

T.C.
AKDENİZ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
BİYOİSTATİSTİK VE TIBBİ BİLİŞİM ANABİLİM DALI

DERİN ÖĞRENME YÖNTEMLERİYLE PREMATÜRE
BEBEKLERİN RETİNA GÖRÜNTÜLERİNİN ANALİZİ

Evren SEZGİN

DOKTORA TEZİ

2025-ANTALYA

EVREN SEZGİN

DOKTORA TEZİ

2024-ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
BİYOİSTATİSTİK VE TIBBİ BİLİŞİM ANABİLİM DALI

DERİN ÖĞRENME YÖNTEMLERİYLE PREMATÜRE BEBEKLERİN RETİNA GÖRÜNTÜLERİNİN ANALİZİ

Evren SEZGİN

DOKTORA TEZİ

DANIŞMAN
Prof. Dr.Ahmet YARDIMCI
İKİNCİ DANIŞMAN
Doç.Dr.Yiğit Ali ÜNCÜ

“Kaynakça gösterilerek tezimden yararlanılabilir”

2025-ANTALYA

Sağlık Bilimleri Enstitüsü Müdürlüğüne;

Bu çalışma jürimiz tarafından Biyoistatistik ve Tıbbi Bilişim Anabilim Dalı Tıp Bilişim Programında Derin Öğrenme Yöntemleriyle Prematüre Bebeklerin Retina Görüntülerinin Analizi tezi olarak kabul edilmiştir. / /

İmza

Tez Danışmanı :
Prof. Dr. Ahmet YARDIMCI
Akdeniz Üniversitesi

Üye :
Doç. Dr. Hakan GÜLKESEN
Akdeniz Üniversitesi

Üye :
Doç.Dr. Neşe ZAYİM
Akdeniz Üniversitesi

Üye :
Dr. Öğr. Üyesi Yılmaz KEMAL YÜCE
Alanya Alaaddin Keykubat Üniversitesi

Üye :
Dr. Öğr. Üyesi Turgay AYDOĞAN
Süleyman Demirel Üniversitesi

Bu tez, Enstitü Yönetim Kurulunca belirlenen yukarıdaki jüri üyeleri tarafından uygun görülmüş ve Enstitü Yönetim Kurulu'nun / / tarih ve / sayılı kararıyla kabul edilmiştir.

Enstitü Müdürü

ETİK BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün safhalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı beyan ederim.

Öğrencinin Adı Soyadı

Evren SEZGİN

İmza

Tez Danışmanı

Prof. Dr. Ahmet YARDIMCI

İmza

TEŞEKKÜR

Öncelikle, danışman hocam Prof. Dr. Ahmet YARDIMCI' ya, tez sürecimde göstermiş olduğu sabır, rehberlik ve değerli katkıları için sonsuz minnettarlığımı ifade etmek istiyorum. Kendisi, akademik yolculuğumda benim için sadece bir rehber değil, aynı zamanda ilham kaynağı olmuştur.

İkinci Danışman hocam Doç. Dr. Yiğit Ali ÜNCÜ' ye hem fikirsel anlamda hem de teknik detaylar konusunda sağladığı rehberlik ve yol gösterici öneriler için teşekkürlerimi sunuyorum.

Ailem, özellikle sevgili eşim Nurper SEZGİN ve çocuklarım, bu süreç boyunca bana verdikleri koşulsuz destek, sevgi ve sabırla her zaman yanımda oldular. Onlara olan teşekkürüm tarif edilemez.

Ayrıca, tez çalışmamda veri toplama, analiz ve diğer süreçlerde bana destek veren değerli hocam Prof. Dr. Ahmet Burak BİLGİN' e ve çalışma arkadaşlarına içten teşekkürlerimi sunarım.

Son olarak, bu süreçte bana manevi destek sağlayan Biyoistatistik ve Tıp Bilişimi Anabilim dalındaki değerli hocalarım ve öğrenci arkadaşlarıma, doktora ders dönemindeki akademik camiaya katkılarıyla yolumu aydınlatan tüm akademisyenlere şükranlarımı sunarım.

Bu tez, tüm bu destek ve katkılar sayesinde bugün tamamlanabilmiştir.

Evren SEZGİN

ÖZET

Amaç: Bu çalışmanın amacı, prematüre retinopatisi (ROP) tanısında klinik uzmanlara yardımcı olabilecek, derin öğrenme temelli bir karar destek sistemi geliştirmektir. Bu kapsamda, prematüre bebeklere ait retina görüntüleri, modern görüntü işleme teknikleri ve derin öğrenme algoritmaları kullanılarak analiz edilerek ve ROP hastalığına ilişkin evrelerin otomatik olarak sınıflandırılması amaçlanmaktadır. Geliştirilecek sistem ile tanı sürecinin hızlandırılması, uzman bağımlılığının azaltılması ve erken müdahale ile hastalığın ilerlemesinin önlenmesi hedeflenmektedir.

Yöntem: Bu hedefte, retina görüntüleri üzerinde, görüntü işleme teknikleri ile görüntü optimizasyonu ve standartlaşması sağlanmıştır. Sınıflandırma işlemi için derin öğrenme yöntemleri kullanılmıştır. Özellikle konvolüsyonel sinir ağları (CNN) gibi derin öğrenme algoritmaları kullanılarak prematüre bebeklerin retina görüntüleri analiz edilerek ve hastalığın sınıflarının (Normal-ROP0, ROP1, ROP2) otomatik olarak tespit edilmesi sağlanmıştır.

Bulgular: Akdeniz Üniversitesi Tıp Fakültesinden alınan ham veri setinde toplam 13779 retina görüntüsü bulunmaktadır. Bu görüntülerdeki veriler filtrelenmiş ve çoğaltılmıştır. Son olarak 25821 retina görüntüsü elde edilmiştir. Bu veri setine CNN algoritmalarından AlexNet'te %83,5, Inception-V3 %89,1, EfficientNet-B0 ise %89,9'luk bir doğruluk oranı tespit edilmiştir.

Sonuç: Görüntü iyileştirme ve derin öğrenme yöntemlerinden sonra en iyi sonucu veren yöntemin %89,9 doğruluk oranı ile EfficientNet-B0 olduğu gözlemlenmiştir. Bu modelin sınıfları ayırt etmede AUC (Area Under Curve) değerlerinin Normal-ROP0 %99, ROP1 %97, ROP2 %98 olduğu tespit edilmiştir. Doğruluk oranlarının yükseltilmesi amacıyla veri miktarının artırılması ve elde edilen görüntülerin çözünürlük ve netlik düzeylerinin iyileştirilmesi gerekmektedir.

Anahtar Kelimeler: Prematüre Retinopatisi, Derin Öğrenme, Yapay Zeka, Retina görüntüleri.

ABSTRACT

Objective: The aim of this study is to develop a deep learning-based decision support system to assist clinical experts in the diagnosis of retinopathy of prematurity (ROP). In this context, retinal images of premature infants are analyzed using modern image processing techniques and deep learning algorithms, with the goal of automatically classifying the stages of ROP. The proposed system is intended to accelerate the diagnostic process, reduce reliance on expert interpretation, and enable early intervention to prevent the progression of the disease.

Method: For this purpose, image optimization and standardization were achieved on retinal images with image processing techniques. Deep learning methods were used for the classification process. In particular, deep learning algorithms such as convolutional neural networks (CNN) were used to analyze the retinal images of premature babies and the classes of the disease (Normal-ROP0, ROP1, ROP2) were automatically detected.

Results: There are a total of 13779 retinal images in the raw dataset obtained from Akdeniz University Faculty of Medicine. Then, the data in these images were filtered and multiplied. Finally, 25821 retinal images were obtained. An accuracy rate of %83,5 in AlexNet, %89,1 in Inception-V3, and %89,9 in EfficientNet-B0 was determined for this dataset from CNN algorithms.

Conclusion: Following image enhancement and deep learning-based classification, the highest performance was achieved by EfficientNet-B0, with an accuracy rate of %89,9. The AUC (Area Under the Curve) values for this model were determined to be 99% for the Normal-ROP0 class, 97% for ROP1, and 98% for ROP2. To further increase classification accuracy, it is recommended to enlarge the dataset and enhance the resolution and clarity of the retinal images.

Keywords: Retinopathy of Prematurity, Deep Learning, Artificial Intelligence, Retinal images.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
TABLOLAR DİZİNİ	iv
ŞEKİLLER DİZİNİ	v
SİMGELER ve KISALTMALAR	vi
1. GİRİŞ	1
2. GENEL BİLGİLER.....	2
3. GEREÇ VE YÖNTEM.....	13
3.1. RETCAM CİHAZI İLE GÖRÜNTÜNÜN ELDE EDİLMESİ.....	13
3.2. GÖRÜNTÜNÜN İYİLEŞTİRİLMESİ.....	15
3.2.1. Histogram İşlemleri	15
3.2.2. Görüntü Filtreleme Algoritmaları.....	16
3.2.3. Kenar Bulma Algoritmaları	17
3.3. ÖZNİTELİK ÇIKARMA.....	20
3.3.1. Yönlendirilmiş Gradyanların Histogramı (HOG, Histograms of Oriented Gradients).....	21
3.3.2. Hough Dönüşümü	22
3.3.3. Otoregresif model	22

3.3.4. Poligonal yaklaşım.....	23
3.3.5. Zincir kodları	25
3.4. SINIFLANDIRMA.....	27
3.4.1.Yapay Sinir Ağları	28
4. BULGULAR	37
5. TARTIŞMA	50
6. SONUÇ VE ÖNERİLER.....	52
KAYNAKLAR	60
ÖZGEÇMİŞ.....	68

TABLÖLAR DİZİNİ

Tablo 2.1. Derin öğrenme ile yapılan çalışmaların karşılaştırılması	11
Tablo 3.1. Modellerin Eğitim Süreleri	36
Tablo 4.1. Veri Seti Bilgileri.....	39
Tablo 4.2. Kullanılan tüm yöntemlerin sayısal karşılaştırılması.....	42
Tablo 6.1. Veri Seti sayıları	52
Tablo 6.2. Derin Öğrenme Modellerinin ROP Sınıflandırma Performans Karşılaştırması	53
Tablo 6.3. Derin Öğrenme Modellerinin 3 Sınıf için ROP Sınıflandırma Performans Karşılaştırması.....	55

ŞEKİLLER DİZİNİ

Şekil 3.1. Sistemin ana akış şeması.....	13
Şekil 3.2. Örnek Bir retina görüntüsü	14
Şekil 3.3. Görüntülerin döndürülerek çoğaltılması	14
Şekil 3.4. Yatay ve Düşey Histogramlar (Şevik, 2007)	15
Şekil 3.5. Yatay ve Dikey Kerneller	18
Şekil 3.6. Öznitelik çıkarma yöntemleri (Günel, 2001)	21
Şekil 3.7. Nesnenin merkezine göre kenar uzunluklarının değişimi.....	23
Şekil 3.8. Poligonal yaklaşım ile nesnenin kritik noktalarının bulunması.....	24
Şekil 3.9. a) Dörtlü zincir kod b) Sekizli zincir kod	25
Şekil 3.10. Verilen sayısal görüntünün sınırlarının dörtlü zincir kod gösterimi.....	25
Şekil 3. 11. Verilen nesnenin sınırlarının sekizli zincir kod ile kodlanması.....	26
Şekil 3. 12. Derin Öğrenme Aşamaları	29
Şekil 4. 1. ROP görüntüsüne farklı filtreleme yapıldıktan sonraki görüntüleri, A) Orijinal Görüntü, B) Gri Tona Çevrilmiş Görüntü, C) Laplace filtreleme, D) Gaussian filtreleme, E) CLAHE filtreleme, F) Median filtreleme	40
Şekil 4.2. ROP görüntüsünde farklı eşikleme yöntemleri sonrası oluşan görüntü örnekleri. A) Orijinal görüntü, B) Gri tonlamalı görüntü, C) Niblack eşikleme, D) Kittler eşikleme, E) Bulanık çıkarım tabanlı eşikleme, F) Kapur eşikleme, G) Triangle eşikleme, H) Çapraz entropi tabanlı eşikleme, I) Otsu eşikleme.....	41
Şekil 4.3. Damar Görüntülerini Tespit Aşamaları	43

Şekil 4.4. Retina Görüntüsüne Maskeleye işlemi	44
Şekil 4.5. A) Laplace Görüntü, B) Clahe Algoritması uygulandıktan sonraki görüntü...	46
Şekil 4.6. Kapanma işleminden sonra retina damarlarının çıkarım görüntüsü.	49
Şekil 6.1. Derin Öğrenme Modellerinin ROC eğrileri. A) AlexNet Modeli, B) DenseNet201 Modeli, C) EfficientNet-b0 Modeli, D) GoogleNet Modeli, E) Inception-v3 Modeli, F) ResNet-18 Modeli	54
Şekil 6.2. Derin Öğrenme Modellerinin Karışıklık Matris (Confusion Matrix) sonuçları. A) AlexNet Modeli, B) DenseNet201 Modeli, C) EfficientNet-b0 Modeli, D) GoogleNet Modeli, E) Inception-v3 Modeli, F) ResNet-18 Modeli	56
Şekil 6.3. ROP (3 Sınıf) için Derin Öğrenme Modellerinin ROC eğrileri. A) AlexNet Modeli, B) DenseNet201 Modeli, C) EfficientNet-b0 Modeli, D) GoogleNet Modeli, E) VGG19 Modeli, F) Inception-v3 Modeli.	58

SİMGELER ve KISALTMALAR

CNN	: Convolutional Neural Network- Konvolüsyonel Sinir Ağı
GAN	: Generative Adversarial Networks- Üretici Çekişmeli Ağ
ILSVRC	: ImageNet Large Scale Visual Recognition Challenge- Büyük Ölçekli Görsel Tanıma Yarışması
MSE	: Mean Squared Error - Ortalama Kare Hatası
NAG	: Normalleşmiş Eğilim
PSNR	: Peak Signal to Noise Ratio - Tepe Sinyal-Gürültü Oranı
ReLU	: Rectified Linear Unit – Düzeltilmiş Doğrusal Fonksiyon
RNN	: Recurrent Neural Networks- Tekrarlayan Sinir Ağı
ROP	: Retinopathy of Prematurity - Prematüre Retinopatisi
SSIM	: Structural Similarity Index- Yapısal Benzerlik İndeksi

1. GİRİŞ

Bir bebek erken doğduğunda (24-30 hafta arası doğan) retinadaki normal damar gelişimi durur ve yeni anormal damar yapımı ortaya çıkar (Walter ve ark.,2018). Bu yeni damarlar kolay çatlayabilen ve sızıntıya sebep olabilen yapıdadır. Aynı zamanda bu damarlar retinaya besin iletiminde de başarılı değildir. Zaman geçtikçe bu damarlanma fibröz nedbe dokusu meydana getirerek retinaya ve vitreye yapışır, beraberinde retinayı çekmeye başlar ve sonunda retinayı ayırmayı başarır (Walter ve ark.,2018).

Garcia ve arkadaşlarının 2024 yılında yayınladığı çalışmada, 1985–2021 yılları arasında dünyadaki Prematüre Retinopatisi (ROP) prevalansındaki eğilimi tanımlamak istemişlerdir. Bu amaçla, Pubmed, Embase ve Google Scholar’ da yer alan 139 çalışmadan toplam 121618 prematüre bebeği değerlendirmeye almışlardır. Meta-analiz sonucunda dünya genelinde prematüre bebeklerde herhangi bir evre ROP’ un prevalansı %31,9 olarak bulunmuştur. Tedavi gerektirecek derecede ROP oranı ise %7,5 düzeyinde tespit etmişlerdir. 1985’ten 2021’e uzanan kırk yıllık dönemde küresel ROP prevalansında belirgin bir azalma eğilimi tespit edilmemiştir. Örneğin, meta-analiz bulgularına göre 1985–1999 döneminde ROP prevalansı %32,5 iken 2000–2010 döneminde %29,9, 2011–2021 döneminde %34 olarak rapor edilmiştir (Garcia ve ark, 2024). Bu nedenle, risk altındaki prematüre bebeklerin uygun şekilde erken taranması ve tedaviye yönlendirilmesi büyük önem taşımaktadır.

Türkiye’de 2018 yılında 69 yenidoğan bakım ünitesinde erken doğan 6118 bebeğin retina taramasında, ROP prevalansı %27, tedavi gerektiren retina prevalansı ise %6,7 tespit edilmiştir (Bas ve ark., 2018).

Bu sebeplerden dolayı, doğumdan sonraki 4. ve 6. hafta bebeklerin mutlaka göz muayenesi yapılması gerekmektedir (Aaby ve ark.,1991). Türkiye’de ROP muayenesi yapabilen merkez sayısı yaklaşık 30 kadardır. Yapılan muayenelerde, uzmanın geçmiş bilgi ve birikimi sonuca doğrudan etki etmektedir. Bu nedenle bu tezde derin öğrenme teknikleri kullanılarak gözlemcinin sonuç üzerindeki etkisinin en aza indirilmesi ve bu manada daha güvenilir ve daha objektif bir ölçüm aracı geliştirilmesi amaçlanmaktadır.

2. GENEL BİLGİLER

Gözümüzün arka duvarını kaplayan retina, milyonlarca görme hücresinden oluşan sinir lifleri ağıdır (Atchison, 2023). Bu hücreler, gözle algıladığımız görüntüleri sinirler aracılığıyla beyne ileterek görmemizi sağlar. Retinadaki herhangi bir bozukluk, görüntülerin beyne doğru şekilde ulaşmasını engelleyebilir veya bu iletişimi tamamen kesebilir (Atchison, 2023).

ROP, erken doğan bebeklerde gözün retina tabakasında anormal damar oluşumu ile ortaya çıkan bir hastalıktır. Normalde, gözdeki damarlar doğumdan önceki son haftalarda gelişmektedir. Ancak prematüre bebeklerde bu süreç tamamlanmadan doğum gerçekleşir. Bu durumda, eksik kalan damarlar doğum sonrası gelişmeye başlar. Ancak, bazı durumlarda bu damarlar normal gelişim göstermeyerek, retina yüzeyine doğru anormal bir şekilde büyüme göstermektedir. Bu anormal büyüme, retina üzerinde yüksek basınç nedeniyle retina dekolmanı (ayrılması) ve görme kaybına neden olabilir.

