

**Derin Öğrenme Tabanlı Oftalmoloji Görüntülerinde Veri
Analizi ve Güvenliđi**

Caner ŐEN



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DERİN ÖĞRENME TABANLI OFTALMOLOJİ GÖRÜNTÜLERİNDE VERİ
ANALİZİ VE GÜVENLİĞİ**

Caner ŞEN
0000-0001-5405-8214

Doç. Dr. Gıyasettin ÖZCAN
(Danışman)

YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2022
Her Hakkı Saklıdır.

TEZ ONAYI

Caner ŞEN tarafından hazırlanan “DERİN ÖĞRENME TABANLI OFTALMOLOJİ GÖRÜNTÜLERİNDE VERİ ANALİZİ VE GÜVENLİĞİ” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Doç. Dr. Gıyasettin ÖZCAN

Başkan : Doç. Dr. Gıyasettin ÖZCAN
0000-0002-1166-5919
Bursa Uludağ Üniversitesi,
Mühendislik Fakültesi,
Bilgisayar Mühendisliği Anabilim Dalı

İmza

Üye : Prof. Dr. Ahmet Emir DİRİK
0000-0002-6200-1717
Bursa Uludağ Üniversitesi,
Mühendislik Fakültesi,
Bilgisayar Mühendisliği Anabilim Dalı

İmza

Üye : Prof. Dr. Eyyüp GÜLBANDILAR
0000-0001-5559-5281
Eskişehir Osmangazi Üniversitesi,
Mühendislik-Mimarlık Fakültesi,
Bilgisayar Yazılımı Anabilim Dalı

İmza

Yukarıdaki sonucu onaylarım

Prof. Dr. Hüseyin Aksel EREN
Enstitü Müdürü

.././.....

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

08/08/2022

Caner ŞEN

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME TABANLI OFTALMOLOJİ GÖRÜNTÜLERİNDE VERİ ANALİZİ VE GÜVENLİĞİ

Caner ŞEN

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Gıyasettin ÖZCAN

Oftalmolojik hastalıkların zamanında teşhisi yapılmadığında ve tedavisi olunmadığında körlüğe kadar giden sonuçlar ortaya çıkmaktadır. Birçok çalışma, erken tedavinin görmeyi tehdit eden bu hastalıklara yakalanılmasının önüne geçildiğini göstermiştir. Örneğin diyabetik retinopati hastalığı dünyadaki şeker hastalarının %80'ini etkilemektedir ve ikinci en büyük körlük nedenlerindedir. Katarakt ise genelde yaşa bağlı bir hastalık olduğu gibi zamanla görme bulanıklığını artırarak hastanın görüşünü engeller. Bu çalışmada oftalmolojik hastalıkların tespiti için derin öğrenme mimarileri kullanılmıştır. Böylece otomatik tespit sistemleri geliştirilerek sağlık hizmetlerinin hızlanması ve uzmanlara yardımcı olunması amaçlanmıştır. Bu amaçla oluşturulan modellerin yüksek doğruluğa sahip olmaları gerekmektedir.

Tez kapsamında, oftalmolojik hastalıklardan diyabetik retinopati ve kataraktın tespiti üzerine çalışılmıştır. İnsan retinasına ait bu oftalmolojik hastalıkları tespit etmek için; hastalıklı görüntü veri setleri üzerinde görüntü ön işleme, derin öğrenme ve transfer öğrenimi gibi yöntemlerle modeller geliştirilmiştir. Geliştirilen modeller ile, literatüre katkı sağlayan oranda yüksek sınıflandırma başarıları elde edilmiştir. Diyabetik retinopati için oluşturulan en iyi modelin 5 sınıflandırma ile %96,6 doğruluk oranına ve katarakt için oluşturulan en iyi modelin 2 sınıflandırma ile %97,2 doğruluk oranına ulaştığı ölçülmüştür. Elde edilen doğruluk oranları literatüre katkı sağlamaktadır. Yapılan analizlerde, transfer öğrenimi yönteminin klasik derin öğrenme yöntemlerinden en az %2 olmak üzere daha iyi bir sınıflandırma yapabildiği görülmüştür. Her hastalık için oluşturulan en iyi modeller, uzmanlar tarafından kullanılmak üzere bir web arayüzü ortamında kullanıma sunulmuştur. Bir sonraki aşamada web arayüzünde toplanan verilerin güvenlik gereksinimleri dikkate alınmıştır. Bu doğrultuda sunucuda saklı veriler, literatürde belirtilen en güvenilir algoritma ile şifrelenmekte olup hasta verisi gizliliği hedeflenmiştir. Bu sayede verilerin siber ortamda güvenilir şekilde saklanması sağlanmıştır.

Anahtar Kelimeler: Oftalmoloji, diyabetik retinopati, katarakt, derin öğrenme, transfer öğrenimi, bilgi güvenliği

2022, xiii + 60 sayfa.

ABSTRACT

MSc Thesis

DEEP LEARNING BASED DATA ANALYSIS AND SECURITY IN OPHTHALMOLOGY IMAGES

Caner ŞEN

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Assoc. Prof. Gıyasettin ÖZCAN

When ophthalmological diseases are not diagnosed and treated on time, results leading to blindness occur. Many studies have shown that early treatment can prevent these vision-threatening diseases. For example, diabetic retinopathy affects 80% of diabetic patients in the world and is the second biggest cause of blindness. Cataract, on the other hand, is generally an age-related disease and increases the blurring of vision over time, preventing the patient's vision. In this study, deep learning architectures were used for the detection of ophthalmological diseases. Thus, by developing automatic detection systems, it is aimed to speed up health services and to help specialists. Models created for this purpose must have high accuracy.

Within the scope of the thesis, the detection of diabetic retinopathy and cataract from ophthalmological diseases was studied. To detect these ophthalmological diseases of the human retina; Models have been developed on diseased image datasets with methods such as image preprocessing, deep learning and transfer learning. With the developed models, high classification success has been achieved, which contributes to the literature. It was measured that the best model created for diabetic retinopathy reached 96.6% accuracy with 5 classifications, and the best model created for cataracts reached 97.2% accuracy with 2 classifications. The obtained accuracy rates contribute to the literature. In the analysis, it has been seen that the transfer learning method can make a better classification, at least 2%, than the classical deep learning methods. The best models created for each disease are made available in a web interface environment for use by experts. In the next step, the security requirements of the data collected on the web interface were taken into account. In this direction, the data stored on the server is encrypted with the most reliable algorithm specified in the literature, and patient data confidentiality is aimed. In this way, it is ensured that the data is stored reliably in the cyber environment.

Key words: Diabetic retinopathy, cataract, deep learning, transfer learning, information security

2022, xiii + 60 pages.

TEŐEKKÜR

Eđitimim boyunca ve bu tez alıŐmasının yürütülmesinde, bilgi birikimi ve deneyimiyle deđerli zamanını ayırarak sabırla beni yönlendiren, alıŐmanın gerçekleştirilmesinde desteđini esirgemeyen deđerli danıŐmanım Do. Dr. Gıyasettin ÖZCAN'a sonsuz teŐekkürlerimi sunarım.

Ayrıca fikirleriyle, alıŐmaya olan ilgisi ve katkısıyla, özellikle alıŐma sonuçlarının doğrulanmasında sağladığı desteklerinden dolayı eş danıŐmanım Prof. Dr. Selim DOĐANAY'a teŐekkürlerimi sunarım.

Tezimin her aşamasında yardımlarını esirgemeyen deđerli arkadaşım Kađan Can ERDEN 'e teŐekkür ederim.

Ve ayrıca büyük emeklerle beni büyüten, hayatımın her anında yanımda hissettiđim sevgili annem Kadriye ŐEN'e ve sevgili babam Mustafa ŐEN'e sevgilerimi ve teŐekkürlerimi sunarım.

Caner ŐEN
08/08/2022

İÇİNDEKİLER

ÖZET..	v
ABSTRACT	vi
TEŞEKKÜR.....	vii
SİMGELER ve KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xiii
1. GİRİŞ	1
1.1. Problem Tanımı.....	1
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI	3
2.1. Kaynak Araştırması.....	3
2.2. Yapay Zeka	6
2.3. Makine Öğrenimi (Machine Learning)	7
2.3.1. Perceptron Modeli	8
2.4. Derin Öğrenme (Deep Learning)	9
2.5. Evrişimsel Sinir Ağları (Convolutional Neural Networks).....	10
2.5.1. Evrişim Katmanı	11
2.5.2. Düzleştirilmiş Lineer Birim Katmanı (ReLU)	12
2.5.3. Havuzlama Katmanı.....	12
2.5.4. Dropout Katmanı.....	13
2.5.5. Düzleştirme Katmanı.....	14
2.5.6. Tam Bağlantılı Katman	15
2.5.7. Softmax	15
2.5.8. Sınıflandırma Katmanı	15
2.6. Transfer Öğrenimi (Transfer Learning)	15
2.7. Retina	16
2.8. Diyabetik Retinopati	16
2.8.1. Anevrizma	17
2.8.2. Kanamalar	17
2.8.3. Eksüdalar	17
2.8.4. Diyabetik Retinopati Evreleri.....	18
2.9. Katarakt	19
2.10. Simetrik ve Asimetrik Şifreleme.....	19
2.10.1. AES Algoritması ve Çalışma Prensipleri	21
3. MATERYAL ve YÖNTEM.....	23
3.1. Veri Seti.....	23
3.1.1. Diyabetik Retinopati	23
3.1.2. Katarakt	25
3.2. Veri Artırma	27
3.2.1. Test Süresi Artırımı (Test-Time Augmentation).....	27
3.3. Deney Araçları	28
3.4. Ön İşleme	28
3.4.1. Ortalama Filtre (Mean Subtraction)	29
3.4.2. Normalizasyon ve Z skoru Normalizasyonu.....	29
3.4.3. Gauss Bulanıklaştırma Filtresi (Gaussian Blur Filter).....	29
3.5. Performans Ölçütleri	33
3.6. Klasik Derin Öğrenme Yöntemi ile Kullanılan Ağlar	34
3.6.1. EfficientNet	34

3.6.2. XceptionNet	35
3.7. Transfer Öğrenimi Yöntemi ile Kullanılan Derin Öğrenme Ağları.....	35
3.7.1. VggNet	35
3.7.2. ResNet	35
3.7.3. DenseNet	36
3.8. Modellerin Kullanılacağı Web Uygulaması ve Uygulama Arayüzünde Hastalık Teşhisi	36
3.9. Web Uygulamasında Bilgi Güvenliğinin Sağlanması.....	38
4. BULGULAR ve TARTIŞMA.....	39
4.1. Diyabetik Retinopati Tespiti için Eğitilen Modellerin Bulguları.....	39
4.1.1. XceptionNet	39
4.1.2. EfficientNet	39
4.1.3. DenseNet121	41
4.1.4. ResNet50	44
4.2. Katarakt Tespiti için Eğitilen Modellerin Bulguları	46
4.2.1. Vgg16	46
4.2.2. ResNet50	48
4.2.3. EfficientNetB0.....	51
4.3. Farklı Yöntemlerle Oluşturulan Modellerin Karşılaştırılması	52
5. SONUÇ	54
KAYNAKLAR	55

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
μ	Ortalama
$\hat{\sigma}$	Standart sapma
Z	Z skoru normalizasyonu
κ	Karesel kappa katsayısı
w	Ağırlık
i	Gerçek derecelendirme katsayıları
j	Tahmini derecelendirme katsayıları
x	Gerçek derecelendirmenin histogram matrisi
m	Beklenen derecelendirmenin histogram matrisi
G	Gauss bulanıklaştırma fonksiyonu
Kısaltmalar	Açıklama
AES	Gelişmiş Şifreleme Standardı
APTOSBD	APTOS 2019 Blindness Detection
BT	Bilgisayarlı Tomografi
CNN	Evrişimsel Sinir Ağları
DCNN	Derin Evrişimli Sinir Ağı
DN	Doğru Negatif
DÖ	Derin Öğrenme
DP	Doğru Pozitif
DR	Diyabetik Retinopati
DRN	Derin Artık Ağ
HPOR	Hafif Proliteratif Olmayan Retinopati
MA	Mikroanevrizma
MLP	Çok Katmanlı Algılayıcılar
MÖ	Makine Öğrenimi
NPDR	Proliteratif Olmayan Retinopati
ODIR	Ocular Disease Intelligent Recognition
ODPOR	Orta Derece Proliteratif Olmayan Retinopati
PR	Proliteratif Retinopati
QWK	Karesel Ağırlıklı Kappa
ReLU	Düzleştirilmiş Lineer Birim
RVM	Uygunluk Vektör Makinesi
SVM	Destek Vektör Makinesi
ŞNR	Şiddetli Proliteratif Olmayan Retinopati
TTA	Test Süresi Artırımı
YN	Yanlış Negatif
YP	Yanlış Pozitif

