F1-skoru: 0.95 ve 0.97). DME sınıfında Xception modeli hafif üstünlük sağlamış (0.94 vs. 0.93), DRUSEN sınıfında ise Diğer Modelin F1-skoru 0.83 ile Xception’a (0.82) kıyasla bir miktar daha yüksek olmuştur. Genel doğruluk açısından ise her iki model %94 değerine ulaşarak benzer bir genel başarı sergilemiştir. Bu bulgular, Xception mimarisinin sınıflar arası ayırmda rekabetçi bir performans sunduğunu ve özellikle DME sınıfında başarılı sonuçlar verdiğini göstermektedir.



Şekil 37. Modellere ve sınıflara göre F1 skoru ile genel doğruluk karşılaştırması

5. TARTIŞMA ve SONUÇ

Bu tez çalışmasında, Optik Koherens Tomografi görüntülerinin sınıflandırılması için farklı derin öğrenme modelleri kullanılmış ve bu modellere lateral inhibisyon (LI) mekanizması entegre edilerek performansları karşılaştırmalı olarak analiz edilmiştir. Literatürde sıklıkla kullanılan DenseNet121, InceptionV3, ResNet50 ve Xception gibi popüler konvolüsyonel sinir ağı mimarileri bu kapsamda değerlendirilmiş ve her biri için lateral inhibisyonun sınıflandırma performansına etkisi ayrıntılı olarak incelenmiştir. Deneysel bulgular, lateral inhibisyonun biyolojik olarak esinlenilmiş bir mekanizma olarak derin öğrenme modellerine entegre edilmesinin, özellikle sınıf ayırım gücünü artırma ve karışıklık oranlarını azaltma açısından önemli avantajlar sunduğunu ortaya koymuştur.

Bu çalışmada, görüntü sınıflandırma için yaygın olarak kullanılan dört derin öğrenme mimarisi olan DenseNet121, InceptionV3, ResNet50 ve Xception modellerinden yararlanılmıştır. Tüm bu modeller, transfer öğrenme yaklaşımı ile, ImageNet veri seti üzerinde önceden eğitilmiş (pretrained) ağırlıklar kullanılarak uygulanmıştır; bu sayede mimarilerin orijinal yapılarına ek bir modifikasyon yapılmamıştır. Söz konusu mimarilerde, katmanlar arası öznetelik çıkarımı için farklı boyut ve sayılarda konvolüsyonel filtreler (kernel) kullanılmaktadır: ResNet50 ve DenseNet121’de genellikle 1x1 ve 3x3 boyutlarında filtreler tercih edilirken, InceptionV3 modelinde farklı boyutlarda (1x1, 3x3, 5x5) çoklu filtreler aynı anda kullanılabilir. Xception ise klasik konvolüsyon yerine, derinlik-ayrıklaştırılmış (depthwise separable) konvolüsyon filtreleri ile öne çıkmaktadır. Tüm bu modellerde, uzamsal boyutu azaltmak ve öznetelik yoğunluğunu artırmak amacıyla çeşitli havuzlama (pooling) yöntemleri uygulanmaktadır. Ara katmanlarda genellikle Max Pooling veya Average Pooling kullanılırken, modelin son bölümünde ise tam bağlantılı katmanlardan önce Global Average Pooling yer almaktadır. Bu çalışmada, modellerin özgün mimarileri ve önceden eğitilmiş ağırlıkları aynen korunmuş, ek olarak özel bir filtre veya havuzlama katmanı eklenmemiştir.

Şekil 37’de, çalışmada kullanılan dört farklı derin öğrenme mimarisinin (DenseNet121, InceptionV3, ResNet50 ve Xception) hem klasik hem de lateral inhibisyon entegre edilmiş versiyonlarının, CNV, DME, DRUSEN ve NORMAL sınıflarındaki F1-score değerleri ile genel doğruluk (accuracy) değerleri birlikte sunulmuştur. Sonuçlar, lateral inhibisyon mekanizmasının özellikle DenseNet121 ve InceptionV3 modellerinde her dört sınıfta da belirgin bir performans artışı sağladığını göstermektedir. Örneğin, DenseNet121