Foos' un yapmış olduğu araştırmada (Foos, 1985); ROP, retinanın damarsal gelişimindeki bozukluk sonucu ortaya çıkan ve prematüre bebeklerde retinal damarlarda yapısal değişikliklere yol açarak körlükle sonuçlandığını çalışmalarında yayınlamışlardır. Son yıllarda bu hastalığın insidansında belirgin bir artış gözlemlendiğini belirlemişlerdir. ROP'un etyolojisinde çeşitli faktörler öne sürülsede, akut fazdaki temel neden lokal retina iskemisi ve bunun sonucunda gelişen neovaskülarizasyon olduğunu saptamışlardır. Kronik fazda ise hastalığın temel mekanizması membran oluşumu ve bunu takip eden retina dekolmanı olduğunu belirlemişlerdir. Akut fazdaki olguların yaklaşık %90'ı kendiliğinden gerileyerek ciddi bir görme kaybına neden olmazken, %10'luk bir kısmı ilerleyerek retina dekolmanına ve nihayetinde körlüğe yol açtığını saptamışlardır.

Geçmişte yapılan çalışmalarda prematüre doğumların tüm canlı doğumların yaklaşık olarak %8,2'sini oluşturduğunu belirtmişlerdir (Joussen ve ark, 2007; Brennan ve ark., 2003; Holmstrom ve ark., 1993; Schali-Delfos ve ark., 1993). Hastalığı özellikle 33 haftadan önce doğan bebekleri veya daha geç doğmuş olup şiddetli hastalık (sepsis, nekrotizan enterokolit) geçiren veya uzun süre oksijen tedavisi alan bebekler ile ilişkilendirmişlerdir.

Aynı zamanda hastalık 1500 gramın altında doğmuş olan bebeklerin %27-40'ında görüldüğünü ve son yıllarda çoğul gebelikler nedeni ile artan prematüre doğum sıklığının dikkat çektiğini belirlemişlerdir. ROP' un çocuklarda görülen körlüklerin 3. en sık nedenini oluşturduğunu belirtmişlerdir.

Hastalığın sınıflandırılması, ilk olarak 1984 yılında kabul edilen, sonra 1987 yılında geliştirilen Uluslararası Prematüre Retinopatisi Sınıflandırması (International Classification of Retinopathy of Prematurity - ICROP) temel alınarak yapılmaya başlanmıştır. Son olarak, Temmuz 2005'te bu sınıflandırmanın yenilenmiş hali yayımlanmıştır. Bu güncellenmiş versiyon da, ICROP sınıflandırmasını ve altı farklı ülkeden 15 oftalmolog tarafından önerilen değişiklikleri içermektedir

Uluslararası sınıflandırma sistemi aşağıda belirtilen 3 klinik parametreyi temel almaktadır:

1-Hastalığın lokalizasyonu (zone)

2-Hastalığın vasküler proliferasyon derecesi (evre)

3-Hastalığın ilerleme derecesi (saat kadranı)

Ayrıca sınıflandırma sisteminde dilatasyonu ve kıvrımlılığı (tortuosity) artmış damarların varlığı veya yokluğu da dikkate alınmış ve bu durum plus hastalığı adıyla belirtilmiştir.

Wallace ve arkadaşları yaptıkları araştırmada; ROPtool kullanarak 20 prematüre bebek üzerinde, 20 yüksek kaliteli RetCam görüntü kullanıp 154 kan damarlarının genişliğini ölçmüşlerdir (Wallace ve ark., 2007). Sonuç tespitinde, kullanıcı doğruluğu için ortalama 10 puanlık bir ölçek kullanılmış ve 2 uzmanın görüşleri karşılaştırılmıştır. ROPtool ölçümleri ile uzman görüşleri arasında korelasyon değeri 0,80 olarak tespit edilmiştir. Ölçümlerde ROPtool' un duyarlılığı %89 (24/27), özgüllüğü %83 (106/127) olarak bulunduğu ve bununla oldukça yeterli bir sonuç olduğu sonucuna varılmıştır. Bu çalışmada öznitelik vektörü olarak sadece görüntülerdeki damarların genişliğine bakılmıştır.

Yavuz ve arkadaşları (2010) çalışmalarında, retina görüntülerinde optik Retinal görüntülerin analizinin doğru biçimde yapılması, retinanın doğal yapısındaki optik disk ve makula gibi yapıların doğru olarak tespiti ve dejenerasyonlardan ayırt edilmesi ile yakından ilişkili olduğunu tespit etmişlerdir (Yavuz ve ark., 2010). Literatürde bu alanda yapılmış çok sayıda çalışma vardır. Bu çalışmalar, görüntü işleme veya model tabanlı olabilmektedir. Her iki yöntemin de kullanıldığı bu çalışmada ilk olarak görüntü işleme teknikleri ile retinal görüntüde aday optik disk bölgeleri bulunmakta, daha sonra Hough Dönüşümü yöntemi ile retinada geometrik olarak bir daire oluşturabilecek bölgeler tespit edilmektedir. Son olarak dairesel yapılar ve aday optik disk bölgeleri karşılaştırılarak optik diskin bulunduğu bölge tespit edilmektedir. Karadeniz Teknik Üniversitesi Tıp Fakültesi oftalmoloji bölümünden alınan retinal görüntüler üzerinde yapılan testler sonucunda %85 oranında başarı sağlamıştır.

Gelman ve arkadaşları (2005) çalışmalarında ROP ile plus hastalığın tanısı için yarı otomatik görüntü analiz yazılımı paketi, Retina Görüntü Ölçek Analizi (RISA) değerlendirmesi yapmışlardır (Gelman ve ark., 2005). RISA' nın geliştirilmiş bir versiyonuyla ROP kontrolü için gelen görüntülerde disk ve makula bölümleri incelenmiştir. Venüller (N=106) ve arteriol (N=44) tespit edilmiş ve damarların eğrilik, çapı ve kıvrımları hesaplanmış, RISA hesaplamaları tamamlandıktan sonar 16 bebeğin 12 gözünde hastalık tespit edilip, 20 gözde hastalık bulunmamıştır. Damarla iki gruba ayırıp, hastalıklı ve hastaliksız her RISA parametresi Mann Whitney testi kullanılarak karşılaştırılmıştır. Sonuç olarak; arteriol ve venüller her ikisi içinde üç parametrenin artı hastalık grubu için önemli ölçüde büyük olduğu saptanmıştır. Örneğin medyan tahmini arteriol ve venüllerin çaplarının hastalıklı kişilerde yaklaşık 12 mm. daha büyük olduğunu tespit etmişlerdir. En yüksek tanısal doğruluk Arterioller için %91,1, venüller için %82,4 olarak tespit edilmiştir.

Al-Rawi ve arkadaşının çalışmasında, DRIVE veri tabanından alınan 40 görüntü üzerinde genetik algoritma yöntemi kullanarak damarların tespit edilmesine çalışılmıştır (Al-Rawi ve Karajeh, 2007). Uygunluk fonksiyonu olarak ROC eğrisi değerleri seçilmiştir. Genetik algoritma ve Gaussian metodu kullanılarak karşılaştırma yapılmıştır. Ortalama ROC değeri 0,9582 olarak tespit edilmiştir. Damarların uzunluğuna ve yoğunluğuna göre

bölümlendirilmiş ve fitness değerleri hesaplanmıştır. Buna göre damarların ortalama uzunluğu, yoğunluğu hakkında değerler elde edilip yeni görüntülere uygulanıp doğruluk değeri hesaplanmıştır. Ortalama doğruluk oranı %94,22 olarak tespit etmişlerdir.

Soares ve arkadaşları retinal görüntüleri otomatik olarak bölümlemek için bir çalışma yapmışlardır (Soraes ve ark.,2006). Görüntüdeki her pikselin damar olup olmadığı bir vektörde toplanmış, daha sonra bu vektör özellikleri 2-D Morlet Dalga Dönüşümünden geçirilmiştir. Bu şekilde üzerindeki frekans değerlerine bakarak, gürültüden arındırılmaktadır. Daha sonra Bayes sınıflama ile görüntüler sınıflara ayrılmaktadır. Sistemin performansı en küçük karesel hata ile ölçülmüştür. DRIVE veri tabanından alınan görüntülerin, yapılan ölçümlerinde ROC değeri 0,9598 olarak ölçülmüştür.

Delibasis ve arkadaşlarının çalışmalarında, retina damarlarını bölütlere ayırarak, görüntülerde otomatik olarak damar sınıflama algoritması geliştirilmiştir (Delibasis ve ark., 2010). Bunun için damarların matematiksel modelleri çıkartılmıştır. Damarların genişliğini hesap ederek, orta noktalarından hareketle damarın ilerleyişini takip etmişlerdir. Damarın çatallaştığı noktaları bu algoritma ile tespitini yapmışlardır. Algoritmalarının doğruluk oranını %94,3 olarak saptamışlardır.

Pedersen ve arkadaşlarının yaptığı çalışma da ise, damarların optik diske olan uzaklığın sonucu olarak, retinal damarların çapındaki değişimin, damar tıkanıklığı diyabetik “Mellitus” gibi çeşitli hastalıkların risk seviyelerinin göstergesi olduğu düşünülmektedir (Pedersen ve ark., 2000). Özellikle, atardamar daralmasının damar tıkanıklığı ile ilgili olduğu düşünülmektedir. Genişlik veya çap ölçüleri Dijkstra’nın kısayol algoritması yoluyla bulunan, damardaki düzleşmiş yola dik olan yoğunluk profillerine dayalıdır. Damar çapı profil genişliklerini tahmin etmek için iki farklı yöntem kullanılır ve damar çapı yoğunluk profillerinden hesaplanır. Damar bölümündeki, merkezi damar daralması tahmin etmek için Normalleştirilmiş eğilim (NAG) ve değişkenin ölçeği kullanarak yöntem tasarlamışlardır. NAG’ ın tasarlanmasında, göz papillasına olan uzaklık artışı ile damar çapında meydana gelen değişimler karşılaştırılmıştır. Geliştirilen bu yöntemlerin performansı nitelikli göz doktoru tarafından değerlendirilmiş ancak herhangi istatistiksel bir ölçüm yapılmamıştır.

Lam ve Yan (2008) çalışmalarında patolojik retinal görüntüler üzerinde çalışmışlar ve görüntülerdeki damar benzeri yapıları ayırt etmek için Laplace operatörü kullanmışlardır (Lam ve Yan, 2008). Daha sonra gürültülü bölgelerin elenmesi için normalize edilmiş gradient vektör alanı kullanılmıştır. STARE veri tabanında yapılan değerlendirme de %89'lara varan bir doğruluk oranı elde etmişlerdir.

Köse ve İkibaş (2011) yaptıkları çalışma ile diyabet hastalığını retina görüntülerinden erken teşhis etmek için bir algoritma geliştirmişlerdir (Köse ve ark., 2011). Bu çalışmada, diyabet hastalığı tanısı koymak için bir metot geliştirilmiştir. Bu metod ters segmentasyon yöntemi üzerine kurulmuştur. Arka plan görüntüleri, ters segmentasyon ile retina fundus görüntülerindeki dejenerasyonları ölçmek ve takip etmek için kullanılır. Doğrudan segmentasyon teknikleri bazı durumlarda tatmin edici olmayan sonuçlar üretmiştir. Bu diyabetik retinopati gibi sağlıklı doku alanlarının homojen olmamasının sonucudur. Ters segmentasyon yöntemi, sağlıklı alanların değişen yapısında, parlak lezyonları segmente etmektense, sağlıklı alanların homojenliğinden yararlanmayı önermektedir. Öte yandan retinal görüntüyü yüksek ve düşük yoğunluklu alanlara bölerek, arka plan görüntüsünden, ayırmışlardır.

Walter ve arkadaşının yaptığı çalışmada renkli retina görüntülemeye Dilation, Erosion, Opening ve Closing Morforolojik operatörleri kullanılarak optik disk ve damarların yapısı sınıflandırılmaya çalışılmıştır (Walter ve ark., 2001). 30 görüntü test edilmiş ve sadece birkaç tanesinde iyi sonuç elde edilememiştir.

Ricci ve Perfetti (2007) yapmış olduğu çalışmada, kenar tespit yöntemleri ve destek vektör sınıflandırması (SVM) yaparak damar yollarını tespit etmeye çalışmışlardır (Ricci ve Perfetti, 2007). Bu çalışmada, görüntüyü 15x15'lik parçalara ayırarak, parçalar içerisinde başlangıç pozisyonundan başlamak üzere 15 derece aralıklarla denemeler yaparak damarın yönünü tespit etmeye çalışmışlardır. Bu yöntem ile %95, SVM uygulayarak ise %96 başarı elde etmişlerdir. Uygulamayı, retinal görüntü etrafındaki tüm değişimleri ölçmek için de kullanmışlardır. Dolayısıyla, aynı hastalara ait retina görüntüleri, hastalığın farklı evrelerinde incelemişlerdir. Naive Bayes metodu, diyabetik retinopatiji segmente etmek için uygulamışlardır. Farklı veri setlerinde sistem

performansını, optik disk tespitinde %95, diyabetik retinopatiyi segmente etmekteyse %90 olarak tespit etmişlerdir.

Campbell ve arkadaşları 2021 yılında yayınladıkları çalışmada, Hindistan'daki bir ROP tele sağlık programından elde edilen görüntüler üzerinde bir derin öğrenme sistemi test edilmiştir. Sonuçlar, yapay zekanın ROP' un tedavi gerektiren formlarını tespit etmede yüksek doğruluk sağladığını göstermektedir (AUROC: %98). Ayrıca, oksijen yönetimi ve neonatal bakım birimlerinin kaynakları ile ROP şiddeti arasında anlamlı bir ilişki bulunduğu belirtilmiştir. Çalışma, yapay zekanın ROP taramasını daha verimli hale getirerek klinik iş yükünü azaltabileceğini ve aynı zamanda hastalık epidemiyolojisini değerlendirmek için bir araç olarak kullanılabileceğini vurgulamaktadır. Ancak, teknolojinin farklı popülasyonlara genellenebilirliği ve düşük maliyetli cihazlarla entegrasyonu gibi konularda daha fazla araştırma yapılması gerektiği ifade edilmektedir.

Wu ve arkadaşları 2022 yılındaki çalışmalarında, ROP teşhisi ve şiddetinin tahmini için derin öğrenme modeli geliştirilmesini ve doğrulanmasını ele almaktadır (Wu ve ark, 2022). Çalışma, 988 prematüre bebekten alınan retinal görüntüler ve klinik özellikler kullanılarak iki model geliştirmiştir: ROP oluşumunu tahmin eden "OC-Net" ve ROP şiddetini tahmin eden "SE-Net". Modeller, ilk ROP taraması sırasında elde edilen retinal görüntüler ve klinik bilgilerden yararlanarak 45 haftalık doğum sonrası yaş öncesinde tahmin yapabilmektedir. ROP tahmininde yüksek duyarlılık (%100) ve AUC değerleri (0.90 ve 0.88) sergilemiştir. Çalışma, derin öğrenme modellerinin, özellikle yüksek risk altındaki bebeklerin erken tanımlanmasında, oftalmologların iş yükünü azaltabileceğini ve ROP kaynaklı körlüğün önlenmesine katkı sağlayabileceğini göstermektedir. Ancak, modellerin genellenebilirliği ve farklı veri kümeleri üzerindeki performanslarının daha fazla araştırılması gerektiği vurgulanmıştır.

Ramanathan ve arkadaşları çalışmalarında, ROP teşhisi için yapay zeka algoritmalarının performansını sistematik olarak incelemektedir (Ramanathan ve ark.,2022). Çalışmada, yapay zeka sistemlerinin ROP' un evrelerini sınıflandırma, plus veya pre-plus hastalığını tespit etme ve vasküler şiddet skoru kullanarak hastalığın ciddiyetini belirlemedeki başarıları değerlendirilmiştir. İncelenen 27 çalışmanın sonuçlarına göre, algoritmalar %71-100 hassasiyet, %74-99 özgüllük ve %91-99 AUROC değerleri ile yüksek doğruluk

göstermiştir. Yapay zekanın klinik değerlendirme süreçlerinde göz doktorlarına yardımcı olma potansiyeline sahip olduğu, ancak mevcut algoritmaların klinik uygulamalara entegrasyonu ve farklı veri kümeleri üzerindeki genelleme yeteneği konularında sınırlamaları olduğu vurgulanmıştır. Ayrıca, teknolojinin daha yaygın kullanımı için etik, yasal ve yönetsel zorlukların aşılması gerektiği belirtilmiştir.

Zhang-Nunes ve arkadaşlarının yayınladıkları çalışmalarında, ROP tedavisinde yapay zekâ uygulamalarının zorluklarını ve fırsatlarını ele almaktadır (Zhang-Nunes, ve ark., 2024). Görüntü tabanlı ROP teşhisinin, yapay zekâ sistemlerinin uygulanması için uygun bir alan olduğu vurgulanmaktadır. Çalışma, düşük ve orta gelirli ülkelerde yapay zekanın uygulanmasının önündeki altyapı, düzenleyici, yasal ve mali engellerin altını çizerek, başarılı tele-sağlık programlarının nasıl yürütüldüğünü örneklerle açıklamaktadır. Ayrıca, ROP tanı ve yönetiminde yapay zekanın, sağlık sistemleri üzerindeki yükü azaltma, epidemiyolojik verileri izleme ve düşük maliyetli cihazlarla entegrasyon sağlama potansiyeline sahip olduğu belirtilmiştir. Ancak, YZ sistemlerinin farklı popülasyonlarla doğrulanması, sürdürülebilirlik ve maliyet etkinliği konularında daha fazla araştırmaya ihtiyaç duyulduğu vurgulanmaktadır.

Yıldız ve arkadaşlarının yapmış olduğu çalışmada, ROP plus hastalığı tanısını koymak için I-ROP ASSIST adında otomatik bir sistem geliştirmişlerdir. Yöntem olarak retina damarlarının otomatik segmentasyonu ve merkez çizgilerinin çıkarılması sonrasında, damar eğrilik ve genişlik gibi ROP ile ilgili özellikler hesaplanmış ve Lojistik regresyon, SVM ve yapay sinir ağı ile değerlendirilmiştir (Yıldız ve ark., 2020). 5512 görüntüden oluşan veri setinde, plus – not_plus ayrımında model AUC %94 elde etmiş; pre-plus ve normal ayrımında ise AUC %88 bulunmuştur.

2023 yılında Bai ve arkadaşlarının yaptığı çalışmada ROP.AI adı verilen bir derin öğrenme algoritması, plus hastalığı tespitinde Avustralya'daki 5 farklı merkezden elde edilen görüntülerle çok merkezli olarak doğrulanmıştır. Mayıs 2021 – Şubat 2022 arasında toplanan 8052 retina görüntüsü modele yüklenmiş ve model çıktılarına 5 uzmandan birinin tanısı referans alınarak performans ölçülmüştür. Plus hastalığı tanısında modelin AUC değeri 0.75 olup, duyarlılık %84, özgüllük %43 ve negatif prediktif değeri %96

olarak bulunmuştur (Bai ve Ark., 2023). Modelin, plus hastalığını yakalayabildiği ancak özgüllüğün düşük kaldığı tespit edilmiştir.