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1. (a) Perceptron sözde kodu (b) perceptron tahmini sözde kodu	9
Şekil 2.2. Örnek CNN mimarisi.....	11
Şekil 2.3. Görüntü üzerine filtre uygulanması.....	12
Şekil 2.4. ReLU aktivasyon fonksiyonu.....	12
Şekil 2.5. (a) Maksimum havuzlama ve (b) ortalama havuzlama.....	13
Şekil 2.6. (a) Normal CNN ağı (b) ağın dropout işlemi uygulandıktan sonraki yapısı (İnik ve ark., 2017).....	14
Şekil 2.7. Düzleştirme işlemi.....	14
Şekil 2.8. Retinal fundus görüntüsündeki temel yapılar.....	16
Şekil 2.9. DR teşhisinde bakılması gereken oluşumlar (Anonim2022a).....	18
Şekil 2.10. Simetrik şifreleme.....	20
Şekil 2.11. Bayt değiştirme işlemi.....	21
Şekil 2.12. Satır öteleme işlemi.....	22
Şekil 3.1. Kullanılan veri setinde etiketlerin dağılımı.....	23
Şekil 3.2. Etiketli verilerin örnek görünüşleri.....	24
Şekil 3.3. Kataraktlı hasta verilerinin etiketlenmiş örnek görünüşleri.....	26
Şekil 3.4. Kataraktı olmayan hasta verilerinin etiketlenmiş örnek görünüşleri.....	26
Şekil 3.5. TTA uygulanmış örnek görüntü verisi.....	28
Şekil 3.6. Gauss bulanıklaştırma filtresi uygulanmış örnek diyabetik retinopati verileri.....	31
Şekil 3.7. Gauss bulanıklaştırma filtresi uygulanmış örnek renklendirilmiş diyabetik retinopati verileri.....	32
Şekil 3.8. Residual blok (He ve ark., 2015).....	36
Şekil 3.9. Uygulama arayüzünde diyabetik retinopati hastalığı teşhisi.....	37
Şekil 3.10. Uygulama arayüzünde katarakt hastalığı teşhisi.....	37
Şekil 4.1. EfficientNetB5 modeli şeması.....	40
Şekil 4.2. EfficientNetB5 modeli doğruluk grafiği.....	40
Şekil 4.3. EfficientNetB5 modeli kayıp grafiği.....	40
Şekil 4.4. DenseNet121 modeli şeması.....	41
Şekil 4.5. DenseNet121 modeli doğruluk grafiği.....	42
Şekil 4.6. DenseNet121 modeli kayıp grafiği.....	42
Şekil 4.7. DenseNet121 modeli karmaşıklık matrisi.....	43
Şekil 4.8. ResNet50 modeli şeması.....	44
Şekil 4.9. ResNet50 modeli doğruluk grafiği.....	44
Şekil 4.10. ResNet50 modeli kayıp grafiği.....	45
Şekil 4.11. ResNet50 modeli karmaşıklık matrisi.....	45
Şekil 4.12. Vgg16 modeli şeması.....	46
Şekil 4.13. Vgg16 modeli doğruluk grafiği.....	47
Şekil 4.14. Vgg16 modeli kayıp grafiği.....	47
Şekil 4.15. Vgg16 modeli karmaşıklık matrisi.....	48
Şekil 4.16. ResNet50 modeli şeması.....	49
Şekil 4.17. ResNet50 modeli doğruluk grafiği.....	49
Şekil 4.18. ResNet50 modeli kayıp grafiği.....	49
Şekil 4.19. ResNet50 modeli karmaşıklık matrisi.....	50

Şekil 4.20.	EfficientNetB0 modeli şeması.....	51
Şekil 4.21.	EfficientNetB0 modeli doğruluk grafiği.....	51
Şekil 4.22.	EfficientNetB0 modeli şeması.....	52

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1. APTOSBD veri seti sınıflarına ait veri sayısı.....	24
Çizelge 3.2. ODIR veri seti sınıflarına ait veri sayısı.....	25
Çizelge 3.3. Karmaşıklık matrisi ((TOĞAÇAR, 2021)'dan alınarak değiştirilmiştir.).....	33
Çizelge 3.4. EfficientNet ağları ve ölçekleri 3.5.....	35
Çizelge 4.1. DenseNet121 modeli performans sonuçları.....	43
Çizelge 4.2. DenseNet121 modeli doğruluk ve QWK sonuçları.....	43
Çizelge 4.3. ResNet50 modeli performans sonuçları.....	46
Çizelge 4.4. ResNet50 modeli doğruluk ve QWK sonuçları.....	46
Çizelge 4.5. Vgg16 modeli performans sonuçları.....	48
Çizelge 4.6. Vgg16 modeli doğruluk ve QWK sonuçları.....	48
Çizelge 4.7. ResNet50 modeli performans sonuçları.....	50
Çizelge 4.8. ResNet50 modeli doğruluk ve QWK sonuçları.....	50
Çizelge 4.9. Farklı mimari ve yöntemlerle oluşturulan modellerin karşılaştırılması.....	53

1. GİRİŞ

1.1. Problem Tanımı

Oftalmoloji, gözde meydana gelen hastalıklar ve bunların cerrahisiyle uğraşan tıp içerisindeki bir anabilim dalıdır. Günümüzde, göz hastalıkları içerisindeki katarakt ve şekerle bağlı diyabetik retinopati hastalıkları çok yaygın hale gelmişlerdir. Bu hastalıkların özellikle erken evrede tespiti, tedavinin başarısını önemli ölçüde artıracaktır. Dolayısıyla hastalıkların erken tespiti için yapay sinir ağları ve derin öğrenme yöntemleri ile hastalığı tanıyabilen modeller geliştirilmiştir.

Diyabetik retinopati (DR), tedavi edilmediği zaman görme kaybına kadar ilerleyen, dünyadaki şeker hastalarının %80'ini etkileyen en yaygın göz hastalıklarından biridir. Çoğu hastalıkta olduğu gibi bu hastalıkta da erken teşhis çok önemlidir. Teşhisi, hastanın fundus görüntülerinin alanında uzman kişiler tarafından yorumlanmasıyla yapılır. Teşhis adımının kolaylaştırılması, zaman ve kaynak açısından çok değerli olacaktır (Tymchenko ve ark., 2020).

Katarakt, doğuştan veya yaşlanmaya bağlı olarak göz merceğinde oluşan bulanıklık olarak tanımlanmaktadır. Tedavi olunmadığında körlüğe kadar giden sonuçlar doğurmakta olup, cerrahi yöntemler ile tedavi edilebilir bir hastalıktır.

Derin Öğrenme (DÖ), üç boyutlu bilgisayarlı tomografi görüntüleri üzerinde kanser lokalizasyonu, diş röntgen görüntülerinin analizi, manyetik rezonans görüntüleme, dokuların biyopsi örneklerini tanıma gibi tıbbi görüntüleme sistemleri oluşturmak için ana akım yöntemi haline gelmiştir. Bir öğrenme modeli oluşturmak için genellikle büyük miktarda veriye ihtiyaç duyulmaktadır. Diğer alanlardaki uygulamaların aksine, sağlık uygulamalarındaki veriler için alanında uzman kişilerin veri etiketlemesi üzerinde çalışması gerekir. Genel olarak tek bir uzmanın etiketleyici görevinde olması yeterli değildir. Çünkü her uzmanın kendi deneyimi, görsel algısı ve sorunu anlama düzeyi vardır. Uzmanlar arasındaki görüş farklılıklarını azaltmak etiketlerin sağlam temeller üzerine kurulmasını sağlayacaktır. Böylece doğru etiketlenmiş veriler öğrenme sonucunun doğruluğunu önemli ölçüde artıracaktır. Bu durumda veri toplama ve etiketleme süreci önemli ölçüde zaman ve kaynak gerektirecektir.

Medikal görüntü verilerinde yapay zeka ile tahmin yapmada son zamanlarda artış yaşanmıştır. Bu durumun iki temel sebebi vardır; görüntü verilerinin dijitalleştirilmesiyle oluşturulan veri setlerindeki artış ve bilgisayarların hesaplama gücündeki artış ile birlikte yapay zeka tekniklerinin gelişimidir.

Öte yandan yapay zeka ile alınan sonuçlar erken teşhis konusunda doktorlara yardımcı olmaktadır. Bu durum ayrıca sosyal ve ekonomik hayata dolaylı olarak katkı sunmaktadır.

Bu tez çalışmasında DR ve kataraktın tespiti için etiketlenmiş veriler ile DÖ modelleri kullanılmıştır. Öğrenme öncesinde verilerin yakınlaştırıp uzaklaştırılması, döndürülmesi gibi işlemler yapılarak verilerin çoğaltılması sağlanmıştır. Ayrıca verilere çeşitli ön işleme teknikleri kullanılarak hastalığın görüldüğü yerlerin daha belirginleştirilmesi ve anlaşılabilir hale getirilmesi sağlanmıştır. Çalışmada yapay sinir ağları ve DÖ yöntemleri kullanılarak yüksek doğruluğa sahip modeller geliştirilmiş ve böylece diyabetik retinopati ve katarakt gibi oftalmolojik hastalıkların hızlıca tespitinin yapılması sağlanmıştır. Bu işlemler python programlama dili ile gerçekleştirilmiştir. Ortaya çıkarılan modellerden başarılı olanların performans ölçütleri de sunulmuştur.

Tez çalışması sonucunda oluşturulan başarılı modeller, web arayüzünde hastalıkların hızlı tespiti için kullanılmıştır. Kullanıcılar hastaların görüntü verilerini web ara yüzünden yükleyerek sonuca ulaşmaktadırlar. Ayrıca sunucuya yüklenen hasta görüntü verilerinin güvenliği sağlanmıştır. Güvenliğin sağlanmasında veriler için şifreleme algoritmaları, sunucu için ise güvenlik duvarı ve güvenlik yazılımları kullanılmıştır.

2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

2.1. Kaynak Araştırması

Son yıllarda, çoğu araştırmacı DR ve katarakt lezyonlarını tespit etmek ve bunları farklı tiplerde sınıflandırmak için çeşitli görüntü işleme teknikleri, veri setleri, öğrenme teknikleri ve algoritmalar kullanılmıştır.

Literatürde yer alan diyabetik retinopati çalışmalarından bazıları şunlardır;

(S. B. Junior & D. Walfer, 2013), kanama segmentasyonu için farklı bir metodoloji önermiştir. Bu teknik, kan damarlarının görüntüden çıkarılmasına dayanmaktadır. Kan damarlarını tespit etmek için çok ölçekli yapılandırma elemanları ile morfolojik açıklık kullanılmıştır. Daha sonra kan damarları görüntüden çıkarılmıştır. Böylece sadece kanamalar segmente edilmiştir. Bu metodoloji %87,69 hassasiyete ulaşmıştır. Ancak, bu çalışma metodolojinin doğruluk testini dikkate almamaktadır. Doğruluk, algoritma performansını test etmek için önemli bir faktördür.

(Kleawsirikul ve ark., 2013), görüntünün kapanması ve görüntünün açılması arasındaki farkı bularak görüntüyü ikili hale getiren bir filtre olan morfolojik silindir şapka dönüşümü kullanarak kanamaları tespit etmek için otomatik bir algoritma sunmuştur. Bu çalışmada beyaz pikseller kan damarlarını ve kanamaları ve siyah pikseller görüntü arka planını temsil etmektedir. Daha sonra görüntüden renk, alan, kompaktlık özellikleri çıkarılmış ve kural tabanlı sınıflandırma kullanılarak kanamalar sınıflandırılmıştır. Kanama sınıflandırması, hastalığın var veya yok olması düşünülerek oluşturulmuş ve %99,12 doğruluk elde edilmiştir. Ancak bu çalışmanın duyarlılığı düşük olup %80,37'dir. Ayrıca, bu çalışmanın sadece 20 görüntüyü dikkate alma dezavantajı vardır.

(Y. Hou, 2014), kan damarlarını segmentlere ayırmak için çok ölçekli bir çizgi algılama metodolojisi sunmuştur. Temel bir çizgi dedektörü, retina kan damarlarının morfolojik özelliklerini kullanarak damar tepkileri üretmektedir. Her piksel damarlı veya damarsız olarak tanımlanmıştır. Araştırmacı, değişen ölçeklerde damar tepki görüntüleri üretmek için çok ölçekli bir çizgi dedektörü geliştirmiştir. Daha fazla damar yanıtına sahip çizgi dedektörü, parçalı damar görüntüsü olarak kabul edilmiştir. Bu çalışma %93,36 doğruluk elde etmiştir. Ancak duyarlılık %73,48 ile düşük olarak ölçülmüştür. Buna benzer olarak

(Ricci & Perfetti, 2007), çizgi dedektörlerine ve SVM'ye dayanan bir algoritma önermiş ve Hou'un çalışmasından daha iyi bir doğruluk oranı (%96,46) elde etmişlerdir. Yine bunlara benzer olarak (Pradeepa & Raja, 2014), kan damarlarını segmentlere ayırmak için SVM tabanlı yöntemi uygulamıştır. Farklı öznelikleri çıkarmak için Gabor filtresi ve eşikleme teknikleri uygulanmıştır. Pradeepa'nın çalışması %90 doğruluk sağlamıştır. Ancak çalışmada duyarlılık ölçümü yapılmamıştır.

(Özçelik & Altan, 2021), DÖ tabanlı ve iki aşamalı bir model geliştirmişlerdir. İlk aşamada modelin aşırı öğrenmesinin engellenmesi için iki boyutlu sinyal işleme tekniği uygulanmıştır. İkinci aşamada CNN ve transfer öğrenimi yöntemlerinden faydalanmışlardır. Çalışmalarında 5100 fundus görüntü verisini eğitim amaçlı ve 900 fundus görüntüsünü test amaçlı kullanmışlardır. Model, DR yok, HPOR, ODPOR, ŞNR, PR şeklinde 5 sınıfa ayrılmıştır ve modelin performansı %97,8 olarak ölçülmüştür.

(Athira & Ferlin, 2014), büyük kanamaları segmentlere ayırmak için splat future tekniğini kullanmıştır. Bu teknikte, görüntü splat adı verilen bölümlere bölünmüştür. Splatlarda, aynı renk ve uzamsal konumdaki pikseller bulunmaktadır. Her bir splattan çok çeşitli özellikler çıkarılarak en iyi splat özelliğinin seçilmesi için ortalama filtre kullanılmıştır. Aslında bu çalışma, kan damarlarıyla örtüşen büyük kanamaları bölümlere ayırma avantajına sahiptir. Ancak görüntü ön işleme teknikleri, hassasiyet hesaplaması ve doğruluk ölçümü çalışmaya dahil edilmemiştir.

(Reza ve ark., 2008), ortalama filtreleme, kontrast ayarı, morfolojik açma ve havza dönüşümüne dayalı bir görüntü işleme tekniği kullanarak eksüdalı segmentlere ayırmak için bir algoritma sunmuştur. Eksüda segmentasyonuna yönelik metodolojileri %96,7'lik yüksek hassasiyete ulaşmıştır.