modelinde CNV ve DME sınıflarında F1-score değerleri sırasıyla 0.93'ten 0.97'ye ve 0.87'den 0.96'ya yükselmiştir. Benzer şekilde, InceptionV3 ve ResNet50 mimarilerinde de lateral inhibisyonun entegrasyonu ile çoğu sınıfta F1-score değerlerinde anlamlı iyileşmeler gözlenmiştir. Xception modelinde ise lateral inhibisyon etkisi sınırlı kalmış ve F1-score değerlerinde büyük bir değişiklik görülmemiştir. Tüm modellerde genel doğruluk değeri, lateral inhibisyon uygulandığında artış göstermiş ve bu durum, modelin genel ayırt edici gücünü olumlu yönde etkilemiştir. Elde edilen bulgular, biyolojik esinli dikkat mekanizmalarının özellikle zorlu ve benzer sınıfların ayrımında geleneksel derin öğrenme yaklaşımlarına kıyasla önemli avantajlar sağlayabileceğini göstermektedir.

DenseNet121 modelinde lateral inhibisyonun entegrasyonu ile CNV sınıfında F1-skoru 0.93'ten 0.97'ye, DME sınıfında 0.87'den 0.96'ya yükselmiş, genel doğruluk ise %93'ten %96'ya ulaşmıştır. Bu durum, özellikle sınıflar arası görsel benzerliğin fazla olduğu ortamlarda lateral inhibisyonun etkili bir şekilde sınıf ayrımını güçlendirebildiğini göstermektedir. InceptionV3 modeline lateral inhibisyon eklendiğinde, DME sınıfında F1-skoru 0.85'ten 0.94'e yükselmiş, genel doğruluk oranı %95'e ulaşmıştır. Bu bulgular, Rozhyna ve ark. (68) ile Khudhur (69) gibi çalışmaların ortaya koyduğu transfer öğrenme temelli başarıların üzerine biyolojik esinlenmeli bir iyileştirme katmanı eklenebileceğini göstermektedir.

ResNet50 mimarisi üzerinde yapılan testlerde, lateral inhibisyonun özellikle CNV ve DME sınıflarında performansı belirgin şekilde artırdığı gözlemlenmiştir. CNV sınıfındaki F1-skorunun 0.90'dan 0.94'e, DME sınıfındaki skorun ise 0.82'den 0.93'e yükselmesi, lateral inhibisyonun kontrastı artırarak düşük benzerlik farklarını öne çıkarma işlevinin pratikteki önemini göstermektedir. Bu durum Zhuang ve ark. (79) lateral inhibisyonun görsel sınıflandırma performansı üzerindeki etkisine dair teorik temelleriyle örtüşmektedir.

Xception mimarisinde ise lateral inhibisyonun etkisi diğer modellere kıyasla daha sınırlı kalmıştır. DME sınıfındaki F1-skorunda hafif bir düşüş gözlenmiş, genel doğruluk oranında ise önemli bir değişiklik olmamıştır. Bu durum, lateral inhibisyonun her model mimarisinde aynı düzeyde etkili olmayabileceğini, modelin yapısal derinliği, filtre boyutları ve bağlantı stratejileri gibi parametrelerin, inhibisyon mekanizmasının etkisini doğrudan belirleyebileceğini düşündürmektedir. Bu bağlamda Marcinek (61) ve Denman (59) gibi araştırmalar, lateral inhibisyonun belirli yapısal mimarilerde daha başarılı sonuçlar doğurduğuna işaret etmektedir.

Yapılan literatür taraması sonucunda, InceptionV3 mimarisi içerisinde lateral inhibisyon mekanizmasının doğrudan entegre edildiği bir çalışmaya rastlanmamıştır. Bu çalışmada ise, InceptionV3 modeline entegre edilen lateral inhibisyon (LICNN) mekanizması sayesinde modelin genel doğruluğu %95'e ulaşmış, özellikle CNV ve DME sınıflarında belirgin F1-score artışları elde edilmiştir.