Wang ve Zang' ın (2021) Çin'de yaptıkları çalışmada ise, prematüre bebeklerin geniş açılı retina görüntülerinden çok boyutlu bulgular çıkartıp ROP' u tespit eden otomatik bir derin öğrenme platformu geliştirilmiştir. Dört farklı merkezden 52.249 fundus görüntüsü eğitime dahil edilmiş; sistem, 5 ayrı sınıflandırıcı kullanarak her görüntüyü analiz etmiş ve bu sonuçları entegre ederek sevk kararını otomatik üretmiştir. Modelin test sonuçlarında AUC %99–99,6 gibi çok yüksek değerlere ulaşmış, uzmanlarla uyum Cohen kappa değeri 0,86–0,98 olarak belirlenmiştir (Wang ve Zang, 2021).

Yenice ve arkadaşları (2024) Türkiye'de yaptıkları çalışmada ise, ROP' un tiplerinin ve evrelerinin sınıflandırılması amacıyla RegNetY002 konvolüsyonel sinir ağı (CNN) mimarisi kullanılarak bir model geliştirilmiştir. 317 bebeğin 634 retinal görüntüsü ile eğitilen model, Tip 1 ve Tip 2 ROP ile A-ROP'u %98 doğrulukla ayırt etmiştir (Yenice ve Ark., 2024). Evre 2 ve 3 ROP ayırımı %90 doğrulukla yapılabilmektedir.

Jiang ve arkadaşları (2022) tarafından yapılan bir çalışmada, oftalmologlara yardımcı olmak için erken teşhis ve kantitatif analiz sağlayan otomatik bir DCNN tabanlı sistem geliştirilmesi ve evre I-III ROP' un özellik parametrelerinin sunulması amaçlanmıştır. Çin'deki prematüre bebeklerden elde edilen 18.827 retinal görüntüden oluşan bir veri seti kullanılmıştır. Retinal kan damarlarının segmentasyonu için iki açık kaynaklı Retina U-Net kullanılmıştır. Ardından, ROP evrelerini (normal, I, II, III) sınıflandırmak için DenseNet sınıflandırıcısı eğitilmiştir. Sınıflandırıcı, doğruluk oranları duyarlılık %90, özgüllük %97 olarak ölçülmüştür (Jiang ve ark.,2022). Çıkarılan kantitatif özelliklerde farklı ROP evreleri arasında istatistiksel olarak anlamlı farklılıklar bulunmuştur. Sistem tarafından çıkarılan özelliklerin klinik teşhislerde, özellikle daha az deneyimli oftalmologlar arasında teşhis tutarlılığını önemli ölçüde artırdığını belirtmişlerdir.

Peng ve arkadaşları (2022) tarafından yapılan bir çalışmada, retinopati prematüresinin otomatik tespiti ve 3 seviyeli ROP derecelendirmesi için yeni bir dikkat-farkındalık ve derin denetim tabanlı ağ (ADS-Net) önerilmiştir. ADS-Net, fundus görüntülerindeki yerel fazlalık ve karmaşık küresel bağımlılık sorunlarını dengelemek için kendi kendine dikkat

mekanizmasına dayalı bir Çok Anlamalı Özellik Toplama (MsFA) modülü ve derin denetimli kayıp stratejisi içermektedir. Ağ, ROP taraması (Normal- ROP) ve 3 seviyeli ROP derecelendirmesi (Hafif, Orta, Şiddetli) için görüntü bazında ve muayene bazında stratejiler kullanılarak Guangzhou Kadın ve Çocuk Sağlığı Merkezi'nden iki veri seti üzerinde değerlendirilmiştir. Görüntü bazında sınıflandırmada, ROP teşhisi için %95,52 ve ROP derecelendirmesi için %90,37 değerlerini elde etmişlerdir (Peng ve ark., 2022).

Huang ve arkadaşları (2020) tarafından yapılan bir çalışmada, derin bir evrimsel sinir ağ kullanarak erken evre ROP' u (ROP yok, evre 1 ROP veya evre 2 ROP) otomatik olarak tespit edilmesi ve sınıflandırılması amaçlanmıştır. Bu çalışmada 11372 retinal fundus görüntüsü analiz edilmiştir. Derin bir CNN uygulanmış ve 10.235 görüntü üzerinde beş kat çapraz doğrulama ile eğitilmiş, 1.137 görüntü doğrulama ve 244 görüntü test için kullanılmıştır. Modelin performansı doğruluk, duyarlılık ve özgüllük kullanılarak değerlendirilmiştir. Model, eğitim sırasında ortalama %99,93 ve test sırasında %92,23 doğruluk elde etmiştir (Huang ve ark., 2020). Bu çalışmalardaki sonuçlara bakıldığında, derin öğrenme ağlarının erken evre ROP' un doğru tespiti için potansiyelini güçlendirmektedir. Otomatik erken tespit sistemleri, ROP tarama programlarına entegre edilerek yakından izleme veya erken tedavi gerektiren bebeklerin belirlenmesinde verimliliği artırabilir.

Zhang ve arkadaşlarının (2018) tarafından yapılan bir çalışmada, geniş açılı retinal görüntüler kullanılarak transfer öğrenimi yoluyla ROP' un otomatik taranması için bir derin sinir ağı performansının değerlendirilmesi amaçlanmıştır. ROP taramasından elde edilen 420365 geniş açılı retinal görüntüden oluşan büyük bir veri seti kullanılmıştır. Etiketlenmiş eğitim seti (8090 pozitif, 9711 negatif görüntü), transfer öğrenimi için üç sınıflandırıcı AlexNet, VGG-16 ve GoogleNet kullanılmıştır. Elde edilen sınıflandırıcılar 1742 örnekten oluşan bir test veri seti üzerinde değerlendirilmiş ve beş bağımsız pediatrik retinal oftalmolog ile karşılaştırılmıştır. VGG-16 modeli, kesinlik-geri çağırma eğrisinde F1 skorunu maksimize eden kesme noktasında %98,8 doğruluk, %94,1 duyarlılık, %99,3 özgüllük ve %93 kesinlik ile en iyi performansı göstermiştir. Bu çalışma, özellikle transfer öğrenimi teknikleriyle derin öğrenmenin, otomatik ROP taraması için yüksek doğruluk elde etmede etkili olduğuna dair daha fazla kanıt sunmaktadır.

Bharath ve arkadaşları (2023) tarafından Hindistan’da yapılan bu çalışmada ise 11 yıllık bir süre boyunca toplanan 227326 geniş açılı görüntüden oluşan geniş bir veri seti kullanılarak derin öğrenme algoritması geliştirilmiştir. Algoritma, ImageNet üzerinde önceden eğitilmiş EfficientNet-B0 mimarisini kullanan, ROP’ un varlığını (Evre 1-3) ve yokluğunu ayıran ikili bir sınıflandırıcıdan oluşmaktadır. Bağımsız test seti sonucunda algoritma, ROP’ u tespit etmede %91,46, duyarlılık ve %91,22 özgüllük elde etmiştir. Yaptıkları çalışmalarının yetersiz hizmet alan bölgelerde ROP tarama kapsamını önemli ölçüde iyileştirebileceğini, bu bağlamda daha erken teşhis ve tedaviye ulaşılabilceğini belirtmişlerdir.

Tablo 2.1. Derin öğrenme ile yapılan çalışmaların karşılaştırılması

Çalışma	Amaç	Yöntem	Sonuç
Zhang ve ark., 2018	ROP’ un otomatik taranması için DNN performansını değerlendirmek	AlexNet, VGG-16, GoogleNet	%98.8 doğruluk VGG -16 modeli ile
Yıldız ve ark., 2020	Plus hastalığını otomatik teşhis etmek	Retina damar analizi ve makine öğrenmesi (LR, SVM, ANN)	AUC %94
Huang ve ark., 2020	Erken evre ROP’ u tespit etmek ve sınıflandırmak	CNN	AUC %92,23
Wang ve ark., 2021	ROP şiddetini çoklu bulgularla tespit etmek	52.249 görüntüyle 5 sınıflama	AUC %99
Jiang ve ark., 2022	Evre I-III ROP’ u teşhis etmek	U-Net, DenseNet	%90 duyarlılık, %97 özgüllük
Peng ve ark., 2022	ROP’ u tespit etmek ve 3 seviyede derecelendirmek	ADS-Net	AUC %95,52
Bai ve ark., 2023	Yapay zeka ile plus hastalığını çok merkezli değerlendirmek	Derin öğrenme modeli ile 8052 retina görüntüsü analizi	AUC %75, %84 duyarlılık %43 özgüllük
Bharath ve ark., 2023	Güney Hindistan popülasyonunda ROP’ u tespit etmek için bir yapay zeka tarama aracı geliştirmek	EfficientNet-B0	%91,46 duyarlılık, %91,22 özgüllük,
Yenice ve ark., 2024	ROP tip ve evrelerinin ayrımı	RegNetY002 CNN ile 634 görüntü	AUC %98 Tip Ayrımı, AUC %90 Evre Ayrımı.


Bu çalışmalarda, ROP teşhisinde kullanılan mevcut yöntemlerin çoğunlukla hastalığın mevcudiyetini saptamaya yönelik olduğu ve evreleme ya da tip belirleme konusunda sınırlı kaldığı gözlemlenmiştir. Ancak, ROP hastalığının farklı evreleri (Normal, ROP1 ve ROP2) arasında sınıflandırma yapılması, tanı ve tedavi süreçlerinde daha önemli kararlar alınmasına olanak sağlayacaktır. Bu bağlamda, çalışmamız, derin öğrenme yöntemlerini kullanarak ROP’ u üç farklı kategoride (Normal, ROP1, ROP2)

sınıflandırmayı amaçlamaktadır. Bu yaklaşım, mevcut literatürdeki eksiklikleri gidermeyi hedeflerken, daha ayrıntılı bir teşhis sistemi geliştirilmesine katkı sağlamaktadır. Sınıflandırma doğruluğunu artırmak adına optimize edilmiş CNN modelleri kullanılmıştır. Literatür incelendiğinde, çalışmalarda kullanılan görüntülerin yerel göz kliniklerinden elde edildiği gözlemlenmiştir. Bu çalışmada da ham retina görüntüleri kullanılarak model geliştirilmiştir. Modelin özgün veriyle eğitilmiş olması klinik karar destek sistemlerinin geliştirilmesine katkı sağlamaktadır.



3. GEREÇ ve YÖNTEM

Sistem 4 aşamada gerçekleştirilmiştir (Şekil 3.1). (1) Retcam cihazı ile görüntünün elde edilmesi (2) Bu görüntünün iyileştirilmesi (3) Görüntüden sınıflandırma için gerekli özelliklerin çıkartılması (4) ROP sınıflandırması için derin öğrenme modellerinin uygulanması (5) ROP 'un sınıflandırılması.




Şekil 3.1. Sistemin ana akış şeması

3.1. Retcam cihazı ile görüntünün elde edilmesi

Çalışmanın ilk aşamasını Akdeniz Üniversitesi Tıp Fakültesi Göz Hastalıkları Anabilimdalı Bölümünde ROP muayenesine başvuran bebeklerden Retcam cihazı ile Retina görüntüleri elde edilmiştir. Bu aşamada etik ilkeler açısından gerekli tüm izinler alınacak ve görüntülerden bir veri tabanı oluşturulmuştur. Çekimler sırasında standart bir prosedür izlenerek olgunun üzerinde minimum gürültü olmasına dikkat edilecektir. Her bebeğin iki gözünden de retina görüntüleri alınmıştır. Şekil 3.2.'de örnek bir retina görüntüsü yer almaktadır.



Şekil 3.2. Örnek Bir retina görüntüsü



Şekil 3.3. Görüntülerin döndürülerek çoğaltılması


Ham retina görüntüleri aşırı karanlık ya da parlaklık durumuna göre bir filtreden geçirilip, bu görüntüler eğitime dahil edilmemiştir. Bazı sınıfların görüntü sayılarının az olmasından dolayı görüntüleri çoğaltmak için görüntü sayısına göre döndürme işlemi gerçekleştirilmiştir. Burada görüntü sayılarının birbirine yakın olması amaçlanmıştır. Şekil 3.3.'de görüntülerin döndürülerek çoğaltılması gösterilmektedir. Buna göre ROP0(normal) görüntüler 15 derece açıyla döndürülerek 370 görüntü, 8880'e, ROP1 görüntüleri de 2391 veri 90 derece açıyla döndürülerek 9564 görüntüye çoğaltılmıştır.

3.2. Görüntünün iyileştirilmesi

Görüntü iyileştirme alanında uygulanan tekniklerin hedefi, görüntünün niteliğini artırmaktır. Kontrast ve parlaklık ayarlaması, gürültü azaltma, kenar belirleme, histogram işlemleri gibi uygulamalar en temel görüntü iyileştirme teknikleridir.

3.2.1. Histogram İşlemleri

Bir görüntü histogramı, sayısal bir görüntünün parlaklık ve ton dağılımını görselleştirerek temel özellikleri hakkında bilgi sağlayan bir grafikdir. Histogram, görüntüdeki her bir parlaklık veya renk değerinin frekansını gösterir ve görüntünün genel parlaklık durumu ile tonal yapısı hakkında çıkarımlar yapılmasına olanak tanır. Histogram genellikle 256 elemanlı bir dizi veya vektör olarak ifade edilir. Yatay eksen, piksel yoğunluk değerlerini (0-255 aralığında) temsil ederken, dikey eksen bu yoğunluk değerlerinin frekanslarını gösterir. Böylece, bir görüntünün parlaklık ve kontrast karakteristikleri nicel olarak analiz edilebilir (Gonzalez ve Woods, 2002; William, 2001).



Şekil 3.4. Yatay ve Düşey Histogramlar (Şevik, 2007)

Şekil 3.4.' te yer alan yatay ve dikey toplam histogramlar, görüntüdeki parlaklık değerlerinin yatay ve dikey eksenler boyunca kümülatif dağılımını istatistiksel olarak göstermektedir. Yatay Toplam Histogram (YTH), her bir yatay satırdaki piksel yoğunluk değerlerinin toplamından oluşurken, Dikey Toplam Histogram (DTH) her bir dikey sütundaki piksel yoğunluk değerlerinin toplamını ifade eder. Bu histogramlar, görüntü üzerindeki yoğunluk dağılımının analizi için kullanılır ve yoğunlukların yüksek olduğu bölgelerin tespit edilmesini sağlar. Özellikle, belirgin yoğunluk değeri taşıyan dokuların veya lezyonların segmentasyonu için faydalı bir referans çerçevesi sunar.

3.2.2. Görüntü Filtreleme Algoritmaları

Filtreleme işlemi, resmin üzerinde 3×3 , 9×9 vb. gibi bir karesel matrisi resim üzerinde harekete ettirerek ya da komşuları ile arasında matematiksel ya da mantıksal ilişkilendirmeler yaparak, her piksel değerinin yeniden hesaplanmasıdır. Filtreleme sayesinde kenar keskinleştirme, görüntü üzerinde netleştirme, görüntüyü yumuşatma, ayrıntıları ortaya çıkarma veya kenar bulma gibi işlemler gerçekleştirilir (Zangana ve ark., 2024).

1-Ortalama Filtresi: Bir görüntüdeki her piksel değeri, komşu piksellerin yoğunluklarının ortalaması alınarak yeniden hesaplanır. Bu işlem, görüntüdeki gri tonlar arasındaki keskin geçişlerin azalmasına ve daha yumuşak geçişlerin oluşmasına neden olur. Ancak bu süreç, görüntü üzerindeki kenar bölgelerinde bulanıklaşma (blur) etkisine yol açabilir. Bu tür bir filtreleme, genellikle düşük frekanslı bileşenlerin vurgulanması ve görüntüdeki yüksek frekanslı (keskin) detayların baskılanması amacıyla kullanılır.

2-Median Filtre: Bu filtreleme yönteminde, bir pikselin değeri, çevresindeki komşu piksellerin sıralanmış değerleri arasından seçilen ortanca değer ile değiştirilir. Bu yöntem, ağırlıklı ortalama filtrelerinden farklı olarak, sıralama işlemine dayalı bir değer seçimi yapar. Ortanca filtrede, komşuluk penceresi içerisindeki piksel yoğunluk değerleri önce sıralanır ve ardından sıralamanın ortasında yer alan değer seçilerek yeni piksel değeri olarak atanır. Ortanca değer doğru şekilde belirlenebilmesi için genellikle tek sayıda komşu kullanılır. Ancak, çift sayıda komşu olması durumunda,

sıralanan iki ortanca değerin aritmetik ortalaması alınarak yeni piksel değeri belirlenir. Bu filtreleme yöntemi, özellikle tuz-biber tipi gürültünün azaltılmasında etkili bir teknik olarak kullanılır.

3-Gaussian Filtre: Ortalama filtrelemenin, Gaussian dağılımı kullanılarak optimize edilmiş bir versiyonu olan Gaussian filtresi, görüntü işlemede sıklıkla kullanılan bir yöntemdir. Gaussian filtre, teorik olarak sonsuz bir transfer fonksiyonuna sahipken, mekansal alanda sonlu bir pencere (tarama penceresi) içerisinde uygulanır. Bu yaklaşım, filtrelemenin hesaplama problemlerini daha yönetilebilir hale getirir. Gaussian yumuşatma işleminin bir diğer avantajı, filtrelemenin önce yatay eksen, ardından elde edilen sonuçla dikey eksen üzerinde uygulanabilmesidir. Bu özellik, işlem süresini ve karmaşıklığını azaltarak daha verimli bir sonuç elde edilmesini sağlar.

4-Unsharp Filtresi: Görüntüdeki ayrıntıları ve keskin geçişleri daha belirgin hale getirmek, bulanık görüntülerde kaybolan detayları yeniden ortaya çıkarmak için kullanılan bir görüntü işleme tekniğidir. Bu yöntem, genellikle endüstriyel ve askeri uygulamalarda, tıbbi görüntüleme çalışmalarında ve diğer birçok alanda detayların iyileştirilmesi amacıyla yaygın olarak kullanılmaktadır. Unsharp filtresi, bir görüntünün düşük frekanslı (bulanık) versiyonunu çıkararak yüksek frekanslı (keskin) bileşenleri vurgular ve bu şekilde görüntünün netliğini artırır.

3.2.3. Kenar Bulma Algoritmaları

1.Sobel algoritması

Sobel algoritması, görüntülerdeki kenarların tespit edilmesine olanak sağlayan bir kenar algılama yöntemidir (Shamshad ve ark., 2023). Bu yöntem, görüntü içerisindeki belirli nesnelerin algılanması ve işlenmesi için temel bir adımdır. Sobel algoritmasında, iki adet konvolüsyon kerneli kullanılmaktadır. Biri yatay kenarları, diğeri ise dikey kenarları belirlemek için kullanılır. Bu kerneller, görüntüde ışık yoğunluğunun ani değişim gösterdiği bölgeleri tespit eder ve böylece kenarları belirlemeye yardımcı olur. Sobel algoritması, temelde bir türev yaklaşımı olarak düşünülebilir.