(Kaur & Talwar, 2015), Fuzzy sinir ağlarını kullanarak kan damarlarını segmentlere ayırmak için bir metodoloji sunmuştur. Her piksel damarlı veya damarsız olarak sınıflandırılmıştır. Bu metodoloji %87,4 hassasiyete ulaşmıştır. Ancak doğruluk ölçümü değerlendirilmemiştir. Çalışmalarının ana avantajı, metodolojilerinin farklı göz hastalıklarının görüntüleri üzerinde test edilmiş olmasıdır.

(Yalcin ve ark., 2018), DÖ tabanlı iki aşamadan oluşan bir yaklaşım sunmuşlardır. İlk aşamada retina görüntülerine ön işleme uygulanarak görüntülerinden gürültünün arındırılması sağlanmıştır. İkinci aşamada ise CNN yöntemiyle DR var ve DR yok olarak iki sınıflandırılma yapılmış ve %98,5 başarı elde edilmiştir.

(Selvathi & Vaishnavi, 2011), Gabor dalgacık dönüşümü kullanılarak retina kan damarı segmentasyonu için bir yöntem önerdi. Her pikseli, pikselin özellik vektörüne dayalı olarak damarlı veya damarsız olarak sınıflandırmak için SVM ve RVM sınıflandırıcıları kullanıldı. Bu çalışmanın dezavantajı, en iyi sonucun 252 saniyede verildiği uzun hesaplama süresidir.

(Aravind ve ark., 2013), morfolojik operasyonlar kullanarak DR'nin ilk klinik belirtisi olan mikroanevrizmaları saptamak için bir yöntem geliştirmiştir. Alan, entropi, korelasyon, enerji, kontrast, homojenlik ve ortalamanın (mean) özellikleri çıkarıldı. Ardından, her bir görüntüyü; normal retina (hastalık yok), HPOR ve ŞNR olarak sınıflandırmak için SVM uygulandı. Bu çalışmanın duyarlılığı ve doğruluğu sırasıyla %92 ve %90 olarak ölçülmüştür. Bu tür çalışmalar, NPDR görüntülerini hafif veya şiddetli sınıflara göre sınıflandırma avantajına sahiptir. Ancak, orta düzeyde NPDR tespit edemez.

(SujithKumar & Vipula, 2012), Uyarlamalı Histogram Eşitleme ve eşikleme kullanarak MA'ları tespit etmek için bir algoritma oluşturdu. Algoritma, her giriş görüntüsünü normal retina veya NPDR'ye sınıflandırmıştır. NPDR görüntüleri, tespit edilen MA'ların sayısına göre hafif, orta veya şiddetli sınıflara ayrılmıştır. Aravind ve ark.'nın aksine, SujithKumar ve ark. HPOR ve ŞNR arasında ayırım yapabildiler. Bu çalışmanın doğruluğu %94,44 olup duyarlılık ölçümü yapılmamıştır.

(Sundhar & Archana, 2014), DR'yi saptamak için otomatik tarama (automatic screening) yöntemini önerdi. Bu yöntem ile, eksüdaların ve MA'ların boyutunu iyi bir şekilde tespit etti. Fundus görüntülerini normal, NPDR ve PDR olarak sınıflandırmak için yapay sinir ağları kullanılmıştır. Sınıflandırma sonucunda çalışma %92,5 hassasiyete ulaşmıştır. Sundhar ve Archana, PDR'yi tespit edebilmiş olsalar da çalışmalarının dezavantajı sınıflandırma testinde az sayıda (40) görüntü verisi kullanmalarıydı.

(Tjanrasa & Anggoro, 2015), NPDR'yi orta veya şiddetli sınıflara ayırmaya odaklanmıştır. Eksüdalar, K-Means kümelemesi kullanılarak bölümlere ayrılmıştır. Çalışmada üç farklı sınıflandırıcı kullanılmıştır. Sinir ağları sınıflandırıcılarından biri olan MLP kullanılmış olup %91,07 doğruluk ölçümü yapılmıştır.

(Jagatheesh & Jenila, 2015), Bag of Visual Words modelini kullanarak DR lezyonlarını saptamak için bir yöntem geliştirmiştir. Model, yerel görüntü tanımlayıcılarını, sınıflandırmada dikkate alınan temsili görüntülere dönüştürmektedir. Bu model, görüntüdeki ilgi noktaları etrafında çok sayıda özellik vektörü tespit etmeyi amaçlamaktadır. Tespit edilen özellikler daha sonra görsel bir sözlüğe dayalı olarak görsel kelimelere atanır. Jagatheesh ve Jenila'nın çalışması, eksüda tespiti için %84,21 doğruluk ve %76,62 hassasiyet, kanama tespiti için %75,2 doğruluk ve %74,57 hassasiyet elde etmiştir.

Literatürde yer alan katarakt ile ilgili çalışmalardan bazıları şunlardır;

(AĞALDAY & ÇINAR, 2021), CNN ve DRN kullanarak iki farklı sınıflandırma yöntemi oluşturmuşlardır. Veri seti olarak 5000 hastanın sağ ve sol gözlerine ait renkli fundus görüntülerini kullanmışlardır. Veri setinde 8 farklı etiket ile sınıflandırma yapılmıştır. Oluşturulan modellerde derin artık ağ yönteminin CNN yöntemine göre daha başarılı sonuç verdiği görülmüştür. CNN modelinin doğruluk oranı %89 iken DRN modelinin doğruluk oranının %95 olduğu ölçülmüştür.

(Zhang ve ark., 2017), DCNN kullanarak performans ve verimlilik araştırması yapmayı amaçlamışlardır. Hastanelerden toplanan 5620 görüntü verisi kullanmışlardır. DCNN sınıflandırması için önemli bir katkı sağlayan g-filtresi kullanılarak yansıma gürültüsünden kurtulmuşlardır. Yöntemlerinden elde ettikleri en iyi doğruluk %93,52 ve en iyi katarakt saptama ve derecelendirmesi %86,69 olarak ölçülmüştür.

2.2. Yapay Zeka

Yapay zeka, farklı alanlardaki spesifik problemlerin çözümüne yönelik insan zekâsının taklit edilmesi ve ilerletilmesi ile ilgili çalışmaları bünyesinde barındırmaktadır. Buna benzer birçok tanımı vardır. Diğer tanımlardan birkaçı şu şekildedir; insan zekâsına benzer makine uygulamaları yapmak ve geliştirmek; insanlara özgü olan yorumlama,

tecrübe ile öğrenme, karar verme gibi zihinsel davranışları uygulayabilme yeteneği (Çilhoroz Y & Işık O, 2021); karmaşık problemleri çözen ve yeni problemlere tepki oluşturabilen programlardır (Arslan ve ark., 2020).

Yapay zekanın tarihsel gelişimine bakıldığında 1952’de üçtaş oyununu oynayabilen ilk program yazıldı (Samuel, 1959). 1964-1966 yılları arasında Joseph Weizenbaum tarafından MIT’in yapay zeka laboratuvarında ilk doğal dil işleme programı yazıldı. 1968’de Terry Winograd bilgisayarların İngilizce cümleleri anlayabileceğini ispatladı. 1980’lerde John Hopfield ve David Rumelhart derin öğrenmeyi yapay zeka alanına kazandırdı. 1990’larda yapay sinir ağları geliştirildi. 1997 yılında IBM tarafından geliştirilen Deep Blue satranç oynama programı dünya satranç şampiyonu Kasparov’u yendi. 2000 yılında Honda akıllı insan robotu ASIMO’yu duyurdu. 2009 yılında Google sürücüsüz arabalar geliştirmeye başladı (Arslan ve ark., 2020; İŞLER & KILIÇ, 2017).

Yapay zeka, insanların yaptıkları işleri daha hızlı ve daha verimli yapmaktadır. Özellikle sağlık alanında erken teşhis, karar verme, tedavi ve sağlığı koruyarak devam ettirme gibi alanlarda kullanılmaktadır. Yapay zeka uygulamasının doğru teşhis ve tedavi üretebilmesi için elde edilen verilerin doğru analiz edilmesi ve doğru etiketlenmesi gerekmektedir (Buyukgoze, 2019).

2.3. Makine Öğrenimi (Machine Learning)

Makine Öğrenimi (MÖ), bir bilgisayarın öğrenmesini sağlamak için algoritmaların ve tekniklerin geliştirilmesi, anlaşılması ve değerlendirilmesi ile ilgilenen yapay zekanın bir alt alanıdır. MÖ istatistik, finans, insan psikolojisi ve beyin modelleme gibi diğer disiplinlerle bağlantılıdır. Birçok MÖ algoritması, model oluşturmak için veri analizini kullandığından, istatistik bu alanda önemli bir rol oynar (Mitchell & Mitchell, 1997).

MÖ algoritmaları, bir model oluşturmak için veri kümesine ihtiyaç duyar. İlk bakışta veri kümesi karmaşık gibi görünse de daha yakından incelendiğinde içinde örüntüler ve ilişkiler bulabiliriz. Ayrıca verileri oluşturan mekanizma hakkında bir fikir ediniriz. Veri kümesi, örneklerin bir koleksiyonudur. Her örnek, o örneğin özelliklerini tanımlayan bir dizi öznitelikten oluşur. Bir öznitelik, öznitelik türüne göre ayrık veya sürekli olabilen bir dizi değer alır.

Her örnek, bir dizi girdi özneliği ve bir çıktı özneliğinden oluşur. Girdi öznelikleri, öğrenme algoritmasına verilen bilgilerdir ve çıktı özneliği, aktivitenin bu bilgi üzerindeki geri bildirimini içerir. Çıktı özneliğinin değerinin, girdi özneliklerinin değerlerine bağlı olduğu varsayılır. Öznelik, kendisine atanan değerle birlikte, bir örneği bir özellik vektörü yapan bir özelliği tanımlar. Bir algoritma tarafından oluşturulan model, örnekteki girdi özneliklerini çıktı özneliğinin bir değerine eşleyen bir işlev olarak görülebilir (Dietterich, 1990).

Bir algoritmanın, girdi verileriyle etkileşime dayalı olarak bir problemi modellemesinin farklı yolları vardır. Bir algoritmanın benimseyebileceği öğrenme stillerini veya öğrenme prosedürlerini dikkate almak, MÖ'de yaygındır. Bu öğrenme stilleri şu şekillerde tanımlanır (El Naga & Murphy, 2015):

Denetimli öğrenme; girilen verilere eğitim verileri denir ve veriler etiketlenmiştir. Tahmin yapılması gereken bir eğitim süreci ile bir model hazırlanır ve bu tahminler yanlış olduğunda düzeltilir. Eğitim süreci, model eğitim verilerinde istenen doğruluk düzeyine ulaşana kadar devam eder. Örnek problemler, sınıflandırma ve regresyondur.

Denetimsiz öğrenme; girdi verileri etiketlenmemiştir ve bilinen bir sonucu yoktur. Girdi verilerinde bulunan yapılar çıkarılarak bir model hazırlanır. Örnek problemler, birliktelik kuralı öğrenme ve kümelemedir.

Yarı denetimli öğrenme: Girdi verileri, etiketli ve etiketsiz örneklerin bir karışımıdır. İstenen bir tahmin problemi var ama modelin tahminlerde bulunmanın yanı sıra verileri organize edecek yapıları da öğrenmesi gerekmektedir. Örnek problemler, sınıflandırma ve regresyondur.

2.3.1. Perceptron Modeli

Perceptron algoritması ilk olarak 1957'de Frank Rosenblatt tarafından yayınlandı. Yapay zeka alanının erken büyümesinde ve gelişmesinde oldukça etkili olan perceptron, bilgisayarların verileri ayrı kategorilere ayırmayı yinelemeli olarak öğrenmesi için ilk yöntemlerden birini sağladı (Rosenblatt, 1958).

En temel perceptron algoritması, Şekil 2.1 (a)'daki sözde kod ile gösterildiği gibi aşağıdaki adımlara sahiptir (McCulloch & Pitts, 1943). Eğitime başlamadan önce, w ağırlık vektöründeki her bir parametre sıfır olarak alınır. Eğitim seti, etiketin 0 veya 1 olduğu, etiketlerle eşleştirilmiş eğitim örneklerini içerecek şekilde formatlanmıştır. Perceptron algoritması, iki iç içe döngüden oluşur. Dış döngü, tüm eğitim seti boyunca yineleme sayısını kontrol etmek için epoch sayısını kullanır. İç döngü, eğitim kümesindeki her eğitim örneği için yürütülür ve iki ana adımı vardır; tahmin ve güncelleme. İlk olarak, eğitim örneğindeki n -boyutlu veriler ve ağırlık vektörü, eğitim örneğinin gerçek etiketini kullanmadan bu örnek için perceptronun tahmin edilen etiketini hesaplamak için kullanılır. Şekil 2.2 (b)'de sözde kodda gösterilen perceptron tahmini hesaplaması, verilen örneğe göre tahmin yapılması için ağırlık vektörünü ve tek bir eğitim örneğini girdi olarak alır.

```
(w:Params) (epochs:nat) (training set:list (Label * Data))
for i in epochs:
  for j in size(training set):
    (example, true label) = training set[j]
    predict = Predict(example, w)
    if predict != true label:
      w = w + training set[j].
(a)

(example:Data) (w:Params) :=
(bias, weight) = w
bias + dot product(weight, example).
(b)
```

Şekil 2.1. (a) Perceptron sözde kodu (b) perceptron tahmini sözde kodu

2.4. Derin Öğrenme (Deep Learning)

DÖ insan beyninin içindeki nöronlar düşünülerek tasarlanmış, çok fazla etiketli veriler üzerindeki özellikleri tespit ederek öğrenmiş modeller oluşturmak için kullanılan bir yapay zekâ yöntemidir (LeCun ve ark., 2015). Çok fazla katmandan oluşan bu yöntem, derin sinir ağları olarak da isimlendirilmektedir (Özçelik & Altan, 2021).