Karşılaştırmalı analizlerden elde edilen bulgular, genel olarak lateral inhibisyon mekanizmasının CNN tabanlı modellerde sınıf ayrımını güçlendirdiğini, modelin dikkat odağını hedef bölgelere yönlendirdiğini ve böylece karışıklık matrislerinde yanlış sınıflandırma oranlarını düşürdüğünü ortaya koymaktadır. Lateral inhibisyon, sinirbilimsel olarak görsel dikkat ve belirginlik tespiti gibi görevlerde bilinen bir avantaj sağlamakla kalmayıp, bu tezde gösterildiği üzere, tıbbi görüntüleme gibi yüksek doğruluk gerektiren bilişsel görevlerde de etkili olmaktadır. Cao ve ark. (58) ile Fu ve Li (80) tarafından geliştirilen çalışmalarda olduğu gibi, bu tezde de lateral inhibisyonun kenar algılama ve belirginlik tespiti gibi düşük seviye görsel görevlerde etkili olduğu görülmektedir. Ancak bu tez, söz konusu mekanizmanın sınıflandırma gibi yüksek seviye bilişsel görevlerde de etkili bir şekilde kullanılabileceğini somut deneysel bulgularla desteklemiştir.

Literatürdeki pek çok OCT sınıflandırma çalışması transfer öğrenme ve hiperparametre optimizasyonu teknikleri ile yüksek doğruluklar rapor etmiştir. Bu çalışmada önerilen yöntem, söz konusu tekniklere biyolojik bir katkı sunmakta, yani derin öğrenme sistemlerinin yalnızca matematiksel değil, aynı zamanda biyolojik olarak da daha gerçekçi modellere yaklaşmasını sağlamaktadır. Lateral inhibisyon, bu yönüyle yalnızca yapay sinir ağı mimarilerine bir katman olarak değil, aynı zamanda bilgi işleme süreçlerinin biyolojik doğruluğunu artıran bir yapı olarak da değerlendirilebilir. Elde edilen başarımların, literatürde bildirilen en yüksek performans değerlerine oldukça yakın ve bazı sınıflarda daha yüksek olması, önerilen yöntemin rekabetçi ve geliştirilebilir olduğunu ortaya koymaktadır.

Ayrıca, bu tezde kullanılan sınıflandırma görevlerinin büyük kısmı dengesiz veri sınıflarına sahip olmasına rağmen, lateral inhibisyon uygulaması ile azınlık sınıflarda dahi dikkate değer iyileşmeler elde edilmiştir. Bu durum, yöntemin veri dengesizliğine karşı da dayanıklı olduğunu göstermekte ve tıbbi görüntüleme gibi verinin sınırlı veya dengesiz olduğu alanlarda büyük bir avantaj sunmaktadır. Aynı zamanda saliency map analizleriyle gösterildiği üzere, modelin dikkati daha anlamlı ve hastalıkla ilişkili alanlara yönlendirdiği

gözlemlenmiş, bu da açıklanabilir yapay zeka (XAI) açısından önemli bir katkı olarak değerlendirilmektedir.

Sonuç olarak, geliştirilen lateral inhibisyon tabanlı CNN modelleri, OCT görüntülerinde retinal hastalıkların sınıflandırılması görevinde üstün performans sergilemiştir. Bu tez, yalnızca teknik bir başarı sağlamamış, aynı zamanda biyolojik bir prensibin derin öğrenme modellerine başarılı bir şekilde entegre edilebileceğini de göstermiştir. Elde edilen sonuçlar, lateral inhibisyon prensibinin, özellikle görsel dikkat, belirginlik tespiti ve sınıf ayrımı gibi konularda CNN modellerine entegre edilmesinin etkili bir strateji olabileceğini ortaya koymaktadır. Gelecekte yapılacak çalışmaların, modelin klinik ortamlarda genelleştirilebilirliğini değerlendirmek üzere daha geniş ve bağımsız veri setleri üzerinde doğrulamalar yapması önerilmektedir. Ayrıca, lateral inhibisyon mekanizmasının farklı derin öğrenme mimarilerine entegrasyonunun daha derinlemesine incelenmesi, yeni tasarımların önerilmesi ve bu yaklaşımın diğer tıbbi görüntüleme alanlarına uygulanabilirliğinin araştırılması, literatüre katkı sağlayabilecek önemli çalışma alanları olarak öne çıkmaktadır.

Sonuç itibarıyla, bu çalışma, bilgisayarlı görü, biyomedikal görüntü analizi ve sinirbilimsel modelleme alanlarının kesişiminde yer alan bütüncül bir yaklaşımla hem mühendislik hem de biyoloji tabanlı yeni nesil yapay zekâ modelleri geliştirilmesine yönelik özgün bir katkı sunmaktadır.