Gradyanlar, kernellerin uygulanmasıyla hesaplanan yoğunluk değerleridir ve her piksel için ayrı ayrı belirlenir. Daha sonra, gradyanların büyüklükleri hesaplanarak kenarlar belirlenir. Gradyan büyüklüğü, iki gradyanın (yatay ve dikey) karelerinin toplamının karekökü ile elde edilir. Bu işlem, görüntüdeki kenarların hassas ve doğru bir şekilde algılanmasını sağlar. Sobel algoritması, özellikle görüntü işlemeye dayalı projelerde kenar tespiti için sıklıkla tercih edilir.

1	0	-1
2	0	-2
1	0	-1
Yatay Sobel Kernel		

1	2	1
0	0	0
-1	-2	-1
Dikey Sobel Kernel		

Şekil 3.5. Yatay ve Dikey Kerneller

2. Canny algoritması

Canny yöntemi, kenar tespiti için birinci ve ikinci türevleri etkin bir şekilde kullanarak optimize edilmiş bir algoritmadır (Canny, 1986). Bu yöntem, Gaussian gürültü ile bozulan adım kenar modelini temel alır ve temel olarak gradyan tabanlı bir yaklaşım sergilemesine rağmen, Laplacian özelliklerinden de yararlanır.

Gaussian'ın birinci türevi, kenar tespiti için optimal sonuçlar üretirken, yumuşatma işlemi gürültünün etkisini azaltır. Çift eşikleme tekniği ise, kenarların daha iyi tanımlanmasını ve gürültü kaynaklı hataların minimuma indirilmesini sağlar. Bu yaklaşım, özellikle hassas kenar tespiti gerektiren görüntü işleme uygulamalarında yüksek doğruluk oranı ile öne çıkar.

Görüntü, gürültüyü azaltmak için Gaussian filtresi ile yumuşatılır. Yumuşatılmış görüntüde gradyan genliği ve yönü belirlenir. Gradyan değerleri, 3x3'lük bir komşuluk içerisinde analiz edilerek, maksimum değere karşılık gelmeyen noktalar bastırılır. Bu işlem, kenar noktalarının daha hassas bir şekilde belirlenmesini sağlar. Kalan pikseller, üst ve alt olmak üzere iki eşik değeri ile işlenir. Üst eşik değerini aşan pikseller doğrudan kenar olarak kabul edilirken, alt eşik değerini aşan pikseller, yalnızca

komşuluğunda üst eşik değerini geçen pikseller bulunduğunda kenar olarak değerlendirilir (Canny, 1986).

3- Laplacian algoritması

Laplacian algoritması, görüntünün ikinci türevini hesaplayarak ince detayların ve kenarların tespiti için kullanılan bir yöntemdir (Ziou ve Tabbone, 1993). Birinci türev, genellikle görüntüde kalın kenarlar üretirken, grilik seviyesindeki ani basamak değişimlerine kuvvetli bir yanıt verir. Buna karşın, ikinci türev, ince kenarları, küçük gürültü noktalarını ve diğer ince detayları daha iyi yakalayarak daha hassas sonuçlar sağlar. Ayrıca, ikinci türev, grilik seviyesindeki bir basamak değişimine çift yanıt verir; bu, birinci türevin tek yanıtına göre daha detaylı bir analiz sunar.

Birinci türevin çizgilere veya noktalara verdiği yanıt sınırlı iken, ikinci türev bu yapıların algılanmasında daha yüksek duyarlılığa sahiptir. Örneğin, bir çizgiye verilen yanıt, basamak değişimine verilen yanıtın daha güçlüdür, bu da ince detayların daha net bir şekilde tespit edilmesine olanak tanır.

Bu durum, bir cismin hızını bilmek yerine ivmesini bilmekle karşılaştırılabilir; ivme, hareketin ayrıntıları hakkında daha fazla bilgi sağlar. Benzer şekilde, Laplacian algoritması da ikinci türevi kullanarak görüntüdeki detayları ve ince özellikleri daha iyi anlamamıza yardımcı olur. Bu özelliği sayesinde Laplacian, kenar tespiti ve detay analizi gerektiren uygulamalarda etkili bir yöntemdir.

İki değişkenli görüntü fonksiyonu $f(x,y)$ için basit bir türev operatörü:

$$\Delta^2 f = \frac{\delta^2 f}{\delta x^2} + \frac{\delta^2 f}{\delta y^2} \quad (1)$$

Denklemiyle verilir. x-yönünde kısmi ikinci türevi,

$$\frac{\delta^2 f}{\delta x^2} = f(x + 1, y) + f(x - 1, y) - 2f(x, y) \quad (2)$$

y-yönünde kısmi ikinci türevi,

$$\frac{\delta^2 f}{\delta y^2} = f(x, y + 1) + f(x, y - 1) - 2f(x, y) \quad (3)$$

ile hesaplanır. İki boyutlu Laplacian operatörünün sayısal hesaplaması yukarıda verilen iki bileşenin toplanmasıyla elde edilir:

$$\Delta^2 f = [f(x+1, y) + f(x-1, y) + f(x, y+1) + f(x, y-1)] - 4f(x, y) \quad (4)$$

Laplacian, bir türev operatörü olarak, görüntüdeki grilik seviyesi süreksizliklerini vurgulayan ve grilik seviyesinin yavaş değiştiği alanların etkisini azaltan bir yöntemdir. Bu özellik, Laplacian operatörünün görüntü analizi ve kenar tespiti süreçlerinde güçlü bir araç olmasını sağlar.

Bir görüntüye Laplacian operatörü uygulandığında, sonuç olarak kenar çizgileri ve diğer süreksizliklerin belirgin şekilde öne çıktığı, geri kalan homojen bölgelerin ise siyah arka plan şeklinde görüldüğü bir görüntü elde edilir. Bu, Laplacian operatörünün grilik seviyesinde ani değişimlere duyarlı olmasından kaynaklanır.

Dolayısıyla, çıkış görüntüsünde, kenarlar ve süreksizlikler, griye veya açık tonlara yakın olarak belirginleşir. Homojen bölgeler ise siyah arka plan olarak görünür ve vurgulanmaz.


3.3. Öznitelik Çıkarma

Öznitelik, bir görüntüye ait ölçülebilir veya gözlenebilir bilgi olarak tanımlanabilir. Öznitelik çıkarımı, görüntüde bulunan ilgisiz veya gereksiz bilgileri eleyerek, yalnızca karakteristik ve anlamlı özelliklerin elde edilmesini hedefleyen bir süreçtir. Temel olarak, bu işlem bir boyut indirgeme tekniği olarak kabul edilebilir.

Görüntü işleme uygulamalarında kullanılan veriler genellikle yüksek boyutludur ve bu verilerin orijinal halleriyle işlenmesi, işlem süresi ve hesaplama maliyetlerini önemli ölçüde artırır. Öznitelik çıkarımı, verinin gereksiz ve aşırı bilgi taşıyan kısımlarını ayıklayarak, önemli özellikleri korur ve veri boyutunu küçültür. Böylece, işleme süresi azalırken model performansı ve doğruluğu artar.

Şekil 3.6'da öznitelik çıkarma yöntemleri ile orijinal verideki gereksiz bileşenler çıkarılarak, karakteristik özelliklerin daha düşük boyutlarda temsil edilmesi sağlanır. Bu süreç, görüntü işleme ve makine öğrenimi gibi alanlarda, özellikle verinin

işlenebilirliğini artırmak ve hesaplama maliyetlerini düşürmek açısından kritik öneme sahiptir (Gunal,2001).



Şekil 3.6. Öznitelik çıkarma yöntemleri (Günel, 2001)

3.3.1. Yönlendirilmiş Gradyanların Histogramı (HOG, Histograms of Oriented Gradients)

HOG yöntemi, piksellerin yönelim ve büyüklük özelliklerini karakterize eden bir yöntem olarak, nesne ve örüntü tanıma alanında yaygın bir şekilde kullanılmaktadır. Yöntem, farklı koşullar altında yüksek performans göstermesi nedeniyle birçok araştırmacının ilgisini çekmiştir. İlk kez Shashua (Shashu, 2004) tarafından önerilen HOG, imgeyi bir grup lokal histogram olarak tanımlamayı amaçlar. Bu histogramlar, bir imgenin lokal bölgelerindeki gradyan yönelimlerinin dağılımını ifade eder (Karakaya ve ark., 2009).

HOG yönteminin temel amacı, bir görüntüdeki şekil ve kenar bilgilerini yönelim bazlı histogramlarla temsil ederek, belirli bir nesnenin veya örüntünün karakteristik özelliklerini ortaya çıkarmaktır.

RGB formatındaki görüntü, gri seviyeli bir görüntüye dönüştürülür. Ardından, bu görüntü üzerinde yatay ve dikey gradyan değerleri hesaplanır. Yatay ve dikey gradyan değerlerinden faydalanılarak, her bir pikselin gradyan yönelimi ve büyüklüğü hesaplanır. Gradyan yönelimlerinden oluşan görüntü, hücre adı verilen küçük bölgelere

ayrılır. Her hücre içindeki gradyan yönelimleri, 45° aralıklarla 8 farklı yön sınıfına etiketlenir. Her bir hücre için gradyan yönelimleri ve büyüklük değerleri kullanılarak lokal histogramlar oluşturulur. Bu histogramlar, hücre içindeki gradyan dağılımını ifade eder. Oluşturulan lokal histogramlar, farklı aydınlatma ve kontrast koşullarına karşı duyarlılığı azaltmak amacıyla normalize edilir.

3.3.2. Hough Dönüşümü

Hough dönüşümü, sayısal görüntülerde doğruların ve diğer geometrik şekillerin tespit edilmesinde sıklıkla kullanılan bir görüntü analiz yöntemidir. İlk olarak siyah-beyaz görüntülerde düzgün doğruları algılamak amacıyla geliştirilmiş olan bu yöntem, zamanla doğrusal olmayan eğriler ve diğer düzensiz şekillerin tespiti için de uygulanmaya başlamıştır.

Hough dönüşümü, bir görüntüden tespit edilebilecek şekiller arasında düzgün doğrular, eğriler, çemberler, elipsler ve doğrusal olmayan keyfi şekillerin yer almasını sağlar. Ancak, her bir şekil tipi için farklı parametrik modeller ve denklemler kullanılarak algılama gerçekleştirilir. Özellikle dönüşüm işlemi sırasında görüntüdeki düzgün doğrular elenir ve çıktı görüntüsünde yalnızca doğrusal olmayan şekiller (örneğin daireler ve eğriler) yer alır. Bu özellik, Hough dönüşümünün, geometrik şekillerin ayrı ayrı analizi ve sınıflandırılmasında etkili bir yöntem olarak kullanılmasını sağlar (Safran, 2007).


3.3.3. Otoregresif model

Bu model de nesnenin sınırının tek boyutlu işaretlenmesinde merkezsel uzaklığın kullanımına dayanmaktadır. Algoritma görüntü içindeki nesnenin merkez noktasının tespiti ile başlar. Daha sonra nesnenin kenarını oluşturan her bir noktanın merkeze göre öklit uzaklığı bulunur. Bu işlemler için aşağıdaki formüllerden faydalanılır.

$$X_g = \frac{\sum_x \sum_y f(x,y) \cdot x}{\sum_x \sum_y f(x,y)} \quad Y_g = \frac{\sum_x \sum_y f(x,y) \cdot y}{\sum_x \sum_y f(x,y)} \quad (5)$$

$$d(i) = \sqrt{(x_i - X_g)^2 + (y_i - Y_g)^2}$$


Eğer $f(x,y)$ nesneye ait ise 1 değerini, değilse 0 değerini alır. Böylece açığa bağlı olan değişimler bulunmuş olur. Şekil 3.7. 'de değişim görülmektedir. Elde edilen değerler vektör formunda yazılarak öznitelik vektörü elde edilir (Günel, 2011).



Şekil 3.7. Nesnenin merkezine göre kenar uzunluklarının değişimi.

3.3.4. Poligonal yaklaşım

Poligonal yaklaşımın temelinde, nesneye ait kritik noktaların hesaplanması yatmaktadır. Kritik noktaların tespitini sağlayan algoritmanın tanımı kısaca şu şekilde verilmektedir: Nesnenin üst sol sınır pikseli ile alt sağ sınır pikseli başlangıç noktaları olarak alınır. Bu iki nokta arasında bir doğru çizilir. Daha sonra doğruya, dik doğrular saptanır. Bu doğruların kenar piksellerini kestiği noktalar belirlenip, bu parçalarının uzunluğu hesaplanır. Belirli bir eşikleme değerinin üstündeki noktalar, referans noktalar olarak tespit edilir. Bu noktaların tek boyuta indirgenmesi ile öznitelik vektörü oluşturulur. Şekil 3.8.'de örnek olarak alınan nesne kenarı üzerinde kritik noktaların bulunuşu gösterilmektedir (Gunal, 2011).



Şekil 3.8. Poligonal yaklaşım ile nesnenin kritik noktalarının bulunması.


Yukarıdaki şekilde, verilen nesne kenarına poligonal yaklaşım uygulanarak nesnenin kritik noktaları tespit edilmiştir. Bu yaklaşım şu şekilde uygulanmaktadır;

- Nesne üzerinde iki nokta seçilir.
- Bu iki nokta arasında bir doğru çizilerek, nesne kenarının üzerindeki noktaların bu doğruya olan izdüşüm uzaklıkları hesaplanır.
- Bu izdüşüm uzaklıklarından maksimum olanı seçilir. Bulunan bu maksimum uzaklık verilen eşik uzaklık değerinin üstünde ise nesnenin bu noktası kritik nokta (nesne köşesi) olarak alınır.
- Başlangıç noktasından başlanarak nesne köşeleri sırayla ardışık olarak birbirine doğru ile bağlanır.
- Nesne kenarlarının bu yeni çizilen doğrular üzerindeki izdüşümlerine olan uzaklıkları tekrar hesaplanır ve 3, 4, 5. adımlar, verilen eşik değerinden küçük veya eşit olana kadar tekrarlanır.


Bu işlemler sonucunda nesne sınır çizgisine yakın küçük doğru parçalarından oluşan yeni bir nesne kenarı elde edilir. Bu küçük doğrular kritik noktaların birleştirilmesi ile elde edilir. Kritik noktalardan oluşan nesneye ait özellikler bir vektör halinde yazılarak nesnenin öznitelik vektörü elde edilir.

3.3.5. Zincir kodları

Sayısal bir görüntü, kenar çıkarma işlemine tabi tutulduğunda yalnızca nesnenin dış hatları belirgin şekilde kalır. Bir sonraki aşamada, bu kenar bilgilerinin uygun bir şekilde kodlanması gerekmektedir. Bu amaçla, zincir kodlama yöntemleri kullanılabilir. İki tip zincir kodlama şekli mevcuttur; dörtlü ve sekizli zincir kod (Şekil 3.9.).



Şekil 3.9. a) Dörtlü zincir kod b) Sekizli zincir kod




Şekil 3.10. Verilen sayısal görüntünün sınırlarının dörtlü zincir kod gösterimi.

Şekil 3.10' da verilen sayısal görüntünün sınırlarının dörtlü zincir kod gösterimi yer almaktadır. Buna göre verilen nesnenin öznitelik vektörü şu şekilde oluşur.

$$V = [0\ 0\ 3\ 0\ 0\ 3\ 3\ 3\ 2\ 1\ 2\ 2\ 3\ 2\ 2\ 1\ 1\ 0\ 1\ 1]$$

Nesnenin kenar bilgilerini daha hassas bir şekilde kodlamak için sekizli zincir kod kullanılması daha iyi sonuç verir. Şekil 3.11.'de buna ilişkin bir örnek verilmiştir.



Şekil 3. 11. Verilen nesnenin sınırlarının sekizli zincir kod ile kodlanması

Bu nesnenin öznitelik vektörü ise şu şekilde oluşur;

$$V = [7\ 7\ 7\ 7\ 4\ 4\ 4\ 4\ 2\ 2\ 2\ 2]$$

Sekizli zincir kodu, dörtlü zincir koduna kıyasla en önemli avantajı olarak, yatay ve dikey kenar çizgilerinin yanı sıra çapraz kenar çizgilerini de tespit edebilme imkânı sunar. Zincir kodları ile nesnenin kenarlarının yönü ve uzunluğu belirlendikten sonra, bu bilgilerden oluşturulan öznitelik vektörü üzerinde çeşitli işlemler uygulanarak daha küçük boyutlu ve farklı nesneler için daha genel bir vektör elde edilebilir. Öznitelik vektörü aşağıdaki gibi dizi haline getirilebilir.

$$V = [V_0, V_1, V_2, \dots, V_7]$$

Burada;

V_0 : Toplam köşe sayısı,

V_1 : En küçük kenarın en büyük kenara oranı,

V_2 : 0 - 45 derece arasında ki açılardan kaç tane olduğu,

V3 : 46 - 90 derece arasındaki açıların kaç tane olduğu,

V4 : 91 - 135 derece arasındaki açıların kaç tane olduğu,

V5 : -0 - -45 derece arasındaki açıların kaç tane olduğu,

V6 : -46 - -90 derece arasındaki açıların kaç tane olduğu,

V7 : -91 - -135 derece arasındaki açıların kaç tane olduğunu gösterir.

Elde edilen bu öznitelik vektörü, sonraki bölümlerde anlatılacak sınıflandırıcıların girişine verilerek nesne sınıflandırılması yapılabilir.

3.4. Sınıflandırma

Sınıflandırma aşamasının temel amacı, örüntüleri öznitelik uzayındaki konumlarına göre, minimum hata ile en uygun sınıflara eşleştirmektir (Zhang ve Wang, 2020). Bu süreçte, sınıflandırıcının başarısında iyi tanımlanmış bir öznitelik vektörü kritik bir rol oynar. Örüntü sınıflandırıcıları, genel olarak geleneksel ve akıllı yöntemler olmak üzere iki ana gruba ayrılabilir.

Geleneksel sınıflandırma algoritmaları, istatistiksel bir yapı olan Bayes karar teorisine dayanır. Ancak bu algoritmaların bazı dezavantajları bulunmaktadır. Örneğin, öznitelik uzayı sınıflandırma uzayına dönüştürülürken gürültü oluşabilir ve her bir sınıf için hata kriterleri açık bir şekilde tanımlanmayabilir. Geleneksel sınıflandırıcılara; çok değişkenli Gauss modelleri, en yakın komşu algoritmaları, maksimum olabilirlik, ikili ağaç sınıflandırıcıları ve Fisher'in doğrusal sınıflandırıcıları örnek olarak gösterilebilir.

Yapay Sinir Ağları (YSA), günümüzde yaygın olarak kullanılan ve başarısını ispatlamış güçlü bir sınıflandırma yöntemidir. Özellikle genelleme yetenekleri sayesinde örüntü tanıma uygulamaları için oldukça etkili bir araçtır.