Günümüzde DÖ, makine öğrenmesi algoritmalarının yeterli olmadığı durumlarda kullanılmakta ve başarılı sonuçlar vermektedir. DÖ sinir ağlarının bir uzantısı olup çok

katmanlı sinir ağlarından biri olarak görülmektedir. Klasik yapay sinir ağlarının yetersiz kaldığı durumlarda çok katmanlı sinir ağları ile DÖ modelleri oluşturulabilmektedir (KELEŞ, 2018). Öyle ki klasik yapay sinir ağları birkaç katmandan oluşurken, derin sinir ağları olarak da adlandırılan çok katmanlı yapılar onlarca katmandan oluşabilir. Böylece verilerdeki karmaşıklık durumları ve doğrusal olmayan durumlar model tarafından öğrenilebilir hale gelmektedir. Günümüzde veri setlerinin ve karmaşık durumların artması ile DÖ popüler hale gelmiştir.

DÖ terimi, (Dechter, 1986) tarafından makine öğrenimine ve daha sonra (Aizenberg ve ark., 2000) tarafından beyinden ilham alan algoritmalara tanıtıldı. DÖ, bilgisayarla görme (He ve ark., 2016), doğal dil işleme (Deng & Liu, 2016), konuşma işleme (Deng & Yu, 2014), veri madenciliği (Witten ve ark., 2005) ve otonom araçlar (Sun ve ark., 2006) gibi birçok alanı önemli ölçüde yeniden şekillendirmiştir.

DÖ kütüphanelerinin ve algoritmalarının kısa zaman içerisinde gelişimi ve medikal görüntü verilerinden hastalıkların tespitinde de gösterdiği başarılı sonuçlarla, DÖ tabanlı uygulamaların geliştirilmesi ve hizmete sunulmasında önemli etkiye sahip olmuştur (POLAT & ÖZERDEM, 2021).

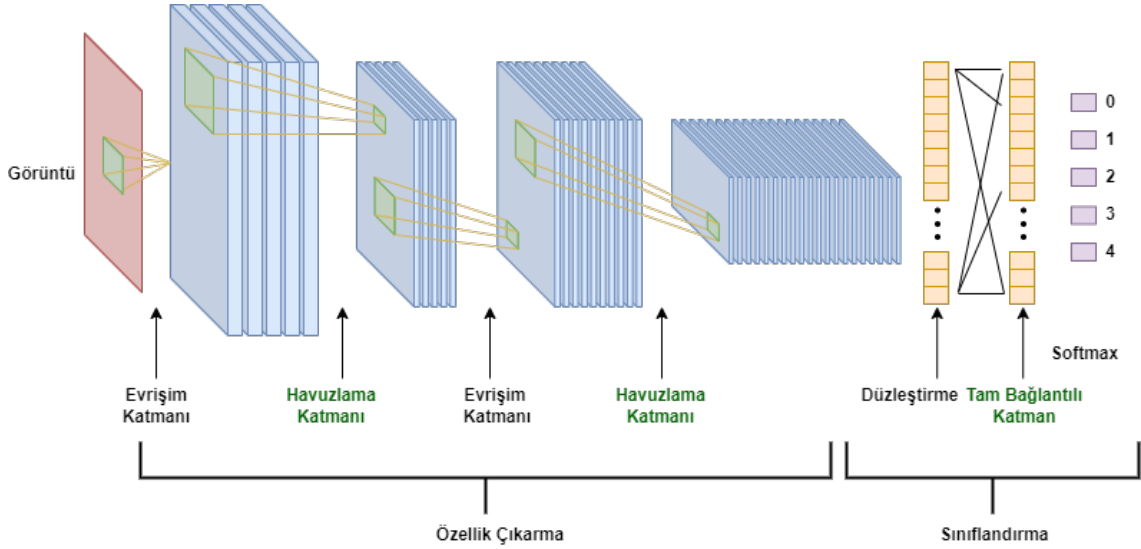
2.5. Evrimsel Sinir Ağları (Convolutional Neural Networks)

DÖ'nün amacı çok boyutlu verilerden özelliklerin çıkartılması ve buradaki gerekli çıktıların girdilerle ilişkilendirilmesiyle bir sonuca varmaktır. Bu karmaşık özelliklerin çıkartılması için genellikle çok katmanlı DÖ algoritmaları kullanılır (Fukushima & Miyake, 1982). Bu algoritmalarından biri de görüntüleri yüksek doğruluk oranı ile çözümleyen ve sınıflandıran görme modellerinden biri olan Convolutional Neural Networks (CNN)'dir (DANDIL & SERİN, 2020). CNN şu bölümlerden oluşur;

[Ön işleme yapılmış görüntü → evrişim katmanı ve ReLU → havuzlama katmanı] * K
→ [Tam Bağlantılı Katman → ReLU] * L → Tam Bağlantılı Katman → Sınıflandırma

K ve L, her işlemin gerçekleştirilme sayısını temsil eder. Öncelikle ön işlenmiş görüntüye evrişim katmanı uygulanır. Evrişim katmanı komşu piksellerden veri çıkarımı yapmak için daha küçük alanlarda evrişimler gerçekleştirir. Verilerdeki doğrusal ve doğrusal olmayan ilişkileri çıkarmak için evrişim katmanından sonra ReLU uygulanır. Son

olarak verilerden en anlamlı bilgiyi çıkarmak için ReLU'dan gelen çıktıya havuzlama uygulanır. Havuzlama katmanında piksel sayısı azaldıkça, görüntü verisinin boyutuna bağlı olarak bu işlemler tekrarlanabilir. Şekil 2.2'de örnek bir CNN mimarisi gösterilmiştir.



Şekil 2.2. Örnek CNN mimarisi

CNN modellerinde eğitimin daha hızlı yapılması ve başarımın daha iyi olması için ön eğitilmiş (pre trained) ağlar kullanılır. Ön eğitilmiş ağlar ile her problem için aynı başarım sağlanamasa da bazı işlemlerin tekrar edilmesinin önüne geçilmiş olunur.

2.5.1. Evrişim Katmanı

CNN modellerinde görüntü üzerinde ilk işlem yapılan katmandır. Evrişim katmanı, görüntüyü ele alan ilk katman olmakla birlikte görüntünün özelliklerini algılamakla sorumludur. Evrişim katmanının, görüntü analizlerinde başarılı sonuçlar elde edilmesini sağladığı kanıtlanmıştır. Görüntüler değerleri olan piksellerden meydana gelen matrislerdir. Filtreler piksel değerlerini komşu değerlerle birleştirmek için kullanılırlar. Bu katmanda görüntünün boyutundan daha küçük boyutta ($[n \times n \times \text{derinlik}]$) bir filtre, görüntünün üzerinde gezerek belirli özellikler çıkarmaya çalışır. Her işlem sonucunda regresyon gerçekleştirilerek ağırlıklı derinliği kadar nöron çıktıları alınır. Bu katmanda kullanılacak filtreler genellikle 3×3 veya 5×5 boyutlarında seçilmektedir. Şekil 2.3'de 5×5 'lik bir görüntü üzerinde 3×3 'lük bir filtrenin uygulanması gösterilmiştir. Sadece ilk işlem renklendirilmiştir.

4	3	8	5	4
5	1	3	3	1
2	7	2	2	2
3	2	6	1	8
4	3	5	7	6

 \times

1	0	-1
1	0	-1
1	0	-1

 $=$


-2	1	6
-1	4	0
-4	-2	-3

Şekil 2.3. Görüntü üzerine filtre uygulanması

2.5.2. Düzleştirilmiş Lineer Birim Katmanı (ReLU)

Aktivasyon fonksiyonu olarak kullanılan bu katmanda, fonksiyona giren negatif değerler sıfıra indirgenir. Bu fonksiyonun diğer fonksiyonlardan ayrılan en önemli özelliği hızlı sonuç vermesidir (Turkoglu ve ark., 2019). Denklem (2.1)'de ve Şekil 2.4'de ReLU aktivasyon fonksiyonu ifade edilmiştir.

$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x > 0 \end{cases} \quad (2.1)$$




Şekil 2.4. ReLU aktivasyon fonksiyonu


2.5.3. Havuzlama Katmanı

Evrişim katmanı ve ReLU'dan sonra havuzlama katmanı gerçekleştirilir. Havuzlama katmanının amacı giriş boyutunu küçültürken modelin ezberleme yapmasını engellemektir. Ayrıca boyut azaldığı için geriye sadece önemli özellikler kalır. Bu katmanda da belirli

filtreler kullanılır. Bunlar ortalama ve maksimum değere göre yapılan filtrelemelerdir. Genellikle daha çok kullanılan ve daha iyi sonuç veren maksimum filtrelemedir ve bu tezde maksimum filtreleme kullanılacaktır. Şekil 2.5’de havuzlama örnekleri gösterilmiştir.



(a)




(b)

Şekil 2.5. (a) Maksimum havuzlama ve (b) ortalama havuzlama

2.5.4. Dropout Katmanı


CNN’de çok fazla veri ile eğitim yapıldığı için ağ bazen ezberleme yapabilir. Bu durumun önüne geçilmesi için dropout katmanı kullanılır. Katmanda uygulanan işlem ağdaki bazı düğümlerin kaldırılmasıdır (İnik ve ark., 2017). Şekil 2.6’da dropout katmanı uygulanmadan önce ve uygulandıktan sonraki ağın yapısı gösterilmiştir.



Şekil 2.6. (a) Normal CNN ağı (b) ağın dropout işlemi uygulandıktan sonraki yapısı (İnik ve ark., 2017)

2.5.5. Düzleştirme Katmanı

Bu katmanın amacı, tam bağlantılı katman için verileri hazırlamaktır. Evrişim ve havuzlama katmanından gelen matrisleri tek boyutlu diziye çevirir.



Şekil 2.7. Düzleştirme işlemi

2.5.6. Tam Bağlantılı Katman

Tam bağlantılı katman, komşu katman nöronlarının karşılıklı bağlandığı fakat aynı katman nöronlarının birbirine bağlanmadığı bir ağ yapısına sahiptir. Katmandaki düğümlerde özellikler tutulmaktadır. Ağırlık (weight) ve bias değerleri değiştirilerek öğrenme sürecine başlanır.

Giriş katmanının nöron sayıları görüntünün genişlik, yükseklik ve derinlik kanallarıyla bağlantılıdır. Gizli katmanlardaki nöron sayılarının parametreleri, verilerin analiz edilmesi ve sınıflandırılmasına göre belirlenir. Çıkış katmanındaki nöronların sayısı ise, ağın tanımlayabilmesi gereken sınıfların sayısına eşittir.

2.5.7. Softmax

Tam bağlı katmandan sonra softmax fonksiyonu ile görüntünün hangi sınıfa ait olduğu olasılığı hesaplanmaktadır (Gold & Rangarajan, 1996).

2.5.8. Sınıflandırma Katmanı

Sınıflandırılması istenen veri sayısı kadar çıktı üreten katmandır. Bu tezde diyabetik retinopati için [0-4] arasında toplam 5 sınıflandırma yapılmıştır ve softmax sınıflandırıcısı tercih edilmiştir. Katarakt için ise 2 sınıflandırma yapılmıştır.

2.6. Transfer Öğrenimi (Transfer Learning)

Denetimli DÖ modellerinde fazla miktarda veri ile eğitim yapılmaktadır. Fakat veri setinin az olarak görüldüğü spesifik problemlerde transfer öğrenimi yöntemi kullanılabilir (Torrey & Shavlik, 2010). Ayrıca bu yöntem kullanıldığında başarılı sonuçlar da elde edilebilmektedir (Duman & Özsoy, 2022).


Transfer öğrenimi yöntemlerinde, önceden çok miktardaki görüntü verileri ile eğitilmiş CNN modellerinden kazanılmış öğrenimler yeni modellere aktarılabilir. Ağdaki parametreler uygun değerler ile eğitime başlar ve küçük değişiklikler ile yeni problemin çözümü için adapte edilirler (POLAT & ÖZERDEM, 2021). Bu yöntemlerin avantajı, ağın zaten görüntünün şekli, kenarı vb. temel özelliklerini fazla veriye sahip olan veri setleri ile öğrenmiş olmasıdır. Böylece yeni model oluşturulurken önceki öğrenme bilgilerinden faydalanılmış olunur (Duman & Özsoy, 2022). Ayrıca transfer öğrenimi ile

yeni model eğitildiğinde harcanan zaman maliyeti de büyük miktarda azaltılmış olmaktadır.

Bu tez çalışmasında, transfer öğrenimi yöntemlerinden DenseNet (Huang ve ark., 2017), ResNet (He ve ark., 2015) ve Vgg (Wang ve ark., 2015) gibi ImageNet yarışmalarında performansları kanıtlanmış, yaygın olarak kullanılan mimariler kullanılacaktır.

2.7. Retina

Retina, gözün en iç kısmını kaplayan hassas ve karmaşık bir ağ tabakasıdır. Burada, göze gelen ışık ve fotoreseptörler, elektromanyetik dalgalara dönüştürülerek optik sinir yoluyla beyne gönderilir. Bu fotoreseptörler çubuklar ve kolonilerden oluşmaktadır. Retinanın arka merkezinde en hassas parçası olan makula vardır. Ayrıntılı olarak görmemizi sağlayan makulanın merkezine fovea denmektedir. Şekil 2.8’de örnek bir retinal fundus yapısı gösterilmiştir.



Şekil 2.8. Retinal fundus görüntüsündeki temel yapılar

2.8. Diyabetik Retinopati

Retinada sık görülen hastalıkların en önemlilerinden biri şeker hastalığına bağlı meydana gelen DR’dir. (Özçelik & Altan, 2021). “DR, en yaygın körlük sebeplerinden biridir. Bu yüzden erken tespiti, görme yeteneğinin kaybedilmemesi açısından büyük önem arz etmektedir (Yalcin ve ark., 2018).” Retinopatinin tam olarak kelime anlamı, retinanın zarar görmüş olmasıdır. DR’nin ilk evrelerinde görme kaybı gerçekleşmez.

Hastalık ilerledikçe kan damarlarında oluşan kanama, etraftaki dokulara sızar. Genellikle gözün her ikisi birden bu kanamalardan etkilenmiş olur.

DR'nin teşhisi için uygulanan bazı yöntemler;

- Gözün doktorlar tarafından manuel olarak muayene edilmesi; doğruluğu daha az ve zaman alıcı bir yöntemdir.
- Hastanın gözbebeğinin damla damlatılarak genişletilmesi; fundus kameraları ile retinanın görüntülenmesini sağlar.