6. KAYNAKLAR

1. Yorston D (2003). Retinal diseases and VISION 2020. *Community Eye Health* 16: 19–20.
2. Rattner A, Sun H, Nathans J (1999). Molecular genetics of human retinal disease. *Annu Rev Genet* 33: 89–131.
3. Zhou C, Li S, Ye L, Chen C, Liu S, Yang H, Zhuang P, Liu Z, Jiang H, Han J,..., Xu X (2023). Visual impairment and blindness caused by retinal diseases: a nationwide register-based study. *Journal of Global Health* 13: 04126.
4. Bhende M, Shetty S, Parthasarathy M, Ramya S (2018). Optical coherence tomography: a guide to interpretation of common macular diseases. *Indian Journal of Ophthalmology* 66: 20–35.
5. Elsharkawy M, Elrazzaz M, Ghazal M, Alhalabi M, Soliman A, Mahmoud A, El-Daydamony E, Atwan A, Thanos A, Sandhu HS,..., El-Baz A (2021). Role of optical coherence tomography imaging in predicting progression of age-related macular disease: a survey. *Diagnostics* 11: 2313.
6. Kim J, Tran L (2021). Retinal disease classification from OCT images using deep learning algorithms. 2021 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB) IEEE, Melbourne, 13-15 October 2021, 1–6. doi:10.1109/CIBCB49929.2021.9562919.
7. Rajagopalan N, N. V, Josephraj AN, E. S (2021). Diagnosis of retinal disorders from optical coherence tomography images using CNN. *PLOS ONE* 16: e0254180.
8. Riazi Esfahani P, Reddy AJ, Nawathey N, Ghauri MS, Min M, Wagh H, Tak N, Patel R (2023). Deep learning classification of drusen, choroidal neovascularization, and diabetic macular edema in optical coherence tomography (OCT) images. *Cureus* 15: e41615.
9. Berrimi M, Moussaoui A (2020). Deep learning for identifying and classifying retinal diseases. 2020 2nd International Conference on Computer and Information Sciences (ICCIS), Sakaka, 13-15 October 2020, 1–6. doi:10.1109/ICCIS49240.2020.9257674.
10. Hadeler KP (1973). On the theory of lateral inhibition. *Kybernetik* 14: 161–165.
11. Jernigan ME, McLean GF (1992). Lateral inhibition and image processing. *Nonlinear*

- vision: determination of neural receptive fields, function, and networks. CRC Press, 1st edition, 451–462. doi:10.1201/9781351075060-17.
12. Hajizadeh F, Zarei M (2021). Optical coherence tomography (OCT). *Diagnostics in ocular imaging*, Cham: Springer International Publishing 254: 409–419.
 13. Fujimoto JG, Drexler W, Schuman JS, Hitzenberger CK (2009). Optical coherence tomography (OCT) in ophthalmology: introduction. *Optics Express* 17: 3978.
 14. Chen TC, Hoguet A, Junk AK, Nouri-Mahdavi K, Radhakrishnan S, Takusagawa HL, Chen PP (2018). Spectral-domain OCT: helping the clinician diagnose glaucoma. *American Academy of Ophthalmology* 125: 1817–1827.
 15. Pavithra KC, Kumar P, Geetha M, Bhandary S V. (2023). Computer aided diagnosis of diabetic macular edema in retinal fundus and OCT images: a review. *Biocybernetics and Biomedical Engineering* 43: 157–188.
 16. Zhang Z, Srivastava R, Liu H, Chen X, Duan L, Kee Wong DW, Kwoh CK, Wong TY, Liu J (2014). A survey on computer aided diagnosis for ocular diseases. *BMC Medical Informatics and Decision Making* 14: 1–29.
 17. Usman M, Fraz MM, Barman SA (2017). Computer vision techniques applied for diagnostic analysis of retinal OCT images: a review. *Archives of Computational Methods in Engineering* 24: 449–465.
 18. Grossniklaus HE, Geisert EE, Nickerson JM (2015). Introduction to the retina Elsevier Inc., 383–396. doi:10.1016/bs.pmbts.2015.06.001.
 19. Kolb H (1995). Simple anatomy of the retina. *Webvision: The Organization of the Retina and Visual System*, 1-24.
 20. Dahrouj M, Miller JB (2021). Artificial intelligence (AI) and retinal optical coherence tomography (OCT). *Seminars in Ophthalmology* 36: 341–345.
 21. Kapoor R, Whigham BT, Al-Aswad LA (2019). Artificial intelligence and optical coherence tomography imaging. *Asia-Pacific Journal of Ophthalmology* 8: 187–194.
 22. Mastropasqua R, Di Antonio L, Di Staso S, Agnifili L, Di Gregorio A, Ciancaglini M, Mastropasqua L (2015). Optical coherence tomography angiography in retinal vascular diseases and choroidal neovascularization. *Journal of Ophthalmology* 2015: 1–8.