YSA, beynin bilgi işleme yöntemlerini modellemek için tasarlanan bir sistem olarak tanımlanabilir. Beynin işlevsel süreçlerine benzer şekilde YSA, öğrenme sürecinden sonra bilgiyi toplar, bu bilgiyi hücreler arasındaki bağlantı ağırlıklarıyla saklar ve genelleme yeteneği gösterir. YSA, paralel dağılmış bir işlemci olarak çalışır ve öğrenme süreci, ağırlık

ağırlıklarının belirli bir hedefe ulaşmak üzere yeniden düzenlenmesini sağlayan öğrenme algoritmalarını içerir.

YSA' nın bu esnek ve güçlü yapısı, onu sınıflandırma, tahmin, örüntü tanıma ve çok çeşitli diğer uygulamalar için ideal bir araç haline getirir. Özellikle karmaşık veri kümeleriyle çalışırken, genelleme yeteneği sayesinde yüksek doğruluk oranları elde edilebilir.

Bu çalışmada ise sınıflandırıcı olarak, çok katmanlı sinir ağları olarak bilinen derin öğrenme modelleri tercih edilmiştir. Derin öğrenme karmaşık ilişkileri öğrenme ve bunları genelleme yeteneği ile tanınır.

3.4.1.Yapay Sinir Ağları


YSA, insan beyninin öğrenme, yeni bilgiler üretme, keşfetme ve mevcut bilgilerden yeni çıkarımlar yapabilme gibi işlevlerini otomatik olarak gerçekleştirmek amacıyla geliştirilen bilgisayar sistemleridir. İnsan beyninin fonksiyonel özelliklerini model alarak, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi alanlarda başarılı bir şekilde uygulanmaktadır.

Teknik açıdan, bir YSA' nın temel görevi, kendisine verilen bir girdi setine karşılık gelebilecek uygun bir çıktı setini belirlemektir. Bu amaçla, ağ, ilgili olayın örnekleri ile eğitilir ve bu eğitim süreci sonucunda genelleme yapma yeteneği kazanır.

Sinir ağı mimarilerinin verilere uygun hale getirilmesi için, ağın girişlerine uygulanacak verilerin yeterli sayıda olması ve bu verilerin uygun eğitim vektörlerine dönüştürülmesi gereklidir. Yetersiz sayıda veri ile eğitilen bir sinir ağı çalıştırıldığında yanlış teşhis riski taşır. Bu durum, ağın eğitim sürecinde kullanılan verilerin çeşitliliği ve kapsamı ile doğrudan ilişkilidir.

a) Derin Öğrenme Kavramları

Derin öğrenme, yapay zekanın bir alt dalı olan makine öğreniminin, büyük veri ve karmaşık hesaplama gücü sayesinde daha derin katmanlardan öğrenme yeteneği geliştiren bir alanıdır. Şekil 3.12’ de bu aşamalar gösterilmektedir.



Şekil 3. 12. Derin Öğrenme Aşamaları

Giriş Katmanı

Veri giriş katmanı, sinir ağlarında girdi verilerinin ağına iletilmesini sağlayan temel katman olarak tanımlanır. Sinir ağlarında kullanılacak veri seti, ağın mimarisi ve yapısına uygun olarak oluşturulmalıdır. Her bir örneklem, giriş katmanına girdi verisi olarak aktarılır ve ağın eğitimi için kullanılır.

Her bir örneklemin ardışık olarak işlenmesiyle bir veri seti oluşturulur. Bu veri setinin boyutu, sinir ağının çalışma hızını, test süresini ve bellek gereksinimlerini doğrudan etkiler. Daha büyük veri setleri, daha fazla hesaplama kaynağı ve depolama alanı gerektirirken, daha küçük veri setleri işlem süresini azaltabilir ancak ağın genelleme yeteneğini sınırlayabilir. Dolayısıyla, veri setinin boyutu ve yapısı, sinir ağının performansı üzerinde kritik bir rol oynar (Inik ve Ulker, 2017; Tamura vd., 1997).

Konvolüsyon katmanı

Konvolüsyon katmanı, CNN temel yapı taşıdır. Bu katman, giriş verisi üzerinde daha önceden belirlenmiş filtreler uygulayarak girdideki belirgin özellikleri çıkarma amacı taşır.

Filtreleme işlemi, filtrenin giriş verisi üzerinde belirli bir kaydırma adımıyla hareket ettirilerek gerçekleştirilir. Bu süreç, giriş verisinden anlamlı özellik haritalarının çıkarılmasını sağlar. Filtreleme işlemi sonucunda, giriş verisinden daha küçük boyutlara sahip bir çıktı matrisi elde edilir. Bu çıktı matrisi, orijinal girdinin daha özetlenmiş ve bilgi içeriği yoğunlaştırılmış bir temsilini oluşturur.

Konvolüsyon katmanının temel işlevi, verinin uzamsal ve yerel özelliklerini öğrenerek, görüntü veya diğer veri türlerindeki önemli yapı taşlarını ortaya çıkarmaktır. Bu özellik, konvolüsyonel sinir ağlarının özellikle görüntü işleme ve görüntü tanıma gibi uygulamalarda güçlü bir araç haline gelmesini sağlar (Ciresan ve ark., 2011).

Derin öğrenme algoritmalarında, farklı boyutlarda filtreler kullanılarak konvolüsyon işlemi gerçekleştirilir. Bu işlem, verideki belirgin özelliklerin çıkarılmasını ve ağın bu özellikleri öğrenmesini sağlar. Filtreleme işlemi, CNN temel bileşenlerinden biridir ve kullanılan filtre boyutları ağın performansını doğrudan etkiler. AlexNet mimarisinde 11x11 boyutunda filtreler kullanılmıştır. GoogleNet, VGGNet ve ResNet gibi derin öğrenme mimarilerinde ise daha küçük filtreler tercih edilmiştir (5x5, 3x3, 2x2, 1x1).

Genel olarak, bir $N \times N$ boyutundaki giriş matrisi üzerinde bir $M \times M$ boyutunda filtre uygulanır. Konvolüsyon işlemi sonucunda, giriş verisinin daha küçük bir boyutta temsili elde edilir. Bu süreç, verideki önemli özelliklerin sıkıştırılarak ağın daha iyi öğrenmesini sağlar.

Filtre boyutları, ağın eğitim süreci ve başarısı üzerinde kritik bir etkiye sahiptir. Büyük filtreler bilgi yakalayabilir ancak işlem maliyeti yüksektir. Küçük filtreler ise daha yerel özellikleri öğrenmeye odaklanır ve genellikle daha derin mimarilerde tercih edilir.

Doğru filtre boyutunun seçimi, ağın performansını optimize etmek için önemlidir. Konvolüsyon katmanında yapılan filtreleme işlemi, veriye ait özelliklerin daha etkili bir şekilde çıkarılmasını ve ağın bu özellikleri daha iyi öğrenmesini sağlar. Bu nedenle, kullanılan filtreler ve konvolüsyon işlemi, derin öğrenme mimarilerinin başarısında önemli bir rol oynamaktadır (Pang ve ark., 2017).

Havuzlama Katmanı

Havuzlama katmanı, genellikle sinir ağlarında giriş verilerinin boyutunu azaltmayı hedefler. Bu katman, veri üzerinde belirli bir filtreleme işlemi gerçekleştirerek ağın sonraki katmanlarına aktarılabacak veri boyutunu küçültür. Havuzlama işlemi sırasında bazı veri kayıpları meydana gelebilir; ancak veri boyutundaki azalma, ağın daha hızlı çalışmasını sağlar. Aynı zamanda, ağıdaki veri miktarının azalması hesaplama maliyetini ve bellek kullanımını da önemli ölçüde düşürür (Hinton vd., 2012).

Havuzlama katmanında işlem yapılırken uygun bir $N \times N$ boyutlu filtre kullanılır. Filtre, veri havuzu üzerinde kaydırılarak her bir konumda uygun değeri belirler ve yeni bir matris oluşturur.

En büyük değer havuzlamasında (Max pooling), $N \times N$ boyutundaki matris içerisindeki en büyük değer seçilir ve bu değer yeni matrisin 1×1 boyutundaki hücresini oluşturur. Bu yöntem, özellikle kenarlar ve nesne özellikleri gibi belirgin yapıları vurgulamak için sıklıkla tercih edilir. Ortalama havuzlamada, $N \times N$ boyutundaki matris içerisindeki tüm değerlerin ortalaması alınır ve bu değer yeni matrisin 1×1 boyutundaki hücresini oluşturur. Bu yöntem, daha genel ve yumuşak özellikler çıkarmak için kullanılır.

Tam Bağlı Katman

Tam bağlı katman, sinir ağlarındaki tüm nöronların bir dizi şeklinde düzenlendiği ve her nöronun bir önceki katmandaki tüm aktivasyonlara tam bağlantılı olduğu bir katmandır. Bu katman, ağın önceki katmanlarında çıkarılan özelliklere dayanarak sınıflandırma veya tahmin yapmasını sağlar.

Tam bağlı katmanın temel özelliği, bir önceki katmandaki tüm aktivasyon değerlerini dikkate alarak nesnelerin hangi sınıfa ait olduğunu belirlemektir. Örneğin, bir görüntüdeki belirli bir nesne tespit edilmek isteniyorsa, bu nesneyi temsil eden özellikler, aktivasyon haritalarında yüksek değere sahip olan nöronlarda yer alacaktır (Lin ve ark., 2013; LeCun ve Bengio, 1995).

CNN genellikle konvolüsyon katmanını takiben bir aktivasyon katmanı yer alır. Aktivasyon katmanı, sinir ağlarında doğrusal olmayan dönüşümleri gerçekleştiren ve ağın öğrenme yeteneğini artıran bir bileşendir. Aktivasyon fonksiyonları, giriş verilerini işleyerek çıktıyı belirli bir aralıkta sınırlayan matematiksel fonksiyonlardır.

Yapay sinir ağlarında yaygın olarak kullanılan aktivasyon fonksiyonları şunlardır:

- Sigmoid: Veriyi 0 ile 1 arasında sınırlar.
- Hiperbolik Tanjant (Tanh): Veriyi -1 ile 1 arasında sınırlar.
- Step (Basamak): Belirli bir eşik değerine göre çıktı üretir.
- Eşik Fonksiyonu (Threshold): Belirli bir eşik değerine bağlı olarak çıktı belirler.

Bununla birlikte, derin öğrenme mimarilerinde en yaygın kullanılan aktivasyon fonksiyonlarından biri ReLU (Rectified Linear Unit) fonksiyonudur. ReLU, $f(x) = \max(0, x)$ formülüyle ifade edilir ve giriş değeri negatifse 0, pozitifse değeri olduğu gibi aktarır. Bu fonksiyonun kullanım avantajları arasında hesaplama kolaylığı ve gradyan söndürme sorununa karşı dayanıklılığı bulunmaktadır (Krizhevsky ve ark., 2012).

ReLU'nun basit ve verimli yapısı, derin öğrenme modellerinde daha hızlı ve etkili bir öğrenme sağlamaktadır. Aktivasyon fonksiyonunun seçimi, ağın doğruluk oranını ve öğrenme başarısını doğrudan etkileyen kritik bir unsurdur.

Çok katmanlı yapay sinir ağlarında, ağın eğitim sürecinde aşırı öğrenme (overfitting) adı verilen istenmeyen bir durum ortaya çıkabilir. Aşırı öğrenme, ağın eğitim verilerini ezberlemesi ve bu nedenle genelleme yapma yeteneğini kaybetmesiyle sonuçlanır. Bu durumun önüne geçmek için Dropout adı verilen bir teknik kullanılmaktadır.

Dropout, sinir ağındaki bazı düğümlerin rastgele devre dışı bırakılmasını sağlayarak ağın ezberleme eğilimini azaltmayı hedefler. Bu yaklaşım, ağın farklı alt yapılar üzerinde öğrenmesini teşvik eder ve genelleme kapasitesini artırır (Srivastava ve ark., 2014). Dropout katmanı, özellikle tam bağlı katmanlar için bir düzenleme yöntemi olarak önerilmiş Hinton ve arkadaşları tarafından geliştirilmiştir.

Bu teknik, sinir ağıının normalleştirme yeteneğini artırdığı ve test performanslarını iyileştirdiği yapılan çalışmalarla gösterilmiştir (Hinton ve ark., 2012). Dropout uygulaması, ağıın eğitim sırasında düğümlerin bir kısmını rastgele devre dışı bırakarak modelin daha genel bir temsil oluşturmalarını sağlar ve böylece aşırı öğrenmenin önüne geçer. Bu yöntem, özellikle büyük ve karmaşık modellerde performans artırıcı bir düzenleme aracı olarak yaygın şekilde kullanılmaktadır.

Yumuşatma Katmanı

Yumuşatma katmanı, sinir ağlarında sınıflandırma katmanı olarak görev yapar. Kendinden önce gelen tam bağlı katmandan aldığı girdi verisini işleyerek, her bir sınıf için olasılık değerlerini hesaplar ve bu değerlere dayanarak sınıflandırma işlemini gerçekleştirir. Yumuşatma katmanı, bir girdinin belirli bir sınıfa ait olma olasılığını değerlendirir ve hangi sınıfa daha yakın olduğunu belirten bir olasılık skoru üretir. Yumuşatma katmanının eğitim sürecinde, modelin tahminleri ile gerçek değerler arasındaki farkı ölçmek için çapraz entropi kaybı kullanılır. Çapraz entropi, modelin yanlış tahminlere verdiği ağırlığı artırarak daha doğru tahminlere yönlendirilmesini sağlar (Tang, 2013).

Sınıflandırma katmanı

Sınıflandırma katmanı, sınıflandırılması yapılacak öge sayısı kadar çıktı üretir. Bu çıktılardan her biri bir sınıfı temsil eder ve modelin giriş verisinin hangi sınıfa ait olduğuna dair olasılık dağılımını sağlar.

Sinir ağlarında, son katman olarak bilinen sınıflandırıcı katman için farklı sınıflandırıcı türleri kullanılabilir, derin öğrenme mimarilerinde genellikle yumuşatma (softmax) sınıflandırıcı tercih edilmektedir (Ciresan, 2001).

Eğitim süresini azaltmanın ve ağıın performansını artırmanın etkili yollarından biri, nöron aktivasyonlarının normalize edilmesidir. Normalizasyon, genellikle ReLU katmanı sonrasında gerçekleştirilir (Li ve ark., 2015). Bu işlem, sinir ağıındaki verilerin belirli bir düzen içerisinde olmasını sağlar. Girdi verileri, çok büyük ya da çok küçük değerler içerebilir. Bu durum, ağıın öğrenme sürecini yavaşlatabilir veya dengesiz hale getirebilir.

Normalizasyon, bu tür değerleri belirli bir aralığa indirerek ağı daha verimli öğrenmesini sağlar. Toplu Normalizasyon (Batch Normalization) gibi yöntemler, verileri her minibatch içinde normalize ederek ağı daha hızlı ve daha kararlı bir şekilde öğrenmesini mümkün kılar (Ioffe ve Szegedy, 2015). Bu yöntem, gizli katmanlardaki aktivasyon değerlerini normalize ederken aynı zamanda modelin aşırı öğrenme riskini de azaltır.

CNN tabanlı modeller arasında AlexNet, GoogleNet, VGG16, VGG19, ResNet-50 ve Faster R-CNN gibi algoritmalar öne çıkmaktadır. Bu yapılar, görüntü işleme ve nesne tanıma gibi birçok alanda başarıyla uygulanmış ve yüksek doğruluk oranlarına ulaşmıştır. AlexNet, 25 katmandan oluşan ve giriş katmanında $227 \times 227 \times 3$ boyutundaki görüntüleri işleyebilen bir yapıya sahiptir (Krizhevsky ve ark., 2012). Bu algoritma, ImageNet veri tabanında yapılan testlerde %80 doğruluk oranına ulaşmıştır. AlexNet, derin öğrenmenin popülerlik kazanmasında önemli bir rol oynayan ilk CNN modellerinden biridir. GoogleNet, AlexNet'e kıyasla 12 kat daha fazla katman içeren bir mimariye sahiptir (Szegedy ve ark., 2015). Bu model, doğrusal aktivasyon fonksiyonlarını kullanarak daha karmaşık yapıları öğrenebilme kapasitesine sahiptir. ImageNet üzerinde yapılan testlerde, GoogleNet %93 doğruluk oranına ulaşmıştır ve derin öğrenme modelleri arasında önemli bir başarı elde etmiştir. VGG16, 13 konvolüsyon katmanı ve 3 tam bağlı katmandan oluşan bir ağ yapısına sahiptir (Simonyan ve Zisserman, 2014). ImageNet veri tabanında yapılan testlerde %89 doğruluk oranı gözlenmiştir (Chen ve ark., 2016). VGG19, VGG16'nın genişletilmiş bir versiyonudur ve toplamda 47 katmandan oluşur. Aynı veri tabanında yapılan testlerde %88 doğruluk oranına ulaşmıştır (Simonyan ve Zisserman, 2014). ResNet-50, mikro mimari modülü yapısını temel alan, toplamda 177 katmandan oluşan bir derin sinir ağıdır. Giriş katmanı olarak $224 \times 224 \times 3$ boyutunda görüntüleri kabul etmektedir (He ve ark., 2016). ResNet-50, katmanlar arasında doğrudan bağlantılar sağlayan bloklar sayesinde, derin ağların eğitiminde karşılaşılan kaybolan gradyan sorununu (vanishing gradient) aşmayı başarmıştır.

Bu çalışmada, derin öğrenme modellerinde giriş boyutu olarak $224 \times 224 \times 3$ seçilmiş ve tüm görüntüler bu boyuta yeniden ölçeklenerek modelin gereksinimlerine uygun hale getirilmiştir. Veri setinin %80' i eğitim için, %20'si doğrulama için rastgele ayrılmıştır. Eğitim sırasında adam optimizasyon algoritması tercih edilmiş, bu algoritma öğrenme

oranını dinamik olarak ayarlayarak hızlı ve kararlı bir yakınsama sağlamıştır. Başlangıç öğrenme oranı olarak $1e-4$ belirlenmiştir. Bu değer, modelin aşırı öğrenme riskini azaltmıştır. Mini batch boyutu olarak 16 seçilmiş ve bu sayede her iterasyonda küçük veri gruplarıyla hesaplama yapılmıştır. Eğitim süreci, toplam 10 epoch ile sınırlandırılmış, bu sürenin modelin yeterli öğrenme kapasitesine ulaşması için uygun olduğu değerlendirilmiştir. Model performansını izlemek amacıyla doğrulama verisi kullanılmış ve her 50 iterasyonda bir doğrulama doğruluğu ve kaybı hesaplanmıştır. Eğitim sürecindeki doğruluk ve kayıp değerleri grafiklerle görselleştirilmiş ve modelin aşırı öğrenme eğilimleri izlenmiştir. Eğitimin ardından test verisi üzerinde sınıflandırma yapılmış, tahmin edilen etiketler ile gerçek etiketler arasındaki ilişki karışıklık matrisi ile görselleştirilmiştir. Ayrıca, test verisinden rastgele seçilen örnekler üzerinde tahmin edilen ve gerçek sınıflar karşılaştırılarak modelin performansı daha detaylı bir şekilde incelenmiştir. Bu parametreler, modelin etkin bir şekilde eğitilmesi ve değerlendirilmesi için dikkatle seçilmiştir.