DR tedavisinde, hastalık çok ilerlememiş ise kan şekeri ve ilgili kan değerleri normal seviyelere getirilmeye çalışılmaktadır. Hastalığın ilerlediği durumlarda ise kanamanın yoğunluğuna göre cerrahi işlem gerekmekte ve lazer tedavisi uygulanmaktadır.

2.8.1. Anevrizma


Anevrizma, DR'nin ilk fark edilen bulgusudur. Retina kapillerlerden gelişmekle beraber genellikle tıkanmış kapiller bölgeler gözlemlenmektedir.12-125 mikron çapında olmaktadır. Küçük anevrizmalar ise kapiller duvarda perisit kaybının yol açtığı zayıflık ve keseleşme sonucu oluşur. Fundus görüntülerinde anevrizmalar boyanmaktadır (İnan ve ark., 2014).

2.8.2. Kanamalar

125 mikron çapından büyük olan mikroanevrizmalar kanama olarak adlandırılmaktadır. Genellikle mikroanevrizmaların yırtılması, dekompanse kapillerler ve intra retinal mikrovasküler anormallikler retinada kanamalara sebep olmaktadır. Kanamalar, fundus görüntülerinde boyanmaz ve fundus görüntülerinde retinada yerleştiği yere göre değişiklik göstermektedirler (İnan ve ark., 2014).

2.8.3. Eksüdalar

Sarı-beyaz renkte, keskin sınırlı, lipid ya da lipoprotein birikimleridir. Fundus görüntülerinde dış pleksiform tabakada yer alırlar ve kümeler halinde veya mikroanevrizmaları saran sirsine halkalar olarak görünürler. Fundus görüntüsünde boyayı maskeleyebilirler. Kendiliğinden ya da lazer yöntemiyle tedavi edilerek rezorbe edilmektedirler (İnan ve ark., 2014).



Şekil 2.9. DR teşhisinde bakılması gereken oluşumlar (Anonim2022a)

2.8.4. Diyabetik Retinopati Evreleri

Amerika Birleşik Devletleri, Sağlık ve Sosyal Hizmetler Bakanlığı'na bağlı Ulusal Göz Enstitüsü'nün (National Eye Institute) DR için tanımladığı 4 adet evre vardır.

Hafif Proliferatif Olmayan Retinopati; bu dönem retinopatinin başlangıç dönemi olmakla beraber, bu dönemde fundus görüntülerinde mikroanevrizmalar ve çok az ufak hemorajilere rastlanır.

Orta Derecede Proliferatif Olmayan Retinopati; retinopatinin bu döneminde fundus görüntülerinde mikroanevrizmalar ile retinal hemoraji sayısı artış gösterir. Dört retinal kadranın en az birinde yaygın şekilde mevcuttur. Bu dönemde yumuşak eksüdalar, venöz boğumlanmalar ve intraretinal mikrovasküler anomaliler görülmeye başlanır.

Şiddetli Nonproliferatif Retinopati; retinopatinin bu evresinde yaygın arteriyoller tıkanıklıklar, yumuşak eksüdalar, venöz değişikliklere ek olarak özellikle intraretinal mikrovasküler anomalilerin yoğunluğu ve genişliğinde artış gözlemlenir.

Proliferatif Retinopati; Bu evrede retina yüzeyinde veya optik disk üzerinde yeni damar oluşumuyla beraber fibröz doku proliferasyonu oluşmuş olur. Genellikle şiddetli nonproliferatif retinopati evresinde olan olgular proliferatif retinopati gelişme riski en yüksek olan olgulardır (İnan ve ark., 2014).

2.9. Katarakt

Katarakt, gözün içerisindeki sinir ve damar içermeyen göz merceğinde oluşan bulanıklıktır. Ayrıca göz merceğinin üzerindeki bulanık kısımların saydamlığının kaybolmasıyla insanda görüş bozulmasına neden olmaktadır. Yaşa göre sınıflandırılan ve doğuştan ya da yaşlanmaya bağlı ortaya çıkabilen bir hastalıktır (TTB-UDEK Etik Çalışma Grubu, 2010).

Katarakt oluşması sonucu göz merceğinin kimyasal bileşiminde değişiklikler meydana gelir. Bu olay ile göz merceğinde kahverengi ile sarı renklerde renklenmeler oluşur. Bunun sonucunda ışık yeteri kadar içeri giremez ve ilk belirti olarak bozulmalar başlar. Bazı durumlarda ise göz merceğindeki düzey ve yere göre görüşü tamamen de engelleyebilmektedir (TTB-UDEK Etik Çalışma Grubu, 2010).

Katarakt tedavi edilebilir bir hastalık olup uzman hekimler tarafından muayene ile tespit edilebilmektedir. İlk evrelerinde gözlük kullanımı ile kişilerin günlük işlerini yapmasını kolaylaştırır da kesin tedavi olarak cerrahi müdahale yapılır. Bu cerrahi işlemde göz çevresi lokal anestezi ile uyuşturularak göz içerisinde 2-3mm gibi küçük bir tünel kesi açılır. Fakoemülsifikasyon tekniği ile bulanıklaşan göz merceği parçalanarak çıkartılır. Bu işlem sonrası çıkartılan göz merceği yerine göz içerisine yapay monofokal ya da multifokal lens yerleştirilerek görme duyusunun iyileşmesi sağlanır (TTB-UDEK Etik Çalışma Grubu, 2010).


2.10. Simetrik ve Asimetrik Şifreleme

Şifreleme, bir verinin içeriğinin üçüncü şahıslar tarafından ele geçirilmesinin önlenmesi amacı ile gerçekleştirilen, verilerin gizlenmesi işlemidir (KODAZ & BOTSALI, 2010).

Bu tez çalışmasında ortaya çıkarılan modeller, bir web arayüzünde kullanılabilir hale getirilecektir. Modellerin kullanımı için görüntü verilerinin yüklenmesi gerekmektedir. Bu nedenle görüntü verilerinin güvenliği için şifreleme işlemi gerçekleştirilecektir.

Şifreleme (encrypt) algoritmaları ile şifrelenecek veriler üzerinde bazı işlemler gerçekleştirilir. Şifre çözme (decrypt) algoritmaları ile de veri tekrar anlamlı hale getirilmektedir (Ceyhan ve ark., 2021). Şifrelemeler kullanım şekillerine göre üç tipe ayrılmıştır; simetrik, asimetrik ve anahtarsız (karma) şifreleme.

Simetrik şifreleme algoritmalarında verinin şifrenmesi ve çözülmesi için tek bir anahtar kullanılmaktadır. Bu anahtar alıcı ile gönderici arasında gizli tutulmalıdır. Şekil 2.10'da simetrik şifreleme ifade edilmiştir.



Şekil 2.10. Simetrik şifreleme (Yılmaz ve ark., 2016)

Asimetrik şifreleme algoritmalarında ise verinin şifrenmesi için bir açık anahtar ve bir de özel anahtar kullanılmaktadır. Özel anahtar sadece şifreyi çözmek için kullanılmaktadır (Ceyhan ve ark., 2021).

Simetrik ve asimetrik şifrelemeler karşılaştırıldığında, simetrik şifreleme asimetrik şifrelemeye göre daha hızlı çalışmakta ve daha kolay uygulanmaktadır. Asimetrik şifreleme ise, simetrik şifrelemeye göre daha güvenlidir ve daha yavaştır. Simetrik şifrelemedeki dezavantaj anahtar dağıtımıdır. Anahtarın istenmeyen kişilerin eline geçmesi sorunlara yol açacaktır.

Simetrik şifrelemede literatürde kullanılan bazı algoritmalar şu şekildedir; IDEA (Daemen ve ark., 1993), DES (Yıldırım, 1995), AES (Daemen & Rijmen, 1999), Blowfish (Schneier, 1993), Twofish (Schneier ve ark., 1998), RC4, MD5, SHA (Ökten, 1997).

Asimetrik şifrelemede ise literatürde kullanılan bazı algoritmalar şu şekildedir; D-H (Diffie-Helman anahtar değişimi), RSA (Kaliski, 2001), DSA (Ökten, 1997).

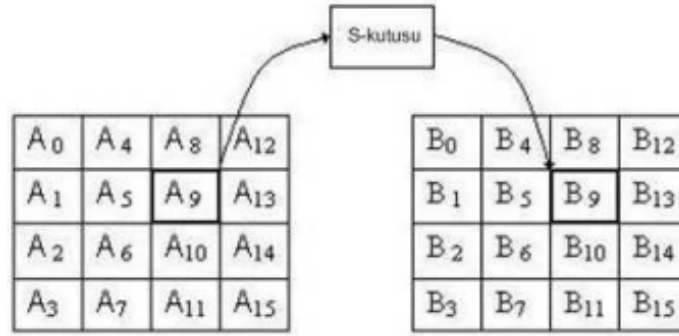
Bu çalışmada görüntü verilerinin güvenliği için, hızlı çalışması ve yaygın kullanımı sebebiyle simetrik şifreleme algoritmalarından AES-128 tercih edilmiştir.

2.10.1. AES Algoritması ve Çalışma Prensipleri

AES şifreleme algoritmasında, şifreleme yapmak ve şifre çözmek için 128, 129 ve 256 bit uzunluklarında anahtarlar ve 128 bit veri blokları kullanılmaktadır (Daemen & Rijmen, 1999). Bu tez çalışmasında AES-128 kullanılmış olup anahtar uzunluğu için 10 turluk işlem yapılmaktadır. Her turda farklı işlemler gerçekleştirilir (Selent, 2010). Bu işlemler sırasıyla bayt değiştirme, satır öteleme, sütun karıştırma ve tur anahtarı ile toplamadır. AES-128 için 10 tur sonunda veri şifrelenmiş olmaktadır (Dworkin ve ark., 2001).

AES, dosya sıkıştırma programları, disk şifreleme sistemleri, mesajlaşma uygulamaları, banka uygulamaları, video oyunları vb. alanlarda kullanılmaktadır.


AES şifreleme algoritmasında ilk olarak bayt değiştirme işlemi yapılmaktadır. Bu işlem algoritma içerisinde doğrusal olmayan tek dönüşüm işlemidir. Girişindeki durumların her baytını, S-kutusu değiştirme tablosu ile başka bayta dönüştürür. Şekil 2.11’de bayt değiştirme işlemi ifade edilmiştir.



Şekil 2.11. Bayt değiştirme işlemi (Dalmıslı & Ors, 2008)

Bayt değiştirme işleminden sonra satır öteleme işlemi yapılmaktadır. Bu işlemde ilk satır aynı bırakılır. İkinci satırda, elemanlar döngüsel olarak birer kez sola kaydırılır. Bu durumda 1. sütundaki eleman 4. sütuna kaymış olur. Üçüncü satırda yine benzer şekilde

ikişer kez ve dördüncü satırda üçer kez döngüsel olarak kaydırılır. Şekil 2.12’de satır öteleme işlemi ifade edilmiştir.



Şekil 2.12. Satır öteleme işlemi (Dalmışlı & Ors, 2008)

Satır öteleme işleminden sonra sütun karıştırma işlemi yapılmaktadır. Bu işlemde 4x4 lük bir matriste her bir sütun, elemanlara sahip 3. dereceden bir polinom olarak alınır. Bu polinomların, sabit bir polinoma göre modülleri alınarak ve çarpılarak sütunların karışım işlemi gerçekleştirilmiştir.

Son adım tur anahtar toplama işleminde ise durum verisi baytları, tur anahtarının baytlarıyla x-or işlemine sokulur (Dalmışlı & Ors, 2008).

3. MATERYAL ve YÖNTEM

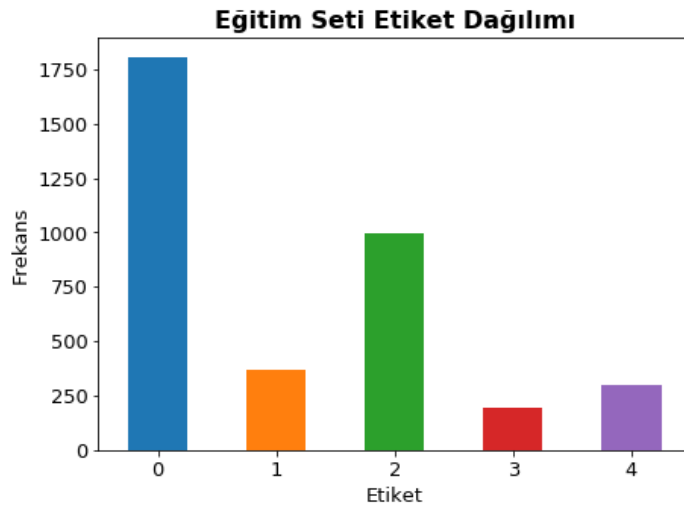
3.1. Veri Seti

Bu çalışmada oftalmoloji konusunda iki farklı veri seti üzerinde çalışılmıştır. Bunlar diyabetik retinopati için APTOSDB, katarakt için ise ODIR veri setidir. Bu veri setlerine ait kapsamlı bilgiler aşağıda açıklanmıştır.

3.1.1. Diyabetik Retinopati

Bu tez çalışmasında, DR için Asya Pasifik Tele-Oftalmoloji Derneği'nin düzenlediği yarışma için sunulan veri seti kullanılmıştır (APTOS 2019 Blindness Detection, 2019). Veri seti açık kaynak olup, verilerin kullanılmasında etik kurul onayına gerek yoktur. Bu veriler, diyabetik retinopati hastalığının bilgisayara öğretilmesini sağlayacak görüntülerden oluşmaktadır. Veriler çok yüksek çözünürlüğe sahip olmadığı için hesaplama maliyeti daha yüksek çözünürlüklü verilerin hesaplamalarına göre daha uygun olacaktır. Hesaplama maliyetinde, kullanılan GPU'nun da önemi çok büyüktür.


APTOSBD veri setinde eğitim için 3662 veri, test için 1928 veri kullanılmıştır. Şekil 3.1.'de etiketlerin dağılımları gösterilmiştir. Bu dağılım, DR'nin evrelerinden oluşmaktadır. Çizelge 3.1'de her bir etiketin sınıflara olan mevcut sayıları verilmiştir. 0-DR yok, 1-HPOR, 2-ODPOR, 3-ŞNR, 4-PR.