23. Tsuji T, Hirose Y, Fujimori K, Hirose T, Oyama A, Saikawa Y, Mimura T, Shiraishi K, Kobayashi T, Mizota A, Kotoku J (2020). Classification of optical coherence tomography images using a capsule network. *BMC Ophthalmology* 20: 1–9.
24. Munk MR, Somfai GM, de Smet MD, Donati G, Menke MN, Garweg JG, Ceklic L (2022). The role of intravitreal corticosteroids in the treatment of DME: predictive OCT biomarkers. *International Journal of Molecular Sciences* 23: 1–22.
25. Klein R, Meuer SM, Knudtson MD, Iyengar SK, Klein BEK (2008). The epidemiology of retinal reticular drusen. *American Journal of Ophthalmology* 145: 263–279.
26. Calvo CM, Hartnett ME (2018). The utility of ultra-widefield fluorescein angiography in pediatric retinal diseases. *International Journal of Retina and Vitreous* 4: 1-6.
27. Chhablani PP, Ambiya V, Nair AG, Bondalapati S, Chhablani J (2018). Retinal findings on OCT in systemic conditions. *Seminars in Ophthalmology* 33: 525–546.
28. Jähne B, Haussecker H, Geissler P (1999). *Handbook of computer vision and applications*. Academic Press 2: 236-245.
29. Bhatt D, Patel C, Talsania H, Patel J, Vaghela R, Pandya S, Modi K, Ghayvat H (2021). CNN variants for computer vision: history, architecture, application, challenges and future scope. *Electronics* 10: 2470.
30. Haugeland J (1989). *Artificial intelligence: the very idea*. The MIT Press., London; 1-288. doi:10.7551/mitpress/1170.001.0001.
31. El Naqa I, Murphy MJ (2015). *What is machine learning? machine learning in radiation oncology*. Springer International Publishing, Cham; 3–11. doi:10.1007/978-3-319-18305-3_1.
32. Lecun Y, Bengio Y, Hinton G (2015). Deep learning. *Nature* 521: 436–444.
33. Kitaguchi D, Takeshita N, Hasegawa H, Ito M (2022). Artificial intelligence-based computer vision in surgery: recent advances and future perspectives. *Annals of Gastroenterological Surgery* 6: 29–36.
34. Szeliski R (2021). *Computer vision: algorithms and applications* 2nd edition. Springer, 1-32.