Bu çalışmada, model eğitimi ve test süreçleri aşağıdaki donanıma sahip bir bilgisayarda gerçekleştirilmiştir:

- **İşlemci (CPU):** 12th Gen Intel(R) Core(TM) i5-12600KF 3.69 GHz.
- **Grafik Kartı (GPU):** Nvidia Geforce GTX 1660 Super Gaming X 6GB 192Bit.
- **Bellek (RAM):** 16 GB DDR3.
- **Depolama:** 512 GB NVMe SSD.
- **İşletim Sistemi:** Windows 11 Pro (64 bit).

Eğitim sırasında GPU hızlandırmasından faydalanılarak NVIDIA CUDA teknolojisi kullanılmış, bu sayede modelin eğitim süreci hızlandırılmıştır. 16 GB RAM ve NVMe SSD depolama, veri işleme ve yükleme sürelerini optimize ederek, büyük veri setleriyle çalışmayı kolaylaştırmıştır. Çalışma kapsamında gerçekleştirilen tüm hesaplamalar ve görsel analizler, Akdeniz Üniversitesi lisansı kapsamında temin edilen MATLAB 2024b yazılımı kullanılarak gerçekleştirilmiştir.

Tablo 3.1. Modellerin Eğitim Süreleri

MODEL ADI	EĞİTİM SÜRESİ(Ortalama)
AlexNet	13 saat 54 dakika
GoogleNet	15 saat 1 dakika
Inception V3	40 saat 52 dakika
MobileNet	18 saat 2 dakika
ResNet-18	15 saat 25 dakika
Vgg16	67 saat 54 dakika
Vgg19	61 saat 43 dakika

Tablo 3.1.'de modellerin eğitim süreleri verilmiştir. Süreyi azaltmak için daha güçlü bir GPU kullanmak veya mini batch boyutunu artırmak yöntemler kullanılabilir. Ancak mini batch boyutu arttığında öğrenme doğruluğunun azaldığı gözlemlenmiştir.

4. BULGULAR

Prematüre bebekler de ROP hastalığının teşhisi için retinadaki optik diskin yerinin belirlenmesi, büyüklüğü, zon bölgelerdeki değişim, damarların kalınlığı, uzunluğu ve sıklığı önemlidir. Retina tabakasında değişimler prematüre bebeklerde çok hızlı gelişmektedir. ROP hastalığını teşhis edebilmek için bebekler düzenli kontrol edilmelidir. Ayrıca, hastalık çok hızlı geliştiğinden dolayı, teşhis ve tedavi arasında geçen süre çok önemlidir. Zamanı hızlı kullanmak ve iş yükünü hafifletmek için otomatik tanımlama sistemlerinin gerekliliği ortaya çıkmaktadır.

ROP hastalığının 5 evresi vardır. Evreler hastalığın önemini göstermektedir. Önem arttıkça hastalığın evresi de artmaktadır. Birinci ve ikinci evrelerde retina kenarlarının normal kan beslemesi problemi oluşmaktadır. 3 evrede kabarıklık oluşur ve istenmeyen damarlar gelişir. 4. evre de alt bölgelerde retina dekolmanı gelişirken, 5. Evrede tüm retinada dekolman oluşmaktadır. Hastalığın önemini belirlemek için retina zon denilen bölgelere ayrılır. Bu bölgelere göre hastalığın teşhisi değişebilir. Tüm bu işlemleri yapmak göz doktorunu yormakla beraber değişik teşhislere sebep olabilmektedir. Özellikle teşhiste kullanılan verilerin fazlalığı doktorların subjektif karar almasına neden olabilmektedir. Bu çalışmada doktora karar vermede yardımcı olacak yeni bir model ortaya koyulmaktadır.

Retina için kullanılan derin öğrenme yöntemleri arasında CNN, recurrent neural networks (RNN), ve generative adversarial networks (GAN) gibi yöntemler bulunmaktadır. CNN, retinal görüntülerin sınıflandırılması, segmentasyonu ve analizi için kullanılır. RNN, retinal görüntülerin zaman içindeki değişimlerini takip etmek için kullanılabilir. GAN, retinal görüntüleri üretebilmek veya retinal görüntülerin eksik parçalarını tamamlamak için kullanılabilir. Bu yöntemlerin hepsi kullanılarak retina ile ilgili çalışmalar yapılmaktadır, ancak her birinin kendine özgü uygulama alanları bulunmaktadır.

CNN yöntemi, genellikle görüntü tanıma ve işleme gibi uygulamalarda kullanılan bir derin öğrenme yöntemidir.

CNN'nin alt kategorileri arasında şunlar yer almaktadır:

LeNet: bu, ilk CNN modeli olarak kabul edilir ve görüntü tanıma için tasarlanmıştır.

AlexNet: bu, 2012 yılında yayınlanmış bir CNN modelidir ve ImageNet veri kümesinde çok iyi sonuçlar elde etmiştir.

VGG: bu, 2014 yılında yayınlanmış bir CNN modelidir ve görüntü tanıma için tasarlanmıştır.

GoogleNet: bu, 2014 yılında yayınlanmış bir CNN modelidir ve Inception mimarisinin ilk versiyonudur.

ResNet: bu, 2015 yılında yayınlanmış bir CNN modelidir ve daha derin ağlarda görülen "vanishing gradient" problemini çözmek için tasarlanmıştır.

DenseNet: bu, 2016 yılında yayınlanmış bir CNN modelidir ve katmanlar arasında güçlü bağlantılar oluşturmak için tasarlanmıştır.

CNN yöntemi için birçok alt kategori mevcut. Bu yöntemin çeşitli uygulamaları ve modelleri üzerine yapılan çalışmalar devam etmektedir.

ROP tedavisinde kullanılan derin öğrenme yöntemleri arasında convolutional neural networks (CNN) ve deep learning-based diagnostic systems gibi yöntemler bulunmaktadır.

Veri Seti


Akdeniz Üniversitesi Göz ABD alınan ROP görüntü sayıları Tablo 4.1.'de gösterilmektedir. Görüntü sayıları, ROP0 (Normal) 467, ROP1 3467, ROP2 ise 9845 adettir. Öncelikli olarak kalitesiz, parlaklığı düşük ve damarları belli olmayan görüntüler çıkartılmış daha sonra da algoritma eğitimi için eksik gruptaki veriler çoğaltılmıştır.

Tablo 4.1. Veri Seti Bilgileri


	HAM Veri Seti	Temizlenmiş veri Seti	Çoğaltılmış veri Seti
ROP0(Normal)	467	370	8880
ROP1	3467	2391	9564
ROP2	9845	7377	7377

Veri setinde bulunan görüntüleri iyileştirme yapmak amacıyla, farklı eşikleme ve filtreleme yöntemleri uygulanmıştır. Bu algoritmaların hangisinin en iyi sonucunu verdiğini tespit etmek amacıyla, ortalama kare hatası (MSE - Mean Squared Error), tepe sinyal gürültü oranı (PSNR - Peak Signal to Noise Ratio) ve yapısal benzerlik endeksi (SSIM - Structural Similarity Index) görüntü kalitesi ölçüm teknikleri ile karşılaştırılması yapılmıştır.


Şekil 4.1.'de retinanın orijinal görüntüsü, gri tona çevrilmiş görüntüsü ve Laplace, Gaussian, Clahe, Median filtreleri uygulandığında oluşan görüntüler gösterilmiştir.




A)




B)




C)



D)




E)



F)

Şekil 4. 1. ROP görüntüsüne farklı filtreleme yapıldıktan sonraki görüntüleri, A) Orijinal Görüntü, B) Gri Tona Çevrilmiş Görüntü, C) Laplace filtreleme, D) Gaussian filtreleme, E) CLAHE filtreleme, F) Median filtreleme

Şekil 4.2.' de orijinal görüntü, gri tonlamalı görüntü, niblack, kittler, bulanık çıkarım tabanlı, kapur, triangle, çapraz entropi tabanlı, otsu eşikleme sonucu oluşan retina görüntüleri gösterilmektedir.



Şekil 4.2. ROP görüntüsünde farklı eşikleme yöntemleri sonrası oluşan görüntü örnekleri. A) Orijinal görüntü, B) Gri tonlamalı görüntü, C) Niblack eşikleme, D) Kittler eşikleme, E) Bulanık çıkarım tabanlı eşikleme, F) Kapur eşikleme, G) Triangle eşikleme, H) Çapraz entropi tabanlı eşikleme, I) Otsu eşikleme

ROP görüntülerinin, ön işleme algoritmalarının karşılaştırılması sonucu kaydedilen veriler Tablo 4.2.' de gösterilmektedir.

Tablo 4.2. Kullanılan tüm yöntemlerin sayısal karşılaştırılması

EŞİKLEME YÖNTEMİ	FİLTRELEME YÖNTEMİ	PSNR	MSE	SSIM
Otsu	Laplace	21.2545	0.0075	0.3895
	Clahe	21.6047	0.0069	0.4762
	Gaussian	23.2699	0.0047	0.3923
	Median	21.2584	0.0075	0.3798
NiBlack	Laplace	5.4025	0.2882	0.1547
	Clahe	5.3879	0.2892	0.0990
	Gaussian	8.0272	0.1575	0.1799
	Median	5.6172	0.2743	0.1690
Kittler	Laplace	10.6400	0.0863	0.3306
	Clahe	10.5963	0.0872	0.2545
	Gaussian	14.3288	0.0369	0.4259
	Median	11.0933	0.0777	0.3459
Kapur	Laplace	17.6288	0.0173	0.3892
	Clahe	17.6595	0.0171	0.4634
	Gaussian	21.0955	0.0078	0.4098
	Median	17.7978	0.0166	0.3859
Triangle	Laplace	12.0226	0.0628	0.3580
	Clahe	11.9812	0.0634	0.3236
	Gaussian	15.8193	0.4384	0.0262
	Median	12.4269	0.0572	0.3624
Çapraz Entropi	Laplace	21.0236	0.0079	0.4300
	Clahe	16.6761	0.0215	0.4534
	Gaussian	22.7010	0.0054	0.4305
	Median	21.1946	0.0076	0.4191
Bulanık Çıkarım	Laplace	14.0310	0.0395	0.3133
	Clahe	14.2041	0.0380	0.3881
	Gaussian	18.9467	0.0127	0.3465
	Median	14.2417	0.0377	0.3137

ROP görüntülerine uygulanan görüntü işleme yöntemlerinin sonuçlarının değerlendirmesinde ilk olarak PSNR değeri kullanılmıştır. PSNR değerlerine göre en iyi yöntemin Eşikleme yönteminde OTSU, filtreleme algoritmasında ise Gaussian yönteminin (PSNR= 23.2699) olduğu görülmüştür. Daha sonra uygulanan Çapraz Entropi

yöntemi ve Gaussian yöntemlerinin ise (PSNR= 22.7010) en iyi sonucu verdiği sonucu ortaya çıkmıştır. Arka planın tek tip olması nedeniyle de NiBlack Eşikleme Yöntemi ve Clahe filtresi (PSNR=5.3879) en kötü sonucu vermiştir. Sayısal değerlendirmede ikinci olarak MSE değerlerini incelediğimiz de en küçük hatanın (MSE=0.0047) ile yine Otsu ve Gaussian filtrelerinden geçirilen yöntem sonucu ortaya çıktığı gözlemlenmektedir. Görüntüde bulunması gereken damarları bulmada en yüksek hata payının Ni black algoritmasındaki hata payları olduğu görülmektedir. İki yöntemde de aynı algoritmaların başarılı çıkması göz retinası ile ilgili yapılan araştırmalarda bu yöntemlerin daha sık kullanılma nedenini göstermektedir. SSIM değerlerinden en yüksek değeri ise (SSIM=0.4762) Otsu eşikleme yöntemi ile kullanılan CLAHE fitresinin yer aldığı gözlemlenmiştir.

Bu duruma göre tüm veri setine Gaussian Operatörü ile Çapraz Entropi Yöntemi ya da Otsu Eşikleme yöntemi ile damarların çıkarılması işlemi uygulanmıştır. Bundan sonraki süreçte görüntüler CNN ağ sistemine girilip sonuçlar değerlendirilmiştir. CNN sistemindeki farklı yöntemlerin karşılaştırılması ve en iyi sonuç için farklı hibrit sistemler denenmesi düşünülmektedir.


Damar Görüntülerinin Tespiti



Şekil 4.3. Damar Görüntülerini Tespit Aşamaları

Şekil 4.3.'de retinadaki damar görüntülerini tespit aşamaları gösterilmektedir. Retinadaki kan damarlarının tespiti, retina görüntüsünün gri seviyeye indirgenmesiyle başlamaktadır. Gri seviyeye indirgenmiş retinal fundus görüntülerde yer alan kan damarlarını arka plana göre daha da belirginleştirmek ve bölütleme işleminde ayırt edilmesini kolaylaştırmak için görüntünün bazı aşamalardan geçmesi gerekmektedir.

Öncelikli olarak retina görüntüsünün kenarlarını görüntüden ayırtmak için bir maskeleme yapılmıştır (Şekil 4.4.).



Şekil 4.4. Retina Görüntüsüne Maskeleme işlemi

Retinal görüntülerin kontrastını artırmak için Kontrast Sınırlı Uyarlamalı Histogram Eşitleme (CLAHE) yöntemi uygulanmaktadır. Bu yöntem, görüntüdeki kontrastın homojen bir şekilde artırılmasını sağlar. Retinal görüntülerin gölgeleme etkilerini düzeltmek ve bükülmeyi azaltmak için radyasyon kanalında kısıtlanmış çok yönlü histogram farklılaştırması uygulanması daha etkili bir yaklaşım olarak önerilmektedir.

Görsel kontrastın daha etkili bir şekilde ayarlanabilmesi için $L^*a^*b^*$ renk alanı kullanılmaktadır. Bu renk alanı, görsel kontrastların güçlü bir şekilde ayrıştırılmasını sağlayan üç ortogonal bileşenden oluşur:

- **L***: Parlaklık bileşeni, 0 (koyu) ile 100 (beyaz) arasında bir değer alır.
- **a***: Yeşilden kırmızıya renk geçişlerini temsil eder ve -128 ila +127 arasında değişir.
- **b***: Maviden sarıya renk geçişlerini temsil eder ve -128 ila +127 arasında değişir.

L* bileşeni, insan gözünün parlaklık algısını yakından temsil eder ve kontrastın değiştirilmesi için kullanılabilir. $L^*a^*b^*$ renk alanında işlenen görüntü, işlem tamamlandıktan sonra tekrar Kırmızı-Yeşil-Mavi (RGB) renk alanına dönüştürülür.

Ne yazık ki, RGB renk alanının bağımlı yapısından dolayı RGB kanallarından Lab^* renk alanına dönüşüm için net bir standardizasyon mevcut değildir. L^* bileşeninin dönüştürülme prosedürü, ilgili koşullara bağlı olarak belirlenir ve bu işlem sırasında ortaya çıkan değişiklikler detaylı bir şekilde analiz edilmelidir (Arbargathe, 2017).

Bu yöntemler, retinal görüntülerdeki kontrastın artırılması ve görsel anlamda daha net bir analiz için güçlü araçlar sunmaktadır.

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,412453 & 0,357580 & 0,180423 \\ 0,212671 & 0,715160 & 0,072169 \\ 0,019334 & 0,119193 & 0,950227 \end{bmatrix} * \begin{bmatrix} r'(x,y) \\ g'(x,y) \\ b'(x,y) \end{bmatrix} \quad (6)$$

$$L = 116f\left(\frac{y}{y_n}\right) - 16$$



A) Laplace Görüntü



B) Clahe Algoritması uygulandıktan sonraki görüntü

Şekil 4.5. A) Laplace Görüntü, B) Clahe Algoritması uygulandıktan sonraki görüntü

Laplace Operatörü

Laplace operatörü, görüntü işlemede farklı yönlerdeki kenarlara eşit tepki veren bir ikinci türev operatörü olarak bilinir. Bu özellik, kenar belirleme ve görüntü netleştirme işlemlerinde Laplace operatörünü etkili bir araç haline getirmektedir.

$f(x,y)$ fonksiyonu şeklindeki bir görüntüye aşağıdaki Laplace denklemi uygulandığında kenarların daha belirgin olması sağlanır.

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \quad (7)$$

Laplace filtresinin matrisleri için aşağıdaki filtre uygulanır.

$$L = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad L = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (8)$$

Eşikleme

Eşikleme, görüntüdeki arka plan gürültüsünü azaltarak, piksellere kodlanmış yararlı bilgilerin elde edilmesini sağlayan temel bir görüntü işleme yöntemidir. Bu yöntem, görüntü yoğunluğu belirli bir eşik değerinden (T) daha düşük olan pikselleri siyah (0) ve

eşik değerinden büyük olan pikselleri beyaz (1) olarak sınıflandırarak, iki bölgeye ayrılmış bir ikili görüntü oluşturur.

Eşikleme işlemi şu şekilde tanımlanabilir:

Eşik görüntüsü $g(m, n)$ Eşitlik 9' daki gibi tanımlanabilir (Pal & Pal, 1993):

$$g(m,n) = \begin{cases} 1, & \text{eğer } (m,n) \geq T \text{ ise} \\ 0, & \text{aksi takdirde} \end{cases} \quad (9)$$

Bu yöntem, özellikle damar gibi belirli yapıların çıkarımında kullanılır. Ancak damar binarizasyon işlemi, elde edilen damarların kesin doğruluğunu sağlamak için yüksek performanslı algoritmalarla desteklenmelidir. Eşikleme, en temel haliyle, bir eşik değeri belirleyerek tüm pikselleri sınıflandırmayı içerir.

Morfolojik İşlemler

Eşikleme sonrası ikili görüntü üzerinde, morfolojik işlemler kullanılarak yapıların boyutları ve şekilleri üzerinde düzenlemeler yapılır. Bu işlemler, genellikle görüntülerin genişletilmesi, aşındırılması, açılması ve kapatılması gibi temel adımlardan oluşur:

1. Genişletme (Dilation):

- Sayısal bir görüntü, bir yapısal elemanla kesiştiği bölgeler kadar genişletilir. Bu işlem, nesneleri kalınlaştırır ve küçük boşlukları doldurur.