Şekil 3.1. Kullanılan veri setinde etiketlerin dağılımı

Çizelge 3.1. APTOSBD veri seti sınıflarına ait veri sayısı

Etiket Adı	Sınıf	Veri Sayısı
0	Diyabetik Retinopati Yok	1805
1	Hafif Proliferatif Olmayan Retinopati	370
2	Orta Derecede Proliferatif Olmayan Retinopati	999
3	Şiddetli Proliferatif Olmayan Retinopati	193
4	Proliferatif Retinopati	295




Şekil 3.2. Etiketli verilerin örnek görünümleri

3.1.2. Katarakt


Bu tez çalışmasında, katarakt için Shanggong Medical Technology şirketi tarafından Çin'deki farklı hastanelerden toplanan ODIR isimli veri seti kullanılmıştır (Peking University International Competition on Ocular Disease Intelligent Recognition, 2019). Veri seti açık kaynak olup, verilerin kullanılmasında etik kurul onayına gerek yoktur. Bu veri setinde 5000 hastanın sağ ve sol gözlerinden alınan fundus fotoğrafları yer almaktadır. Bu veriler uzmanlar tarafından 8 etikette sınıflandırıldı. Yani 5000 fundus görüntüsü; normal, diyabet, glukoma, katarakt, yaşa bağlı makula dejenerasyonu, hipertansiyon, patolojik miyop ve diğer anormallikler olarak ayrılmıştır. Veriler içerisinden katarakt olan 304 sol göz ve 290 sağ göz fotoğraflarının %80'i eğitim için, %20'si ise test için kullanılmıştır. Katarakt haricinde kalan veriler içerisinden 500 tanesi rastgele alınarak kataraktı olmayan hasta şeklinde eğitime dahil edilmiştir. Şekil 3.3'de kataraktlı hastaların ve Şekil 3.4'de kataraktı olmayan hastaların örnek görünümleri verilmiştir.

Çizelge 3.2. ODIR veri seti sınıflarına ait veri sayısı

Etiket Adı	Sınıf	Veri Sayısı
0	Kataraktı Olmayan Hasta	500
1	Kataraktlı Hasta	594



Şekil 3.3. Kataraktlı hasta verilerinin etiketlenmiş örnek görüntüleri



Şekil 3.4. Kataraktı olmayan hasta verilerinin etiketlenmiş örnek görüntüleri

3.2. Veri Artırma


Makine öğrenimi, DÖ gibi yöntemlerin ve sinir ağlarının son zamanlardaki hızlı gelişimiyle, büyük miktarlarda veriye olan ihtiyaç artmıştır. Büyük veri setlerini toplamak her zaman mümkün olmayıp, mümkün olduğu zamanlarda da zaman alıcı bir iş haline dönüşebilmektedir. Bu nedenle daha fazla veri elde etmek için mevcut veri setimizde küçük değişiklikler yapmamız gerekecektir. Bu değişiklikler; döndürme, ters çevirme, ölçekleme ve öteleme gibi küçük değişikliklerdir. Bu sayede modelimiz değişiklikler sonucu oluşan yeni veriler ile eski verilerin birbirinden farklı olduğunu düşünecektir. Değiştirilen veriler eğitim setine eklenerek modeli eğitmek için kullanılmaktadır.

Bir insan döndürülmüş bir görüntünün, döndürülmemiş bir görüntüyle aynı içeriğe sahip olduğunu kolayca anlayabilir. Fakat makine öğrenimi için veri döndürme yöntemi önemsiz bir kavram olarak varsayılmaz. Çünkü model önemsiz ayrıntıları görmeyi de öğrendiğinden daha kararlı olacaktır.

DÖ modellerinin performansı genelde eğitim setinin boyutuna oranla artabildiğinden, yapay olarak artırılmış eğitim seti ile modelin eğitim performansı artacak ve genelleme yapması azalacaktır.

3.2.1. Test Süresi Artırımı (Test-Time Augmentation)

TTA, test veri setinde veri artırma uygulamasıdır. TTA'nın amacı, veri artırmanın eğitim setine yaptığına benzer şekilde, test görüntülerinde rastgele değişiklikler yapmaktır. Böylece eğitilmiş modele aynı görüntüleri göstermek yerine, bu görüntülerin değiştirilmiş halleriyle birkaç kez göstermiş olacağız. Bir veri üzerinde yapılan değişikliklerle oluşturulan yeni veriler genelde on veriye kadardır.



Şekil 3.5. TTA uygulanmış örnek görüntü verisi

3.3. Deney Araçları

CNN ile eğitim işlemleri ve testleri, python programlama dilinin 3.7 sürümü ile yapılmıştır. Oluşturulan modeller için, tensorflow 2.4 sürümü ve keras kütüphaneleri kullanılmıştır. Yazılan algoritmaların grafik birimi ile çalışması için tensorflow'un 2.4 sürümü ile uyumlu olan NVIDIA CUDA 11 kullanılmıştır. Deney için kullanılan bilgisayarda; AMD RX 6600XT 8 GB grafik birimi, AMD Ryzen 5 3600 işlemci (3.6 GHz, 4.2 GHz'ye kadar overclock edilebilir hız), 32 GB 3600 MHz bellek özellikleri bulunmaktadır. Ayrıca deney için çevrimiçi programlama ve makine öğrenimi yapabilmeyi sağlayan kaggle notebook platformu da kullanılmıştır. Bu platformda grafik birimi olarak NVIDIA TESLA P100'den yararlanılmıştır.

3.4. Ön İşleme

Veri setini eğitim için kullanmadan önce bazı ön işleme tekniklerinden geçirmek gerekmektedir. Bu sayede verinin analiz edilebilmesi kolaylaşmaktadır. En iyi sonucu elde edebilmek için doğru ön işleme yönteminin seçilmesi son derece önemlidir. Bu tezde ortalama filtre, normalizasyon ve Gauss bulanıklaştırma filtresi (Gaussian blur) yöntemleri kullanılmaktadır.

3.4.1. Ortalama Filtre (Mean Subtraction)

Ortalama filtre (subtract per-channel) yönteminde orijinal görüntüden (eğitim setinden) kanal başına ortalama hesaplanır (Naik, 1995). Geometrik olarak eğitim setinin her boyut boyunca orijin etrafında merkezlenmesi olarak açıklanabilir. Bu sayede orijinal görüntüyü yeniden boyutlandırmaya veya kırpmaya gerek kalmayacaktır. $\hat{\mu}$ ortalamasını almak için 'X' (3.1) kullanılır.

$$\hat{\mu} = \sum_{i=1}^N X_i \quad (3.1)$$

3.4.2. Normalizasyon ve Z skoru Normalizasyonu

Normalizasyon, verileri yaklaşık olarak aynı ölçekte olacak şekilde ayarlamak için kullanılır (Krishnaiah, 1980). Eğitim setindeki verilerin farklı boyutlarda olabilmesi nedeniyle bu yöntem kullanılmıştır. Her boyuttaki verilerin standart sapmasına bölünmesiyle bulunur. Standart sapma (3.2)'de gösterildiği gibi hesaplanır.

$$\hat{\sigma} = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \hat{\mu})^2} \quad (3.2)$$

Z skor normalizasyonu, istenmeyen detayların (outlier) düzenlenmesi işlemidir. Bunlar gürültülerin giderilmesi, tutarsızlıkların giderilmesi ve eksik alanların doldurulması gibi işlemlerdir. Ortalama çıkarma ve normalizasyon ile birlikte (3.3)'de gösterildiği gibi uygulanır.

$$Z = \frac{X - \hat{\mu}}{\hat{\sigma}} \quad (3.3)$$

3.4.3. Gauss Bulanıklaştırma Filtresi (Gaussian Blur Filter)


Filtreleme işleminin amacı görüntüdeki gürültüyü azaltmak ve aynı zamanda önemli bilgileri de korumaktır. Gürültülü bir görüntü matematiksel olarak (3.4)'de gösterilmiştir. $f(i, j)$ yoğunluk, $n(i, j)$ gürültünün gri seviye, $g(i, j)$ gürültüsüz görüntüdeki piksel değerini göstermektedir (Değirmenci A ve ark., 2018).

$$f(i, j) = g(i, j) + n(i, j) \quad (3.4)$$


Doğrusal filtre türlerinden olan Gauss filtresi ayrılabilir maskeye sahip olduğundan uygulanması hızlıdır. Maskesindeki katsayılar merkez piksele olan mesafeye ve standart sapma değerlerine bağlıdır. Standart sapma değeri küçük seçildiğinde görüntüdeki bulanıklaşma oranı azalmakta ve gürültü giderimi başarımı da buna bağlı olarak azalmaktadır. Büyük seçildiğinde ise gürültü azaltmadaki başarımı ve bulanıklaştırma oranı artmaktadır. (Değirmenci A ve ark., 2018). Gauss fonksiyonu genel formülü (N boyutlu) (3.5)'de ifade edilmiştir.

$$G(r) = \frac{1}{2\pi\sigma^2} e^{-r^2/(2\sigma^2)} \quad (3.5)$$

Gauss bulanıklaştırma filtresinin eğitim setindeki verilere uygulanması sonucunda örnek veriler Şekil 3.6 ve Şekil 3.7'de gösterilmiştir.



Şekil 3.6. Gauss bulanıklaştırma filtresi uygulanmış örnek diyabetik retinopati verileri



Şekil 3.7. Gauss bulanıklaştırma filtresi uygulanmış ve keskinleştirilmiş örnek renklendirilmiş diyabetik retinopati verileri

3.5. Performans Ölçütleri

Bu tez çalışmasında kullanılan modellerin, diyabetik retinopati ve katarakt problemlerini tespit etme başarısı için yaygın olarak kullanılan performans ölçütlerinden karmaşıklık matrisi (TOĞAÇAR, 2021) ve QWK kullanılmaktadır. Karmaşıklık matrisinde kullanılan metrikler; F1-skoru, doğruluk, duyarlılık ve kesinliktir. Bu metriklerde kullanılan parametreler ise; yanlış pozitif (YP), yanlış negatif (YN), doğru pozitif (DP), doğru negatif (DN)'dir (Christopher ve ark., 2008).

- YP, hastalıklı sınıfta olan veri setinin, normal olarak tahmin edilmesidir.
- YN, normal sınıftaki veri setinin, hastalıklı olarak tahmin edilmesidir.
- DP, normal sınıftaki veri setinin, normal olarak tahmin edilmesidir.
- DN, hastalıklı sınıfta olan veri setinin, hastalıklı olarak tahmin edilmesidir.

Çizelge 3.3. Karmaşıklık matrisi (Powers, 2007)

		Tahmin	
		Normal Veri	Hastalıklı Veri
Gerçek	Normal Veri	DP	YN
	Hastalıklı Veri	YP	DN

Doğruluk; en sezgisel performans ölçütüdür ve sadece doğru tahmin edilen gözlemin toplam gözleme olan oranıdır. Doğruluk yüksek olduğunda modelin iyi olduğu varsayılsa da YP ve YN değerlerinin durumlarını değerlendirmek de gerekebilmektedir. Denklem 3.6'da işlem yapıldığında 0 ile 1 arasında sonuç elde edilecektir.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (3.6)$$

Duyarlılık; pozitif sınıftaki verilerin tahminlerinin başarılılığı sonucunu verir. Doğru tahmin edilen pozitif gözlemlerin gerçek sınıftaki tüm gözleme olan oranıyla bulunmaktadır. Denklem 3.7'de gösterilmiştir.

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (3.7)$$

Kesinlik; tahmin sonucundaki pozitif verilerin tahminlerinin başarılılığı sonucunu verir. Doğru tahmin edilen pozitif gözlemlerin toplam tahmin edilen pozitif gözlemlere olan oranıyla bulunmaktadır. Denklem 3.8’de gösterilmiştir.

$$Kesinlik = \frac{DP}{DP + YP} \quad (3.8)$$

F1-skoru; kesinlik ve duyarlılığın ağırlıklı ortalamasıdır. Bu nedenle hem YN hem de YP değerler hesaba katılmaktadır. Genellikle eşit olmayan bir sınıf dağılımı var ise doğruluktan daha önemli bir ölçüt olabilmektedir. Denklem 3.9’da gösterilmiştir.

$$F1 - Skoru = \frac{2 \times DP}{2 \times DP + YP + YN} \quad (3.9)$$

QWK; En çok kullanılan kappa ölçütlerinden biridir. Puanlayıcılar arasındaki rastgele anlaşma olasılığını dikkate almaktadır ve anlaşmama olasılığını dikkate almamaktadır. Bu nedenle ağırlıklandırılmıştır. Ağırlıklar, puanların varyansı ile orantılıdır. İki ve daha fazla sınıflandırma olduğunda kullanılabilen bu katsayıda, sınıflar arasındaki puan farkının fazla olması durumunda sonuç düşük çıkabilmektedir (Uysal & Doğan, 2021). -1 ile 1 arasında puan vermektedir. Rastgele bir model 0’a yakın bir puan verirken, mükemmel tahminler yapan bir model 1 ve 1’e yakın bir puan verecektir. Puanın sıfırın altına inmesi ise modelin rastgeleden daha kötü olduğunu gösterecektir. Karesel kappa katsayısı, Denklem 3.10’da gösterilmiştir.

$$\kappa = 1 - \frac{\sum_{i=1}^k \sum_{j=1}^k w_{ij} x_{ij}}{\sum_{i=1}^k \sum_{j=1}^k w_{ij} m_{ij}} \quad (3.10)$$

3.6. Klasik Derin Öğrenme Yöntemi ile Kullanılan Ağlar

3.6.1. EfficientNet

EfficientNet (Tan & Le, 2019), ImageNet ve diğer görüntü sınıflandırma ve öğrenme görevlerinde verimli sonuç veren modeller arasındadır. Daha az parametre ile daha iyi sonuçlar vermektedir (KORKMAZ & ALKAN, 2022). Ayrıca görüntülerde daha yüksek çözünürlük kullanılmasına imkan vererek daha verimli sonuçlar alınmasını

sağlamaktadır. Bu çeşitli ölçeklendirme sunan EfficientNet ağları Çizelge 3.4'de gösterilmiştir.