35. Ketkar N, Moolayil J (2021). Deep learning with python: learn best practices of deep learning models with PyTorch. Apress, 1-306. doi:10.1007/978-1-4842-5364-9.
36. Tabian I, Fu H, Khodaei ZS (2019). A convolutional neural network for impact detection and characterization of complex composite structures. *Sensors* 19: 1–25.
37. LeCun Y, Boser B, Denker JS, Henderson D, Howard RE, Hubbard W, Jackel LD (1989). Backpropagation applied to handwritten zip code recognition. *Neural Computation* 1: 541–551.
38. Huang G, Liu Z, Van Der Maaten L, Weinberger KQ (2017). Densely connected convolutional networks. *IEEE* 39: 4700–4708.
39. Fakoor R, Ladhak F, Nazi A, Huber M (2013). Using deep learning to enhance head and neck cancer diagnosis and classification. *Proceedings of the 30th International Conference on Machine Learning, Atlanta, 2013*, 1-6. doi:10.1109/ICSCAN.2018.8541142.
40. Tran KA, Kondrashova O, Bradley A, Williams ED, Pearson J V, Waddell N (2021). Deep learning in cancer diagnosis, prognosis and treatment selection. *Genome Medicine* 13: 1–17.
41. Kleppe A, Skrede OJ, De Raedt S, Liestøl K, Kerr DJ, Danielsen HE (2021). Designing deep learning studies in cancer diagnostics. *Nature Reviews Cancer* 21: 199–211.
42. Gupta J, Pathak S, Kumar G (2022). Deep learning (CNN) and transfer learning: a review. *Journal of Physics: Conference Series* 2273: 1-10.
43. Salehi AW, Khan S, Gupta G, Alabdullah BI, Almjally A, Alsolai H, Siddiqui T, Mellit A (2023). A study of CNN and transfer learning in medical imaging: advantages, challenges, future scope. *Sustainability* 15: 5930.
44. Hussain M, Bird JJ, Faria DR (2019). A study on CNN transfer learning for image classification. *Advances in Intelligent Systems and Computing* 840: 191–202.
45. Elena-Anca P (2023). Applications of deep learning algorithms for retinal diseases diagnosis based on optical coherence tomography imaging. *2023 24th International Conference on Control Systems and Computer Science, CSCS, 2023*, 594–597. doi:10.1109/CSCS59211.2023.00099.

46. Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z (2016). Rethinking the inception architecture for computer vision. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 11 Dec 2015, 2818–2826.
47. Khalil I, Mehmood A, Kim H, Kim J (2024). OCTNet: A modified multi-scale attention feature fusion network with InceptionV3 for retinal OCT image classification. *Mathematics* 12: 1–19.
48. Rethinking the Inception Architecture for Computer Vision (2015). Available from: <https://paperswithcode.com/method/inception-v3>. [Accessed 20 April 2025].
49. He K, Zhang X, Ren S, Sun J (2015). Deep residual learning for image recognition. *Diagnostics* 14: 1–17.
50. Karthik K, Mahadevappa M (2023). Convolution neural networks for optical coherence tomography (OCT) image classification. *Biomedical Signal Processing and Control* 79: 104176.
51. Manjunath C, Sasi A, Chowdary Ch S, Sharon Roji Priya C, Naick BR, Macherla H, Lella KK (2025). Enhancing glaucoma detection in fundus images: a ResNet based segmentation and advanced ML algorithms with Duck Pack optimizer. *International Research Journal of Multidisciplinary Technovation* 7: 108–120.
52. Chollet F (2017). Xception: deep learning with depthwise separable convolutions. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) IEEE*, Honolulu, 21-26 July 2017, 1800–1807. doi:10.1109/CVPR.2017.195.
53. Do MT, Huynh HN, Tran TN, Hoang TL (2023). Prediction of retina damage in optical coherence tomography image using Xception architecture model. *2023 IEEE 5th Eurasia Conference on Biomedical Engineering, Healthcare and Sustainability (ECBIOS), IEEE, Tainan, 02-04 June 2023, 58–61*. doi:10.1109/ECBIOS57802.2023.10218586.
54. A novel deep neural network model based Xception and genetic algorithm for detection of COVID-19 from X-ray images (2023). Available from: <https://viso.ai/deep-learning/xception-model/>. [Accessed 21 April 2025].
55. Gülmez B (2023). A novel deep neural network model based Xception and genetic algorithm for detection of COVID-19 from X-ray images. *Annals of Operations*

Research 328: 617–641.