2. Aşındırma (Erosion):

- Genişletme işleminin tersidir. Görüntü üzerindeki nesneleri inceltir ve küçük nesneleri kaldırabilir. Bu işlem, boyutsal olarak daralma ve nesnelerin ayrılmasına yol açabilir.

3. Açma (Opening):

- Aşındırma ve genişletme işlemlerinin ardışık uygulanmasıyla gerçekleştirilir. Birbirine yakın nesneleri fazla değişime yol açmadan ayırmak için kullanılır.

4. Kapama (Closing):


- Genişletme ve aşındırma işlemlerinin ardışık uygulanmasıdır. Bu işlem, birbirine yakın nesneleri birleştirir ve görüntüdeki küçük boşlukları doldurur.

Eşikleme ve morfolojik işlemler, özellikle tıbbi görüntüleme ve nesne tanıma gibi uygulamalarda, belirgin yapıların çıkarılması ve gürültünün azaltılması için yaygın olarak kullanılmaktadır.

Retina damarlarının çıkarımında, özellikle kapanma işlemi sonrası damarlar net bir şekilde ayrıştırılır ve görüntüdeki yapılar dolgun hale getirilir. Bir ikili görüntü A kümesinin, bir yapı elemanı B ile kapatılması, genişleme işlemini takiben yapılan aşındırma ile ifade edilir. Bu işlem, görüntüdeki nesneleri birleştirerek daha düzgün ve bütünsel bir yapı sağlar.

$$A \bullet B = (A \oplus B) \ominus B.$$

Burada $\bullet$ simgesi kapanma işlemini, $\oplus$ ve $\ominus$ sırasıyla genişleme ve erozyonu belirtir.



Şekil 4.6. Kapanma işleminden sonra retina damarlarının çıkarım görüntüsü.

5. TARTIŞMA

Bu çalışma, ROP teşhisinde uzmanlara yardımcı olabilecek bir karar destek sistemi geliştirilmesini hedeflemektedir. Görüntü işleme ve derin öğrenme algoritmalarının kullanımıyla retina görüntülerinin analiz edilmesi ve ROP sınıflarının doğru bir şekilde tespit edilmesi amaçlanmıştır. Ancak çalışmanın metodolojisi ve sonuçları göz önüne alındığında bazı potansiyel uygulamalar, sınırlamalar ve sonuçların değerlendirilmesi gereken yönleri bulunmaktadır.

Çalışmanın sonuçları, klinik uygulamalarda kullanılabilecek gerçek zamanlı bir teşhis sistemine dönüştürülebileceğini göstermektedir. Özellikle mobil cihazlarla entegre edilebilecek bir uygulama, saha çalışmalarında veya taşınabilir sağlık hizmetlerinde önemli bir katkı sağlayabilir. Bu sistem, ROP teşhisinde yer alan uzmanların iş yükünü azaltabilir ve subjektif karar verme sürecini daha objektif hale getirebilir.

Mevcut derin öğrenme yöntemlerinin sınırları da dikkate alınarak gelecekteki çalışmalar için optimizasyon ve gelişmiş algoritmalar önerilebilir. Örneğin, AlexNet gibi CNN modellerinin yanı sıra, daha yeni mimarilerin (Transformer tabanlı modeller gibi) kullanılması doğruluk oranını artırabilir.

Çalışmada kullanılan veri setinin boyutu ve kalitesi, elde edilen sonuçları doğrudan etkileyen önemli sınırlamalardır. Toplamda 25821 görüntü kullanılmış olsa da, sınıflar arasındaki dengesizlik (ROP0, ROP1 ve ROP2 arasında) algoritmanın genelleme yeteneğini sınırlandırmış olabilir. Ek olarak, görüntülerin kalitesi (parlaklık, netlik, çözünürlük) bazı sınıfların yanlış sınıflandırılmasına neden olmuştur. Veri setinin genişletilmesi, çeşitlendirilmesi ve görüntü kalitesinin artırılması, gelecekteki çalışmalar için önerilmektedir.

Doğruluk Oranlarının %90 seviyeye çıkamaması nedenleri arasında:

- Veri setindeki sınırlamalar: Düşük kaliteli görüntüler ve sınıflar arasındaki dengesizlik.

- Algoritma sınırlamaları: Kullanılan CNN modellerinin derinliđi ve mimarileri, daha yüksek dođruluk oranlarına ulaşmada yeterli olmayabilir.
- Görüntü işleme aşamasındaki sınırlamalar: Histogram işlemleri ve filtreleme tekniklerinin daha fazla optimize edilmesi gerekebilir.

Bu sistemin pratikte uygulanabilirliđi sırasında karşılaşılabilecek olası zorluklar da ele alınmalıdır. Uzmanlar tarafından kabul görmesi, sistemin güvenilirliđi ve etik sorumluluklar (örneğin, yanlış pozitif veya yanlış negatif sonuçların olası sonuçları) gibi konular, gelecekteki araştırmaların odak noktası olabilir.

Literatürde, ROP evrelerini kapsayan çalışmaların sınırlı sayıda olması, bu alandaki eksikliđi göstermektedir. Bu çalışma, ROP teşhisinde otomatik sistemlerin potansiyelini ortaya koymanın yanı sıra, literatürdeki eksikliđin aksine üç evreyi kapsayarak kapsamlı bir analiz sunmaktadır. Ancak, daha geniş veri setleri ve gelişmiş algoritmalarla desteklenerek, dođruluk oranları artırılabilir ve sistemin daha fazla genelleme yapabilmesi sağlanabilir. Gelecekte, bu sistemlerin zaman içindeki deđişiklikleri izleyebilecek RNN veya GAN tabanlı yaklaşımlar ile güçlendirilmesi önerilmektedir.

6. SONUÇ ve ÖNERİLER

Akdeniz Üniversitesi Göz ABD. alınan ROP görüntü sayıları; Normal ROP0 467, ROP1 3467, ROP2 ise 9845 adettir. Görüntü boyutları 640x480 piksel ve RGB renk modunda kaydedilmiştir. Öncelikli olarak kalitesiz, parlaklığı düşük ve damarları belli olmayan görüntüler çıkartılmış daha sonra da algoritma eğitimi için eksik gruptaki veriler çoğaltılmıştır. Tablo 6.1.'de veri seti sayıları gösterilmektedir.

Tablo 6.1. Veri Seti sayıları

Sınıflar	Ham Veri Seti	Temizlenmiş veri Seti	Çoğaltılmış veri seti
ROP0(Normal)	467	370	8880
ROP1	3467	2391	9564
ROP2	9845	7377	7377

Bu çalışmada geliştirilen sınıflandırma yaklaşımı, iki aşamalı bir modelleme stratejisine dayanmaktadır. İlk aşamada, retina görüntülerinin ROP'lu görüntüyü tespit edebilmesi hedeflenmiştir. Bu doğrultuda, ROP ve ROP olmayan görüntüleri ayırt edebilecek bir derin öğrenme modeli eğitilmiştir. Bu model, temel olarak ikili sınıflandırma problemine odaklanmış ve hastalığın tespitine yönelik ilk karar destek işlevini üstlenmiştir.

İkinci aşamada ise, hastalığın evrelerini belirlemek amacıyla çok sınıflı bir sınıflandırma modeli oluşturulmuştur. Bu model, ROP' un klinik derecelerine (ROP0, ROP1, ROP2) göre yeniden eğitilmiştir.

Bu iki aşamalı yaklaşım sayesinde hem hastalık tespiti hem de evreleme işlemleri kademeli ve modüler bir yapıda gerçekleştirilmiş; modelin tanısallık doğruluğunu artırmıştır.

Tablo 6.2.'de, ROP teşhisi amacıyla geliştirilen derin öğrenme modelleri, "normal" ve "ROP teşhisi konmuş" olmak üzere iki sınıfa ayrılan retinal görüntüler üzerinde test edilmiştir. İncelenen modeller AlexNet, DenseNet-201, ResNet-18, GoogleNet, Inception-v3 ve EfficientNet-b0'dır. Her model; test doğruluğu, duyarlılık (sensitivity), özgüllük (specificity) ve AUC (ROC eğrisi altında kalan alan) bakımından


karşılaştırılmıştır. En yüksek test doğruluğu Inception-v3 modeline aitken, en yüksek duyarlılık değeri EfficientNet-b0 modelinde elde edilmiştir.

Tablo 6.2. Derin Öğrenme Modellerinin ROP Sınıflandırma Performans Karşılaştırması


Model	Doğruluk	Duyarlılık	Özgüllük	AUC
AlexNet	0.888	0.678	0.998	0.955
DenseNet-201	0.925	0.93	0.923	0.982
ResNet-18	0.915	0.936	0.873	0.973
GoogleNet	0.919	0.938	0.882	0.974
Inception-v3	0.938	0.913	0.952	0.982
EfficientNet-b0	0.936	0.97	0.872	0.984

En yüksek duyarlılık değeri %97 ile EfficientNet-b0 modelinde gözlemlenmiştir. Bu sonuç, EfficientNet-b0'ın ROP vakalarının büyük çoğunluğunu doğru tespit ettiğini göstermektedir. AlexNet'in duyarlılığı %67,8 ile en düşük değerdir; bu durum, çok sayıda pozitif vakanın yanlış negatif olarak sınıflandırıldığını işaret eder. En yüksek özgüllük değeri %99,8 ile AlexNet modeline aittir. Bu, modelin negatif sınıfları ayırt etmede çok başarılı olduğunu ancak pozitif sınıflarda aynı başarıyı gösteremediğini ortaya koymaktadır. Inception-v3 modeli %95,2 özgüllükle hem pozitif hem de negatif sınıflarda dengeli bir başarı göstermektedir.


En yüksek özgüllük değeri %99,79 ile AlexNet modeline aittir. Bu, modelin negatif sınıfları ayırt etmede çok başarılı olduğunu ancak pozitif sınıflarda aynı başarıyı gösteremediğini ortaya koymaktadır. Inception-v3 modeli %95,19 özgüllükle hem pozitif hem de negatif sınıflarda dengeli bir başarı göstermektedir. Kullandığımız veri seti için; EfficientNet-b0, özellikle yüksek duyarlılığı nedeniyle, ROP gibi erken müdahale gerektiren kritik durumlarda ön tarama aracı olarak idealdir. Fakat özgüllüğü daha düşüktür; bu da bazı normal vakaların yanlışlıkla ROP' lu olarak sınıflandırılabileceği anlamına gelir.




A) AlexNet Modeli




B) DenseNet 201 Modeli




C) EfficientNet-b0 Modeli



D) GoogleNet Modeli



E) Inception-v3 Modeli



F) ResNet-18 Modeli

Şekil 6.1. Derin Öğrenme Modellerinin ROC eğrileri. A) AlexNet Modeli, B) DenseNet201 Modeli, C) EfficientNet-b0 Modeli, D) GoogleNet Modeli, E) Inception-v3 Modeli, F) ResNet-18 Modeli

Şekil 6.1’de görüldüğü üzere EfficientNet-b0 %98,4 ile ROP teşhisinde en güçlü ROC performansını göstermiştir. AlexNet, özgüllüğü yüksek olsa da diğerlerine göre düşük AUC değeri nedeniyle klinik risk taşıyabilecek pozitif sınıfları kaçırma eğilimindedir.

Tablo 6.3.'de yedi farklı derin öğrenme mimarisi (AlexNet, VGG-19, EfficientNet-b0, GoogleNet, ResNet-18, Inception-v3, DenseNet-201) kullanılarak Normal, ROP1 ve ROP2 evrelerini kapsayan üç sınıflı bir ROP sınıflandırmasının sonuçları gösterilmektedir. Her bir modelin sınıf bazlı duyarlılık, özgüllük ve genel doğruluk (accuracy) performansları değerlendirilmiştir.

Tablo 6.3. Derin Öğrenme Modellerinin 3 Sınıf için ROP Sınıflandırma Performans Karşılaştırması

Model	Doğruluk	Normal Duyarlı lık	Normal Özgüllü k	ROP1 Duyarlı k	ROP1 Özgüllü k	ROP2 Duyarlı k	ROP2 Özgüllü k
AlexNet	0.835	0.69	1.00	0.92	0.83	0.89	0.92
VGG-19	0.860	0.81	0.96	0.82	0.93	0.97	0.90
EfficientNet -b0	0.899	0.91	0.96	0.83	0.96	0.98	0.93
GoogleNet	0.862	0.84	0.96	0.78	0.96	1.00	0.88
ResNet-18	0.880	0.85	0.97	0.85	0.97	0.85	0.97
Inception-v3	0.891	0.92	0.94	0.92	0.94	0.92	0.94
DenseNet- 201	0.881	0.92	0.94	0.80	0.96	0.94	0.93

Model performansları doğruluk açısından incelendiğinde, en yüksek genel başarı EfficientNet-b0 modeli ile elde edilmiştir (%89,9). Bunu sırasıyla Inception-v3 (%89,1), DenseNet-201 (%88,1) ve ResNet-18 (%88) modelleri takip etmektedir. AlexNet (%83,5) ve VGG-19 (%86) modelleri ise daha düşük genel doğrulukta sonuç üretmiştir.

True Class	normal	rop1	rop2
normal	1234	402	140
rop1	13	1759	141
rop2	1	155	1319
		Predicted Class	

A) AlexNet Modeli

True Class	normal	rop1	rop2
normal	1639	68	69
rop1	197	1528	188
rop2	23	71	1381
		Predicted Class	

B) DenseNet 201 Modeli

True Class	normal	rop1	rop2
normal	1620	93	63
rop1	137	1579	197
rop2	2	32	1441
		Predicted Class	

C) EfficientNet-b0 Modeli

True Class	normal	rop1	rop2
normal	1484	122	170
rop1	132	1494	287
rop2		4	1471
		Predicted Class	

D) GoogleNet Modeli

True Class	normal	rop1	rop2
normal	1569	140	67
rop1	92	1624	197
rop2	2	31	1442
		Predicted Class	

E) Inception-v3 Modeli


True Class	normal	rop1	rop2
normal	1444	182	150
rop1	133	1563	217
rop2	4	36	1435
		Predicted Class	

F) Vgg19 Modeli


Şekil 6.2. Derin Öğrenme Modellerinin Karışıklık Matris (Confusion Matrix) sonuçları. A) AlexNet Modeli, B) DenseNet201 Modeli, C) EfficientNet-b0 Modeli, D) GoogleNet Modeli, E) Inceprion-v3 Modeli, F) ResNet-18 Modeli

Şekil 6.2 incelendiğinde, karışıklık matrisinde, modellerin ROP2 sınıfını ayırt etmede oldukça başarılı olduğu gözlemlenmiştir. Genel olarak EfficientNet-b0 modelinin en iyi performansı verdiği görülmekle beraber, özellikle ROP1 sınıfının karışıklık oranı diğer sınıflara göre yüksek çıkmıştır.


Sonuç olarak, derin öğrenme modellerinin ROP teşhisi gibi çok sınıflı medikal sınıflandırma görevlerinde performanslarının yalnızca doğruluk oranlarıyla değil, sınıf bazlı duyarlılık ve özgüllük metrikleriyle birlikte değerlendirilmesi gerektiği gözlemlenmiştir. EfficientNet-b0, özellikle ROP2 evresinde yüksek duyarlılığı ile tedavi gerektiren hastaların kaçırılmasını engelleyebileceği görülmüştür. Inception-v3 modeli ise, her üç sınıfta da dengeli ve yüksek performans sergileyerek geniş ölçekli tarama sistemlerinde güvenle kullanılabilir. AlexNet, normal sınıfındaki %100 özgüllüğe rağmen düşük duyarlılık sebebiyle diğer modellerine kıyasla yetersizdir. Yüksek özgüllük, modelin negatif örnekleri doğru şekilde tanımladığını gösterse de; düşük duyarlılık, pozitif örneklerin önemli bir kısmının model tarafından tespit edilemediğini ifade eder. Bu durum, yanlış negatiflerin klinik açıdan ciddi sonuçlar doğurabileceği durumlarda modelin güvenilirliğini azaltır. Bu nedenle, AlexNet'in bu dengesiz sınıflandırma performansı, günümüzün daha derin, parametrik olarak optimize edilmiş ve duyarlılık-özgüllük dengesini daha iyi sağlayan modelleriyle kıyaslandığında yetersiz kalmasına yol açmaktadır.




A) AlexNet Modeli




B) DenseNet 201 Modeli




C) EfficientNet-b0 Modeli



D) GoogleNet Modeli



E) VGG19 Modeli



F) InceptionV3 Modeli

Şekil 6.3. ROP (3 Sınıf) için Derin Öğrenme Modellerinin ROC eğrileri. A) AlexNet Modeli, B) Desnet201 Modeli, C) EfficientNet-b0 Modeli, D) GoogleNet Modeli, E) VGG19 Modeli, F) Inception-v3 Modeli.

Şekil 6.3.'de, üç sınıflı ROP görüntülerine yönelik geliştirilen derin öğrenme modellerinin (AlexNet, VGG-19, EfficientNet-b0, GoogleNet, Inception-v3, DenseNet-201) performansı ROC eğrileri üzerinden gösterilmektedir. EfficientNet-b0 ve Inception V3 modelleri Normal (%99), ROP1 (%97), ROP2 (%98) ile hem eğri şekli hem de AUC değerleri açısından oldukça üstün performans göstermektedir.

EfficientNet-b0 ve Inception V3 modelleri, optimize edilmiş mimari yapıları ve düşük parametre sayıları sayesinde eğitim sürecinde aşırı öğrenme (overfitting) riskini azaltmaktadır. Bu modellerin 1x1, 3x3 ve 5x5 gibi farklı boyutlardaki konvolüsyon filtrelerini derinlemesine ayırık biçimde kullanabilme yetenekleri, çok ölçekli özellik çıkarımını mümkün kılmakta; böylece sınıflar arasındaki ayırt edici yapısal farklılıkları daha etkin bir şekilde öğrenmelerine olanak tanımaktadır. Sonuç olarak, bu modellerin yüksek duyarlılık ve özgüllük değerleri ile başarılı sınıflandırma performansı sergilediği gözlemlenmiştir.



KAYNAKLAR

Aaby, A. A., Banagale, R., Benda, G. I., Binder, N. D., Brown, W. J., Gilhooly, J. T., ... & Williams, A. T., Incidence and early course of retinopathy of prematurity. *Ophthalmology*, 1991; 98(11), 1628–1640.

Al-Rawi, M., Karajeh H., Genetic Algorithm Matched Filter Optimization For Automated Detection Of Blood Vessels From Digital Retinal Images, *Computer Methods And Programs In Biomedicine*, 2007; Volume: 87, Issue: 3, Pages: 248-253.

Antonia M. Joussen, Thomas W. Gardner, Bernd Kirchhof, Stephen J. Ryan. Retinal Vascular Disease. C. Jandek, M.H. Foerster. Clinical Course and Treatment 2007; 20:403.