Çizelge 3.4. EfficientNet ağları ve ölçekleri 3.5

EfficientNetB0	224, 224, 3
EfficientNetB1	240, 240, 3
EfficientNetB2	260, 260, 3
EfficientNetB3	300, 300, 3
EfficientNetB4	380, 380, 3
EfficientNetB5	456, 456, 3
EfficientNetB6	528, 528, 3
EfficientNetB7	600, 600, 3

3.6.2. XceptionNet

InceptionNet'in geliştirilmiş sürümü olarak Google tarafından sunulmuştur. Derinlikte ayrılabilir erişime dayanan verimli bir ağdır (Chollet, 2017). Böylece evrişim işlem maliyeti önemli derece azalacaktır (BOZKURT, 2021).

3.7. Transfer Öğrenimi Yöntemi ile Kullanılan Derin Öğrenme Ağları

3.7.1. VggNet

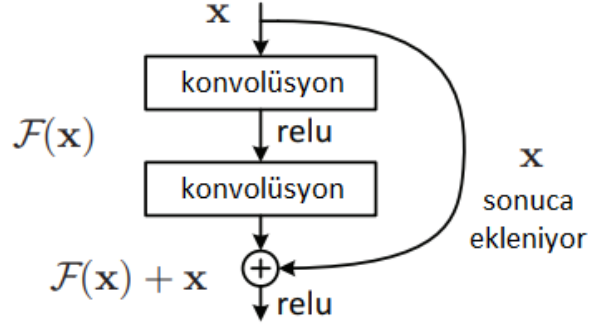
VggNet (Wang ve ark., 2015) ağı 11 ile 19 aralığındaki konvolüsyon katmanlarından oluşan 6 farklı ağa sahiptir. Literatürde bu ağlardan en çok Vgg16 ağı kullanılmaktadır. Bu tezde de katarakt veri seti ile oluşturulacak modelde Vgg16 ağı kullanılmıştır. VggNet, ImageNet 2014 yarışmasının kazananı olmuştur. Bu tarihten önceki DÖ ağlarından farklı olarak bu ağda 2x2 ve 3x3'lük filtreler uygulanmıştır (DOĞAN & TÜRKOĞLU, 2019).

3.7.2. ResNet

ResNet (He ve ark., 2015) ağı en fazla 152 katmandan oluşmakta olup, ImageNet 2015 yarışmasının kazananı olmuştur. Bu ağda Residual bloklar kullanılmaktadır. Bu bloklarda x girişi ile birlikte konvolüsyon işlemleri yapıldıktan sonra $F(x)$ sonucu çıkmaktadır (İnik

ve ark., 2017). Bu sonuç x girişine eklenerek Denklem 3.11'deki gibi gösterilmektedir. Residual blok örneği Şekil 3.8'de gösterilmiştir.

$$H(x) = F(x) + x \quad (3.11)$$



Şekil 3.8. Residual blok (He ve ark., 2015)

3.7.3. DenseNet

DenseNet (Huang ve ark., 2017) ağı, benzer bir CNN mimarisinden daha az parametre gerektirir ve gereksiz parametreleri ortadan kaldırır. Ayrıca bu ağda düşük ağırlık değerlerine sahip katmanlar olmadığı için ağ yapısı diğer ağlara göre küçüktür (Yapıcı ve ark., 2019). DenseNet ağı diğer ağlarda olduğu gibi farklı katmanlara sahip ağlara ayrılmıştır. Bu tezde diyabetik retinopati için kullanılan DenseNet121 ağı başarılı sonuçlar vermiştir.

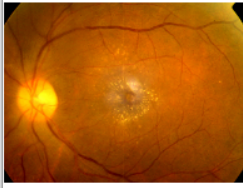
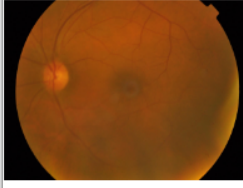
3.8. Modellerin Kullanılacağı Web Uygulaması ve Uygulama Arayüzünde Hastalık Teşhisi

Yapay sinir ağları ve DÖ ile oluşturulan modeller, hastalıkların hızlı tespiti için web arayüzünden kullanılabilir. Bu amaçla bir web arayüzü oluşturulmuştur. Bu arayüzde görüntü verileri sunucuya yüklenerek Şekil 3.9 ve Şekil 3.10'daki gibi hastalıkları sınıflandırmaktadır. Teşhis sonucunda ekranda sunucuya yüklenen görüntü verileri, hastalığa ait sınıflandırma sonuçları ve dosya isimleri görünmektedir. Ayrıca bu uygulama aynı anda çok fazla görüntü verisini sınıflandırabilir.

Upload an Image/Images for Cataract Diagnosis:
 Dosyaları Seç Dosya seçilmedi

Upload an Image/Images for Diabetic Retinopathy Diagnosis:
 Dosyaları Seç 2 dosya

Uploaded Files and Diagnostic Results:

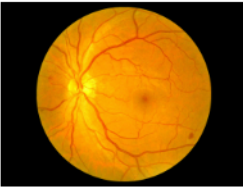
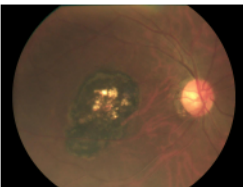
	[1] 0bfa8ea173d6.png
	[0] 0d1c7806f918.png

Şekil 3.9. Uygulama arayüzünde diyabetik retinopati hastalığı teşhisi

Upload an Image/Images for Cataract Diagnosis:
 Dosyaları Seç 2 dosya

Upload an Image/Images for Diabetic Retinopathy Diagnosis:
 Dosyaları Seç Dosya seçilmedi

Uploaded Files and Diagnostic Results:

	Not Cataract	1112_left.jpg
	Cataract	1178_right.jpg

Şekil 3.10. Uygulama arayüzünde katarakt hastalığı teşhisi

3.9. Web Uygulamasında Bilgi GüvenliĐinin SaĐlanması

Günümüzde sunuculara, bulut depolama alanlarına fazlaca görüntü yüklenmektedir. Bu görüntüler bazı kötü niyetli kişilerin eline geçebilmektedir. Bu yüzden tez çalışmasında uygulamaya yüklenen görüntü verilerinin güvenliğinin sağlanması için şifreleme algoritması kullanılmıştır. Böylece görüntü verilerinin güvenli bir şekilde depolanması amaçlanmıştır. Verilere şifreleme yapmak her zaman en iyi yöntem olmamakla birlikte şifre çözülmesi esnasında veri kayıpları yaşanabilmektedir. Veri kayıplarının önlenmesi için literatürde; Data Loss/Leakage Prevention/Protection (DLP), Information Loss/Leakage Prevention/Protection (ILP), Content Monitoring and Protection (CMP) gibi yöntemler bulunmaktadır (Purpura, 2007).

Bu tez çalışmasında, sunucuya yüklenen görüntü verileri üzerinde simetrik şifreleme işlemi gerçekleştirilmiştir. Bu amaçla, çalışmada AES-128 algoritması kullanılmıştır.

4. BULGULAR ve TARTIŞMA

Bu başlık altında yapılan çalışmalardan elde edilen bulgular gösterilmektedir. Modellerden elde edilen en iyi sonuçların doğruluk grafikleri, kayıp grafikleri, karmaşıklık matrisleri ve performans ölçütleri sunulmaktadır. Doğruluk ve kayıp grafiklerine bakıldığında, VA azalıp VL artıyorsa modelin öğrenemediği, VA artıp VL azalıyorsa modelin doğru kurulduğu, öğrenmenin gerçekleştiği ve iyi çalıştığı anlaşılmaktadır. Eğer model öğrenemiyorsa modelin parametrelerinde veya katmanlarında değişiklik yapılması gerekmektedir.

Doğruluk modelin tahmininin gerçek verilerle karşılaştırıldığında ne kadar doğru olduğunun ölçüsüdür. Algoritmanın performansını yorumlanabilir bir şekilde ölçmek için doğruluk metriği kullanılır. Bir modelin doğruluğu genellikle model parametrelerinden sonra belirlenir ve yüzde şeklinde hesaplanır.

Kayıp, eğitim ve doğrulama üzerinden hesaplanır ve modelin bu iki küme için ne kadar iyi performansla çalıştığını gösterir. Modelin tahmini mükemmelse kayıp sıfırdır. Doğruluğun aksine, kayıp bir yüzde değildir. Eğitim veya doğrulama kümelerinde her örnek için yapılan hataların toplamıdır.

4.1. Diyabetik Retinopati Tespiti için Eğitilen Modellerin Bulguları

4.1.1. XceptionNet

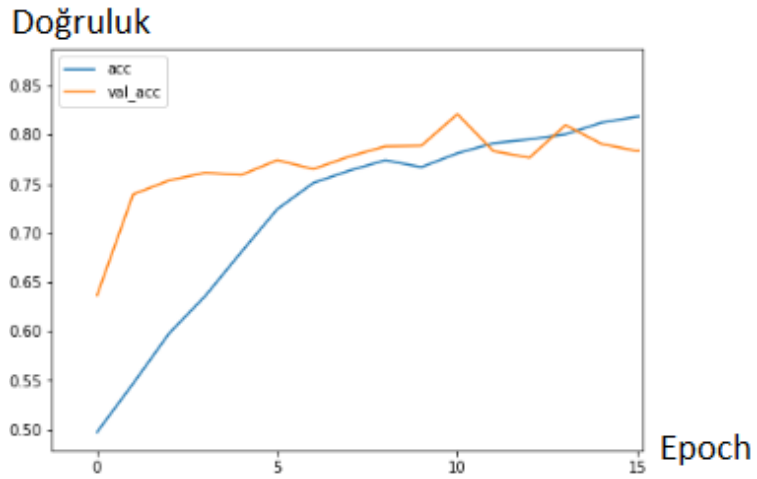
XceptionNet ağı ile çeşitli katmanların ve parametrelerin değiştirilmesiyle yapılan eğitimlerde modelin en iyi başarısı %72,3 doğruluk vermektedir. Bu oranın yeterli olmamasından dolayı modelin performans ölçütleri hesaplanmamış ve diğer ağlarla çalışılmaya devam edilmiştir.

4.1.2. EfficientNet


EfficientNet ağı ile ve yeni katmanlar eklenerek diyabetik retinopati için yeni modeller oluşturulmuştur. Bu modeller farklı çözünürlüklere sahip B3, B4, B5 ve B6 ağlarıyla eğitilmiştir. Eğitimler sonucunda B3 ağı %76,5, B4 ağı %76,8 ve B6 ağı %84,1 doğruluk oranına ulaşmıştır. %83,5 doğruluk oranına sahip B5 ağının model şeması Şekil 4.1'de, doğruluk grafiği Şekil 4.2'de ve kayıp grafiği Şekil 4.3'de gösterilmiştir.

Layer (type)	Output Shape	Param #
efficientnet-b5 (Model)	(None, 15, 15, 2048)	28513520
global_average_pooling2d_1 ((None, 2048)	0
dropout_1 (Dropout)	(None, 2048)	0
dense_1 (Dense)	(None, 5)	10245
dense_2 (Dense)	(None, 1)	6
Total params: 28,523,771		
Trainable params: 28,351,035		
Non-trainable params: 172,736		

Şekil 4.1. EfficientNetB5 modeli şeması



Şekil 4.2. EfficientNetB5 modeli doğruluk grafiği



Şekil 4.3. EfficientNetB5 modeli kayıp grafiği

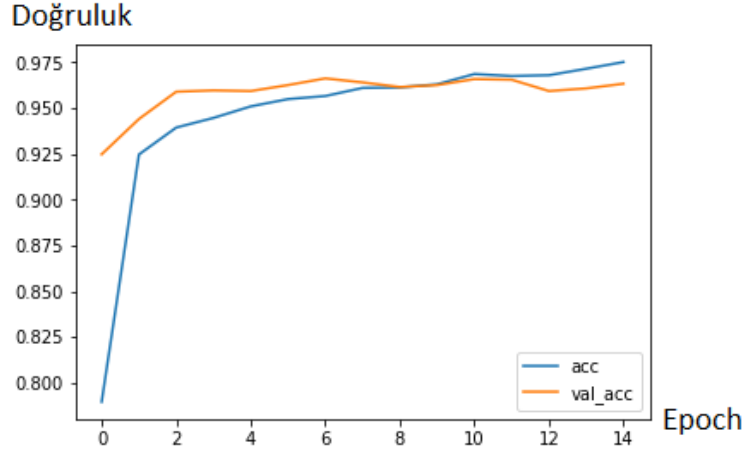
Şekil 4.1 doğruluk grafiğine bakıldığında, 10. döngüde model en başarılı öğrenimini gerçekleştirmiştir. Daha sonraki döngülerde öğrenme başarısı artmadığı için erken durdurma yapılarak eğitim sonlandırılmıştır. Şekil 4.3 kayıp grafiğine bakıldığında ise kaybın giderek azalması modelin başarılı bir şekilde öğrenim gerçekleştirdiğini göstermektedir. Eğitim sonucunda oluşturulan modeller hedeflenen başarıya ulaşamadığı için performans ölçütleri ve karmaşıklık matrisi hesaplamaları yapılmamıştır. Ayrıca diyabetik retinopati görüntülerinden oluşan bu veri setinin EfficientNet ağında çözünürlüğün yükseltilmesiyle yapılan eğitiminde daha başarılı sonuçlar ortaya çıktığı gözlemlenmiştir.

4.1.3. DenseNet121


Transfer öğrenimi yöntemi ile Densenet121 modeli kullanılarak ve bazı yeni katmanlar eklenerek oluşturulan yeni model, Şekil 4.4’de gösterilmiştir. Veri setinin bu model ile eğitiminden alınan doğruluk sonuçları Şekil 4.5’deki grafikte gösterilmiş ve %96,6 doğruluk oranına ulaşılmıştır. Ayrıca eğitim sırasında oluşan kayıplar Şekil 4.6’deki grafikte gösterilmiştir.