56. Gilbert CD, Hirsch JA, Wiesel TN (1990). Lateral interactions in visual cortex. *Cold Spring Harbor Symposia on Quantitative Biology* 55: 663–677.
57. Thoreson WB, Mangel SC (2012). Lateral interactions in the outer retina. *Progress in Retinal and Eye Research* 31: 407–441.
58. Cao C, Huang Y, Wang Z, Wang L, Xu N, Tan T (2018). Lateral inhibition-inspired convolutional neural network for visual attention and saliency detection. *Proceedings of the AAAI Conference on Artificial Intelligence, AAAI [Internet]*, 27 April 2018, 6690-6697.
59. Denman Q, Lehnen J, Sebok D, Weidler T (2021). Modeling lateral inhibition in convolutional neural networks. Available from: <https://www.researchgate.net/publication/350007399Modeling>. [Accessed 20 January 2025].
60. Werblin F, Jacobs A (1996). CNN-based retinal model uncovers a new form of edge enhancement in biological visual processing. 1996 Fourth IEEE International Workshop on Cellular Neural Networks and their Applications Proceedings (CNNA-96), Seville, 24-26 June 1996, 303–307. doi:10.1109/cnna.1996.566582.
61. Marcinek F (2020). Reproduction of lateral inhibition-inspired convolutional neural network for visual attention and saliency detection. arXiv:2005.02184.
62. Lee M, Bang H, Lee E, Won Y, Kim K, Park S, Yoo H, Lee S (2022). Lateral image reconstruction of optical coherence tomography using one-dimensional deep deconvolution network. *Lasers in Surgery and Medicine* 54: 895–906.
63. Jiang L, Liu Y, Xiao S, Chua Y (2022). Gradient mask: lateral inhibition mechanism improves performance in artificial neural networks. arXiv:2208.06918.
64. Kang K, Shelley M, Sompolinsky H (2003). Mexican hats and pinwheels in visual cortex. *Proceedings of the National Academy of Sciences of the United States of America* 100: 2848–2853.
65. Mégardon G, Tandonnet C, Sumner P, Guillaume A (2015). Limitations of short range Mexican hat connection for driving target selection in a 2D neural field: activity suppression and deviation from input stimuli. *Frontiers in Computational*

Neuroscience 9: 1–16.

66. Marr D, Hildreth E (1980). Theory of edge detection. *Proceedings of the Royal Society of London - Biological Sciences* 207: 187–217.
67. Lindeberg T (2008). Feature detection with automatic scale selection. *Society* 72: 41–63.
68. Rozhyna A, Atzori M, Müller H (2024). A comparative study of deep convolutional neural networks for the analysis of retinal damage in optical coherence tomography. *Medical Imaging 2024: Imaging Informatics for Healthcare, Research, and Applications*, San Diego, 2 April 2024, 1-6. doi:10.1117/12.3006872.
69. Khudhur AM (2025). Optical coherence tomography retinal classification using deep neural network. *Journal of Optics (India)*, 1-8. doi:10.1007/s12596-025-02561-6.
70. Chan GCY, Muhammad A, Shah SAA, Tang TB, Lu C-K, Meriaudeau F (2017). Transfer learning for diabetic macular edema (DME) detection on optical coherence tomography (OCT) images. *2017 IEEE International Conference on Signal and Image Processing Applications (IEEE ICSIPA 2017)*, Malaysia, 12-14 September 2017, 493–496. doi:10.1109/ICSIPA.2017.8120662.
71. Saraiva AA, Santos DBS, Pedro P, Moura Sousa JV, Ferreira NMF, Neto JESB, Soares S, Valente A (2020). Classification of optical coherence tomography using convolutional neural networks. *International Joint Conference on Biomedical Engineering Systems and Technologies, BIOSTEC*, Lisboa, 2020, 168–175.
72. Kayadibi İ (2021). Optik koherens tomografisi görüntüleri kullanarak evrişimsel sinir ağı tabanlı retinal hastalık tespiti. Yüksek lisans tezi, Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı, Afyon.
73. Metin B, Karasulu B (2022). Derin öğrenme modellerini kullanarak insan retinasının optik koherans tomografi görüntülerinden hastalık tespiti. *Veri Bilim Derg*, 5(2): 9-19.
74. Güldemir NH, Alkan A (2021). Derin öğrenme ile optik koherens tomografi görüntülerinin sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* 33(2): 607–615.
75. Ünlü EI, Çınar A (2022). Derin öğrenme algoritmaları ile oct görüntülerinden retina