Atalı,G., Özkan S., Karayel D., Morfolojik Görüntü İşleme Tekniği ile Yapay Sinir Ağlarında Görüntü Tahribat Analizi, *APJES IV-I*, 2016; 01-07, Doi:10.21541/apjes.27271.

Atchison, D., Optics of the Human Eye (2nd ed.). CRC Press.2023
<https://doi.org/10.1201/9781003128601>.

Bai, A., Dai, S., Hung, J., Kirpalani, A., Russell, H., Elder, J., et al. Multicenter validation of deep learning algorithm ROP.AI for the automated diagnosis of plus disease in ROP. *Translational Vision Science & Technology*,2023; 12(8), 13.

Bao Y, Ming WK, Mou ZW, Kong QH, Li A, Yuan TF, Mi XS. Current Application of Digital Diagnosing Systems for Retinopathy of Prematurity. *Comput Methods Programs Biomed*. 2021; Mar, 200:105871. doi: 10.1016/j.cmpb.2020.105871. Epub 2020 Nov 23. PMID: 33309305.

Bas, A.Y., Demirel N, Koc E., On behalf of the TR-ROP Study Group, et al. Incidence, risk factors and severity of retinopathy of prematurity in Turkey (TR-ROP study): a prospective, multicentre study in 69 neonatal intensive care units. *British Journal of Ophthalmology* 2018; 102:1711-1716.

Bharath, S., Kumar, V., Anitha, N., Sujatha, N., & Vinekar, A., Development and validation of an artificial intelligence based screening tool for detection of retinopathy of prematurity in a South Indian population. *Frontiers in Pediatrics*, 2023, 11, 1197237.

Brennan R., Gnanaraj L., Cottrell DG. Retinopathy of prematurity in practice. I. Screening for threshold disease. *Eye* 2003; 17:183–188.

Brown, J. M., Campbell, J. P., Beers, A., Chang, K., Donohue, K., Ostmo, S., Chan, R. V. P., Dy, J., Erdogmus, D., Ioannidis, S., Chiang, M. F., & Kalpathy-Cramer, J. Fully automated disease severity assessment and treatment monitoring in retinopathy of prematurity using deep learning. In P-H. Chen, & J. Zhang (Eds.), *Medical Imaging 2018: Imaging Informatics for Healthcare, Research, and Applications*, 2018, [105790Q] (Progress in Biomedical Optics and Imaging - Proceedings of SPIE; Vol. 10579). SPIE. <https://doi.org/10.1117/12.2295942>.

Campbell JP, Singh P, Redd TK, Brown JM, Shah PK, Subramanian P, Rajan R, Valikodath N, Cole E, Ostmo S, Chan RVP, Venkatapathy N, Chiang MF, Kalpathy-Cramer J. Applications of Artificial Intelligence for Retinopathy of Prematurity Screening. *Pediatrics*. 2021; Mar, 147(3):e2020016618. doi: 10.1542/peds.2020-016618. PMID: 33637645; PMCID: PMC7924138.

Canny, J. F. A Computational Approach to Edge Detection, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(6), 1986.

Chee RI, Darwish D, Fernandez-Vega A, Patel S, Jonas K, Ostmo S, Campbell JP, Chiang MF, Chan RP. Retinal Telemedicine. *Curr Ophthalmol Rep*. 2018; Mar, 6(1):36-45. doi: 10.1007/s40135-018-0161-8. Epub 2018 Jan 29. PMID: 30140593; PMCID: PMC6101043.

Chen, L. C., Papandreou, G., Kokkinos, I., Murphy, K., & Yuille, A. L. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected, 2016; crfs. arXiv preprint arXiv:1606.00915.

Coyner AS, Swan R, Brown JM, Kalpathy-Cramer J, Kim SJ, Campbell JP, Jonas KE, Ostmo S, Chan RVP, Chiang MF. Deep Learning for Image Quality Assessment of Fundus Images in Retinopathy of Prematurity. *AMIA Annu Symp Proc.* 2018; Dec 5;2018: 1224-1232. PMID: 30815164; PMCID: PMC6371336.

Delibasis K., Kechriniotis A., Assimakis N., Automatic Model-Based Tracing Algorithm For Vessel Segmentation And Diameter Estimation, *Computer Methods And Programs In Biomedicine* Volume 100, Issue 2, November 2010; Pages 108-122.

Doğan, F., Türkoğlu İ., Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme”, *DÜMF Mühendislik Dergisi* 10:2,2019: 409-445.

Doğan, F. Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması, 2018; *Sakarya University Journal Of Computer And Information Sciences.*

Foos R. Chronic retinopathy of prematurity. *Ophthalmology* 1985; 92:563-574.

García H, Villasis-Keever MA, Zavala-Vargas G, Bravo-Ortiz JC, Pérez-Méndez A, Escamilla-Núñez A. Global Prevalence and Severity of Retinopathy of Prematurity over the Last Four Decades (1985-2021): A Systematic Review and Meta-Analysis. *Arch Med Res.* 2024 Feb;55(2):102967. doi: 10.1016/j.arcmed.2024.102967. Epub 2024 Feb 18. PMID: 38364488.

Gelman R., Martinez M.E., Deborah P., Moskowitz A. and Fulton A., Diagnosis of Plus Disease in Retinopathy of Prematurity Using Retinal Image Multiscale Analysis, *Investigative Ophthalmology&Visual Science*, Volume, 46, No.12.pp 4734 4738 December,2005.

Ghergherehchi L, Kim SJ, Campbell JP, Ostmo S, Chan RVP, Chiang MF. Plus Disease in Retinopathy of Prematurity: More Than Meets the ICROP? *Asia Pac J Ophthalmol (Phila).* 2018 May-Jun;7(3):152-155. doi: 10.22608/APO.201863. Epub 2018 May 24. PMID: 29797825; PMCID: PMC7880619.

Huang, Y.-P.; Vadloori, S.; Chu, H.-C.; Kang, E.Y.-C.; Wu, W.-C.; Kusaka, S.; Fukushima, Y. Deep Learning Models for Automated Diagnosis of Retinopathy of Prematurity in Preterm Infants. *Electronics* 2020; 9, 1444.

Huang, Y.-P., Kang, E. Y.-C., Chen, K.-J., Tsao, Y., Hsia, T.-C., & Chang, C.-J. (2020). Automated detection of early-stage ROP using a deep convolutional neural network. *British Journal of Ophthalmology*, 104; 8, 1157–1162.

He, K., Zhang, X., Ren, S., & Sun, J. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016; pp. 770-778.

İnik, Ö., & Ülker, E. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, 2017; Gaziosmanpasa Journal of Scientific Research.

Jiang, H., Shen, Y., Zhang, H., Zhou, Y., Jiang, F., & Wu, J., Early Diagnosis and Quantitative Analysis of Stages in Retinopathy of Prematurity Based on Deep Convolutional Neural Networks. *Translational Vision Science & Technology*, 2022; 11:(5), 1–13.

Kanski JJ. *Clinical Ophthalmology: A Systemic Approach*, 6th ed.ed. London, UK: Elsevier Health Sciences 2007.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, 2012; pp. 1097-1105.

Köse, C., İkibaş, C., A personal identification system using retinal vasculature in retinal fundus images. *Expert Systems with Applications*, 2011; 38(11), 13670–13681. <https://doi.org/10.1016/j.eswa.2011.04.141>.

Lam, B. S. Y., Yan, H., A novel vessel segmentation algorithm for pathological retina images based on the divergence of vector fields. *IEEE Transactions on Medical Imaging*, 2008; 27(2), 237–246. <https://doi.org/10.1109/TMI.2007.909827>.

Maji D, Sekh AA. Automatic Grading of Retinal Blood Vessel in Deep Retinal Image Diagnosis. J Med Syst. 2020 Sep; 1;44(10):180. doi: 10.1007/s10916-020-01635-1. PMID: 32870389; PMCID: PMC7462841.

Niemeijer, M., Staal, J., Ginneken, B. van, Loog, M. ve Abr`amoff, M. D., Comparative Study of Retinal Vessel Segmentation Methods on a New Publicly Available Database SPIE Med. Imaging, 5370, 2004; 648–656.

Peng, Y., Li, H., Xiao, B., & Li, X.. ADS-Net: attention-awareness and deep supervision based network for automatic detection of retinopathy of prematurity. Biomedical Optics Express, 2022; 13;(8), 4087–4101.

Ramanathan A, Athikarisamy SE, Lam GC. Artificial intelligence for the diagnosis of retinopathy of prematurity: A systematic review of current algorithms. Eye (Lond). 2023 Aug;37(12):2518-2526. doi: 10.1038/s41433-022-02366-y. Epub 2022 Dec 28. PMID: 36577806; PMCID: PMC10397194.

Redd TK, Campbell JP, Brown JM, Kim SJ, Ostmo S, Chan RVP, Dy J, Erdogmus D, Ioannidis S, Kalpathy-Cramer J, Chiang MF; Imaging and Informatics in Retinopathy of Prematurity (i-ROP) Research Consortium. Evaluation of a deep learning image assessment system for detecting severe retinopathy of prematurity. Br J Ophthalmol. 2018 Nov 23; bjophthalmol-2018-313156. doi: 10.1136/bjophthalmol-2018-313156. Epub ahead of print. PMID: 30470715; PMCID: PMC7880608.

Ricci E., Perfetti R., Retinal Blood Vessel Segmentation Using Line Operators and Support Vector Classification, IEEE Transactions On Medical Imaging, Vol. 26, No. 10, October 2007.

Safran, M.İ. ve Öktem, R., Hızlı Hough Dönüşümü Yaklaşıklığı ve Çubuk Kod Tespitine Uygulanması, SIU 2007, Eskişehir

Salma M Boubakar Khalifa Albargathe, Akram Kh Said Gihedan, Javad Rahebi and Fatma Kandemirli, “Fundus Retina Blood Vessel Segmentation with HMinima

Transformation”, International Journal of Engineering Innovation & Research, 2017; Volume 6, Issue 5, pp. 231–234.

Shamshad, F., Khan, S., Zamir, S. W., Khan, M. H., Hayat, M., Khan, F. S., & Fu, H. . Transformers in medical imaging: A survey. Medical Image Analysis, 2023; 88, 102802.

Shashua A., Gdalyahu Y., and Hayon G., “Pedestrian detection for driving assistance systems: Single-frame classification and system level performance”, In Proceedings of IEEE Intelligent Vehicles Symposium, 2004.

Soares J., Jorge J. G. Leandro, Ceasar-Jr R., Jelinek H., And Cree M., Retinal Vessel Segmentation Using The 2-D Morlet Wavelet And Supervised Classification, Senior Member IEEE Trans Med Imag, Volume 25, No. 9, Pages. 1214-1222, Sep. 2006.

Schalij-Delfos NE., Zijlmans BL., Wittebol-Post D. et al. Screening for retinopathy of prematurity: do former guidelines still apply? J Pediatr Ophthalmol Strabismus 1993; 33:35– 38.

Taylor S, Brown JM, Gupta K, et al. Monitoring Disease Progression With a Quantitative Severity Scale for Retinopathy of Prematurity Using Deep Learning. JAMA Ophthalmol. 2019;137(9):1022–1028. doi:10.1001/jamaophthalmol.2019.2433.

Toptaş, B., Hanbay, D., Retina kan damarlarını çıkarmak için eşikleme temelli morfolojik bir yöntem, NÖHÜ Müh. Bilim. Derg. / NOHU J. Eng. Sci., 2022; 11(1), 010-016.

Türk Oftalmoloji Derneği Prematüre Retinopatisi Komisyonu, Türkiye Prematüre Retinopatisi Rehberi, 2016.

Wallace D., Freedman S., Zhao Z., A Pilot Study Using Roptool to measure retinal vascular Dilation Journal of American Association for Pediatric Ophthalmology and Strabismus Volume 11, Issue 4, August 2007, Pages 381-387.

Walter M. Fierson, American Academy Of Pediatrics Section On Ophthalmology, American Academy Of Ophthalmology, American Association For Pediatric Ophthalmology And Strabismus, American Association Of Certified

Orthoptists, Michael F. Chiang, William Good, Dale Phelps, James Reynolds, Shira L. Robbins, Daniel J. Karr, Geoffrey E. Bradford, Kanwal Nischal, John Roarty, Steven E. Rubin, Donny Won Suh, Sharon S. Lehman, George S. Ellis; Screening Examination of Premature Infants for Retinopathy of Prematurity. *Pediatrics* December 2018; 142 (6): e20183061. 10.1542/peds.2018-3061.

Walter T., Klein J.C., Segmentation of Color Fundus Images of the Human Retina: Detection of the Optic Disc and the Vascular Tree Using Morphological Techniques, In *Medical Data Analysis*, Vol. 2199, 2001, pp. 282-287.

Wang J, Ji J, Zhang M, et al. Automated Explainable Multidimensional Deep Learning Platform of Retinal Images for Retinopathy of Prematurity Screening. *JAMA Netw Open*. 2021;4(5):e218758. doi:10.1001/jamanetworkopen.2021.8758.

Wu Q, Hu Y, Mo Z, Wu R, Zhang X, Yang Y, Liu B, Xiao Y, Zeng X, Lin Z, Fang Y, Wang Y, Lu X, Song Y, Ng WWY, Feng S, Yu H. Development and Validation of a Deep Learning Model to Predict the Occurrence and Severity of Retinopathy of Prematurity. *JAMA Netw Open*. 2022 Jun 1;5(6): e2217447. doi: 10.1001/jamanetworkopen.2022.17447. PMID: 35708686; PMCID: PMC10881218.

Yenice, E. K., Kara, C., Erdaş, Ç. B. Automated detection of type 1 ROP, type 2 ROP and A-ROP based on deep learning. *Eye*, 2024; 38(12), 2644–2648.

Yildiz, V. M., Tian, P., Yildiz, I., Brown, J. M., Kalpathy-Cramer, J., Dy, J., et al., Plus disease in retinopathy of prematurity: Convolutional neural network performance using a combined neural network and feature extraction approach. *Translational Vision Science & Technology*, 2020; 9(2), 10.

Z. Yavuz Et Al., A Method For Automatic Optic Disc Extraction In Retinal Fundus Images,, 5. Uluslararası İleri Teknolojiler Sempozyumu, IATS'09, Turkey, 2009.

Zana, F. ve Klein, J. C., Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation. *IEEE Trans. Image Process.*, 10, 7, 2001; 1010–1019.

Zangana, H. M., Mohammed, A. K., Mustafa, F. M., Advancements in edge detection techniques for image enhancement: A comprehensive review. *International Journal of Artificial Intelligence & Robotics*, 2024; 6(1), 29–39.

Zhang-Nunes S. Light Therapy for Facial Rejuvenation and Dry Eyes, Blepharitis, and Styes. *Int Ophthalmol Clin*. 2024 Jul 1;64(3):9-12. doi: 10.1097/IIO.0000000000000527. Epub 2024 Jun 24. PMID: 38910500; PMCID: PMC11512619.

Zhang, Y., Zhang, G., Lin, W., Sun, Y., Zhang, R., Li, K., & Zhang, S. Development of an Automated Screening System for Retinopathy of Prematurity Using a Deep Neural Network for Wide-Angle Retinal Images. *IEEE Access*, 2018;6, 62083–62091.

Zhang, Y., & Wang, L., A new intelligent pattern classifier based on structured sparse representation. *Computers & Electrical Engineering*, 2020; 86, 106729.

Ziou, D., Tabbone, S., A multi-scale edge detector. *Pattern Recognition*, 1993; 26(9), 1305–1314. [https://doi.org/10.1016/0031-3203\(93\)90137-L](https://doi.org/10.1016/0031-3203(93)90137-L)

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı	Evren	Uyruğu	T.C.
Soyadı	Sezgin	Tel no	
Doğum tarihi		e-posta	

Eğitim Bilgileri

Mezun olduğu kurum		Mezuniyet yılı
Lise	Eskişehir Anadolu Teknik Lisesi	1998
Lisans	Gazi Üniversitesi End.San.Eğit.Fak. Bilgisayar Eğitimi	2002
Yüksek Lisans	Selçuk Üniversitesi Elektronik ve Bilgisayar Eğitimi	2007
Doktora		

İş Deneyimi

Görevi	Kurum	Süre (yıl-yıl)
Öğretim görevlisi	Selçuk Üniversitesi	2002-2009
Öğretim görevlisi	Akdeniz Üniversitesi	2009-

Yabancı Dilleri	Sınav türü	Puanı
İngilizce	YÖKDİL	67,5

Proje Deneyimi

Proje Adı	Destekleyen kurum	Süre (Yıl-Yıl)

Burslar-Ödüller:

Yayınlar ve Bildiriler:

A New Software Program For Pathological Data Analysis, Isik H., Sezgin E., Avunduk M. C., Computers In Biology And Medicine, Cilt.40, Sa.8, Ss.715-722, 2010 (Sci-Expanded)

Prematüre Retina Kan Damarlarının Tespitinde Farklı Görüntü İşleme Yöntemlerinin Performanslarının Karşılaştırılması, Sezgin E., Üncü Y. A., Yardımcı A., Süleyman Demirel Üniversitesi Fen Edebiyat Fakültesi Fen Dergisi = Süleyman Demirel University Faculty Of Arts And Science Journal Of Science , Cilt.18, Sa.2, Ss.62-75, 2023 (Hakemli Dergi)

Okul Öncesi Eğitimde Mobil Teknolojilerin Kullanılmasına Yönelik Örnek Bir Araştırma, Sezgin E., Tonguç G., Eğitim Ve Öğretim Araştırmaları Dergisi (Journal Of Research In Education And Teaching) , Cilt.5, Sa.Özel Sayı , Ss.296-304, 2016 (Hakemli Dergi)

Web Based Online Article Evaluating System (Akdeniz University Sample), Yücel F., Sezgin E., Oral O., Topakcı M. The International Journal Of Educational Researchers , Cilt.4, Ss.22-30, 2013 (Hakemli Dergi)

A Model For Common Courses In Higher Education: Web Based Student Grouping Software (Example Of Akdeniz University) Oral O., Sezgin E., Yücel F., Topakcı M., The International Journal Of Educational Researchers , Cilt.4, Ss.31-38, 2013 (Hakemli Dergi)

Web Based Online Article Evaluating System (Akdeniz University Sample)", Yücel F., Sezgin E., Oral O., Topakcı M., The International Journal Of Educational Researchers , Cilt.4, Sa.1, Ss.22-30, 2013 (Hakemli Dergi)

The Grouping Of Informatics Knowledge Levels Of The Students At Faculty Of Education Using K-Means Algorithms, Çetin H., Sezgin E., E-Journal Of New World Sciences Academy Education Sciences , Cilt.7, Sa.1, Ss.459-465, 2012 (Hakemli Dergi).