- hastalıklarının sınıflandırılması. 2nd International Conference on Engineering and Applied Natural Sciences, Konya, 15-18 Ekim 2022, 1-6.
76. Karri SPK, Chakraborty D, Chatterjee J (2017). Transfer learning based classification of optical coherence tomography images with diabetic macular edema and dry age-related macular degeneration. *Biomedical Optics Express* 8: 579.
 77. Yang J, Wang G, Xiao X, Bao M, Tian G (2024). Explainable ensemble learning method for OCT detection with transfer learning. *PLoS ONE* 19: 1–17.
 78. Aykat Ş (2023). Derin öğrenme kullanarak optik koherens tomografi görüntülerinden retina hastalığı tespiti. Doktora tezi, İstanbul Üniversitesi-Cerrahpaşa Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, İstanbul.
 79. Zhuang C, Yuan X, Guo X (2023). Suppression helps: lateral inhibition-inspired convolutional neural network for image classification. *ICLR 2023 Conference*, Kigali, 1-5 May 2023, 1–6.
 80. Fu H, Li D (2009). The application of lateral inhibition model in image's contour enhancement and design of its electro-model. *Journal of Multimedia* 4: 333–340.
 81. Kermany DS, Goldbaum M, Cai W, Valentim CCS, Liang H, Baxter SL, McKeown A, Yang G, Wu X, Yan F,..., Zhang K (2018). Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell* 172: 1122-1131.e9.
 82. Peretz O, Koren M, Koren O (2024). Naive Bayes classifier – an ensemble procedure for recall and precision enrichment. *Engineering Applications of Artificial Intelligence* 136: 108972.
 83. Jin C, Jia C, Hu W, Xu H, Shen Y, Yue M (2024). Predicting antimicrobial resistance in *E. coli* with discriminative position fused deep learning classifier. *Computational and Structural Biotechnology Journal* 23: 559–565.
 84. Powers DMW (2011). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. *International Journal of Machine Learning Technology* 2:37–63. doi:10.48550/arXiv.2010.16061.
 85. Rachmat, Yusuf M, Basmar MF, Suherwin (2024). Analysis of algorithms and data processing efficiency in movie recommendation systems based on machine learning. *Jurnal Mandiri IT* 13: 273–279.

86. Bowers AJ, Zhou X (2019). Receiver operating characteristic (ROC) area under the curve (AUC): a diagnostic measure for evaluating the accuracy of predictors of education outcomes. *Journal of Education for Students Placed at Risk* 24: 20–46.
87. Shao H, Xu Q, Yang Z, Wen P, Gao P, Huang Q (2023). Weighted ROC curve in cost space: extending AUC to cost-sensitive learning. *Advances in Neural Information Processing Systems* 36: 1–12.
88. Breiman L (2001). Random forests. *Machine Learning* 45: 5–32.
89. Universitäts- und Landesbibliothek Sachsen-Anhalt (2013). Über die wirkung der räumlichen vertheilung des lichtreizes auf die netzhaut. Available from: <https://opendata.uni-halle.de/handle/1981185920/90360>. [Accessed 20 April 2025].
90. Hubel D, Wiesel T (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology* 195: 215–243.
91. Grossberg S (1988). Nonlinear neural networks: principles, mechanisms, and architectures. *Neural Networks* 1: 17–61.
92. Serre T, Oliva A, Poggio T (2007). A feedforward architecture accounts for rapid categorization. *Proceedings of the National Academy of Sciences of the United States of America* 104: 6424–6429.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Ruken ERDEM DEMİR
Uyruğu : T.C.
Doğum Tarihi :
Telefon (İş) :
E-Posta : :
Yazışma Adresi (İş)

EĞİTİM BİLGİLERİ

Derece	Mezun Olduğu Kurumun Adı	Mezuniyet Yılı
Doktora/Uzmanlık	Karadeniz Teknik Üniversitesi/ Biyoistatistik ve Tıp Bilişimi	-
Yüksek Lisans	Yüzüncü Yıl Üniversitesi/ Biyoistatistik ve Tıp Bilişimi	2017
Lisans	Yüzüncü Yıl Üniversitesi/ Matematik	2008
Lise	Kızıltepe İpekyolu Anadolu Lisesi	2000

AKADEMİK/MESLEKİ DENEYİMİ

Görevi	Kurum	Süre (Yıl -Yıl)
1. Öğretim Görevlisi (Ek Ders)	Ardahan Üniversitesi	2015-2016
2. Matematik/Geometri Öğretmeni	Açı Dershanesi	2011-2013
3. Matematik/Geometri Öğretmeni	Uğur Dershaneleri	2008-2011

YABANCI DİL

YÖKDİL 2018 Sonbahar Dönemi Sınavı

UZMANLIK ALANI

Biyoistatistik ve Tıp Bilişimi