Layer (type)	Output Shape	Param #
densenet121 (Model)	(None, 7, 7, 1024)	7037504
global_average_pooling2d_1 ((None, 1024)	0
dropout_1 (Dropout)	(None, 1024)	0
dense_1 (Dense)	(None, 5)	5125
Total params: 7,042,629		
Trainable params: 6,958,981		
Non-trainable params: 83,648		

Şekil 4.4. DenseNet121 modeli şeması




Şekil 4.5. DenseNet121 modeli doğruluk grafiği



Şekil 4.6. DenseNet121 modeli kayıp grafiği

Şekil 4.5 doğruluk grafiğine bakıldığında, 6. döngüde model en başarılı öğrenimini gerçekleştirmiştir. Daha sonraki döngülerde VL artmadığı için erken durdurma yapılarak eğitim sonlandırılmıştır. Şekil 4.6 kayıp grafiğine bakıldığında ise kaybın giderek azalması modelin başarılı bir şekilde öğrenim gerçekleştirdiğini göstermektedir. Eğitim sonucunda oluşturulan karmaşıklık matrisi Şekil 4.7’de gösterilmiştir. Bu matrise göre modelimiz; test veri setinde olan 0 sınıfındaki verilerin %100’ünü 0 olarak, 1 sınıfındaki verilerin %79’unu 1 olarak, 2 sınıfındaki verilerin %97’sini 2 olarak, 3 sınıfındaki verilerin %62’sini 3 olarak ve 4 sınıfındaki verilerin %91’ini 4 olarak doğru tahmin edebilmeyi başarmıştır.



Şekil 4.7. DenseNet121 modeli karmaşıklık matrisi

Eğitim sonucunda modelden alınan performans ölçütlerinin sonuçları Çizelge 4.1 ve 4.2’de gösterilmiştir. Bu sonuçlara bakıldığında eğitim setindeki verilerde 0 ve 2 sınıfındaki verilerin daha fazla olması yine bu sınıfların doğru tespit edilebilmesini son derece arttırmıştır. Diyabetik retinopati tespitinde hem klasik DÖ yöntemleri hem de transfer öğrenimi yöntemi kullanıldığında en verimli sonucun transfer öğrenimi yöntemi ve Densenet121 mimarisi ile alındığı görülmektedir.

Çizelge 4.1. DenseNet121 modeli performans sonuçları

Model	Sınıflar	Kesinlik (%)	Duyarlılık (%)	F1-Skoru (%)
DenseNet121	0	99	100	99
	1	96	79	85
	2	90	97	95
	3	94	62	78
	4	93	91	91
	Ağırlıklı Ortalama		95,49	94,33

Çizelge 4.2. DenseNet121 modeli doğruluk ve QWK sonuçları

Doğruluk (%)	96,6
QWK Eğitim Skoru (%)	97

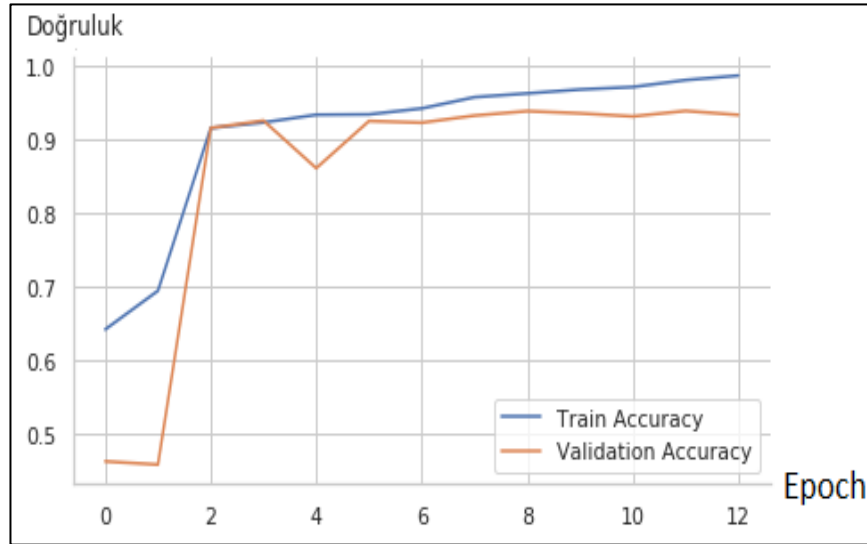
4.1.4. ResNet50

Transfer öğrenimi yöntemi ile Resnet50 modeli kullanılarak ve bazı yeni katmanlar eklenerek oluşturulan yeni model, Şekil 4.8’de gösterilmiştir. Veri setinin bu model ile eğitiminden alınan doğruluk sonuçları Şekil 4.9’deki grafikte gösterilmiş ve %93,9 doğruluk oranına ulaşılmıştır. Ayrıca eğitim sırasında oluşan kayıplar Şekil 4.10’deki grafikte gösterilmiştir.

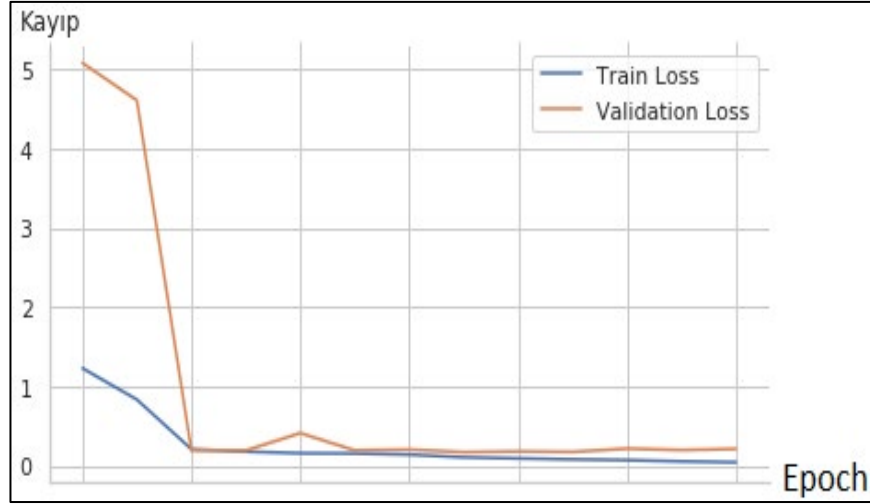
Layer (type)	Output Shape	Param #	Connected to
resnet50 (Functional)	(None, 2048)	23587712	
global_average_pooling2d_1 (Glo	(None, 2048)	0	activation_49[0][0]
dropout_1 (Dropout)	(None, 2048)	0	global_average_pooling2d_1[0][0]
dense_1 (Dense)	(None, 2048)	4196352	dropout_1[0][0]
dropout_2 (Dropout)	(None, 2048)	0	dense_1[0][0]
final_output (Dense)	(None, 5)	10245	dropout_2[0][0]

Total params: 27,794,309
Trainable params: 4,206,597
Non-trainable params: 23,587,712

Şekil 4.8. ResNet50 modeli şeması




Şekil 4.9. ResNet50 modeli doğruluk grafiği



Şekil 4.10. ResNet50 modeli kayıp grafiği

Şekil 4.9 doğruluk grafiğine bakıldığında, 8. döngüde model en başarılı öğrenimini gerçekleştirmiştir. Daha sonraki döngülerde VL artmadığı için erken durdurma yapılarak eğitim sonlandırılmıştır. Şekil 4.10 kayıp grafiğine bakıldığında ise kaybın giderek azalması ve bu şekilde devam etmesi modelin başarılı bir şekilde öğrenim gerçekleştirdiğini göstermektedir. Eğitim sonucunda oluşturulan karmaşıklık matrisi Şekil 4.11’de gösterilmiştir. Bu matrise göre modelimiz; test veri setinde olan 0 sınıfındaki verilerin %100’ünü 0 olarak, 1 sınıfındaki verilerin %65’ini 1 olarak, 2 sınıfındaki verilerin %97’sini 2 olarak, 3 sınıfındaki verilerin %50’sini 3 olarak ve 4 sınıfındaki verilerin %79’unu 4 olarak doğru tahmin edebilmeyi başarmıştır.



Şekil 4.11. ResNet50 modeli karmaşıklık matrisi

Eđitim sonucunda modelden alınan performans ölçütlerinin sonuçları Çizelge 4.3 ve 4.4’de gösterilmiştir. Bu sonuçlara bakıldığında eğitim setindeki verilerde 0 ve 2 sınıfındaki verilerin daha fazla olması yine bu sınıfların doğru tespit edilebilmesini son derece arttırmıştır.

Çizelge 4.3. ResNet50 modeli performans sonuçları

Model	Sınıflar	Kesinlik (%)	Duyarlılık (%)	F1-Skoru (%)
ResNet50	0	99	100	99
	1	95	65	77
	2	81	97	88
	3	86	50	63
	4	80	79	79
	Ağırlıklı Ortalama	91,47	91,32	90,27

Çizelge 4.4. ResNet50 modeli doğruluk ve QWK sonuçları

Doğruluk (%)	93,9
QWK Eğitim Skoru (%)	95,1

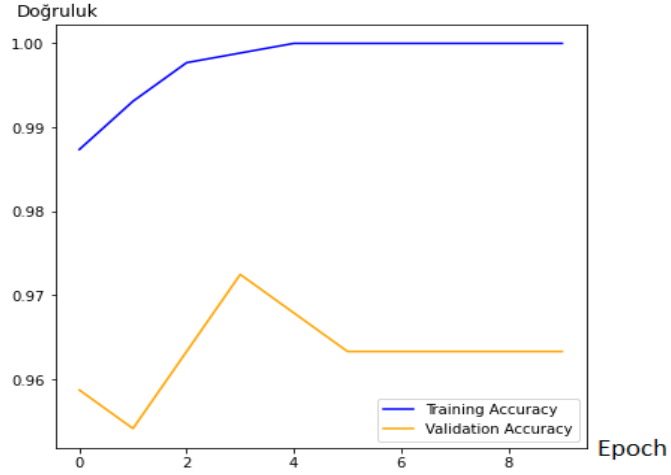
4.2. Katarakt Tespiti için Eğitilen Modellerin Bulguları

4.2.1. Vgg16

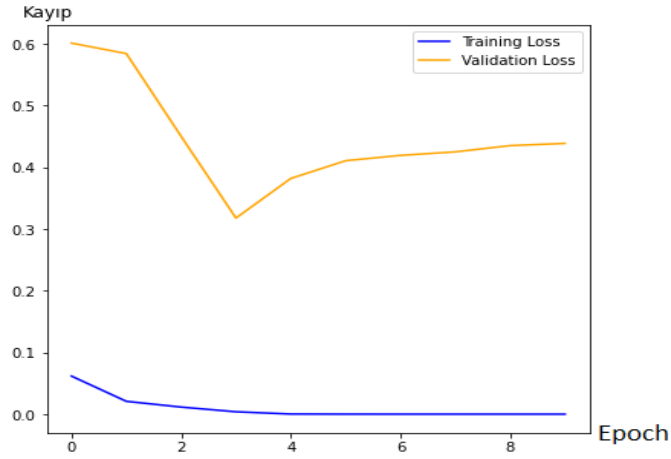
Transfer öğrenimi yöntemi ile vgg16 modeli kullanılarak ve bazı yeni katmanlar eklenerek oluşturulan yeni model, Şekil 4.12’de gösterilmiştir. Veri setinin bu model ile eğitiminden alınan doğruluk sonuçları Şekil 4.13’deki grafikte gösterilmiş ve %97,2 doğruluk oranına ulaşılmıştır. Ayrıca eğitim sırasında oluşan kayıplar Şekil 4.14’deki grafikte gösterilmiştir.

Layer (type)	Output Shape	Param #
vgg19 (Functional)	(None, 7, 7, 512)	20024384
flatten_1 (Flatten)	(None, 25088)	0
dense_1 (Dense)	(None, 1)	25089
Total params: 20,049,473		
Trainable params: 25,089		
Non-trainable params: 20,024,384		

Şekil 4.12. Vgg16 modeli şeması




Şekil 4.13. Vgg16 modeli doğruluk grafiği



Şekil 4.14. Vgg16 modeli kayıp grafiği

Şekil 4.13 doğruluk grafiğine bakıldığında, 3. döngüde model en başarılı öğrenimini gerçekleştirmiştir. Daha sonraki döngülerde VL artmadığı için erken durdurma yapılarak eğitim sonlandırılmıştır. Şekil 4.14 kayıp grafiğine bakıldığında ise kaybın az olması modelin başarılı bir şekilde öğrenim gerçekleştirdiğini göstermektedir. Eğitim sonucunda oluşturulan karmaşıklık matrisi Şekil 4.15’de gösterilmiştir. Bu matrise göre modelimiz; test veri setinde olan 0 sınıfındaki verilerin %92’sini 0 olarak ve 1 sınıfındaki verilerin %100’ünü 1 olarak, doğru tahmin edebilmeyi başarmıştır.



Şekil 4.15. Vgg16 modeli karmaşıklık matrisi

Eğitim sonucunda modelden alınan performans ölçütlerinin sonuçları Çizelge 4.5 ve 4.6'da gösterilmiştir. Bu sonuçlara bakıldığında eğitim setindeki sınıfsal girdilerin birbirine yakın olması öğrenmeyi iyileştirmiştir. Katarakt tespitinde hem klasik DÖ yöntemleri hem de transfer öğrenimi yöntemi kullanıldığında en verimli sonucun transfer öğrenimi yöntemi ve vgg16 mimarisi ile alındığı görülmektedir.

Çizelge 4.5. Vgg16 modeli performans sonuçları

Model	Sınıflar	Kesinlik (%)	Duyarlılık (%)	F1-Skoru (%)
Vgg16	0	100	92	96
	1	93	100	97
	Ağırlıklı Ortalama	96,2	96,34	96,54

Çizelge 4.6. Vgg16 modeli doğruluk ve QWK sonuçları

Doğruluk (%)	97,2
QWK Eğitim Skoru (%)	92,6

4.2.2. ResNet50

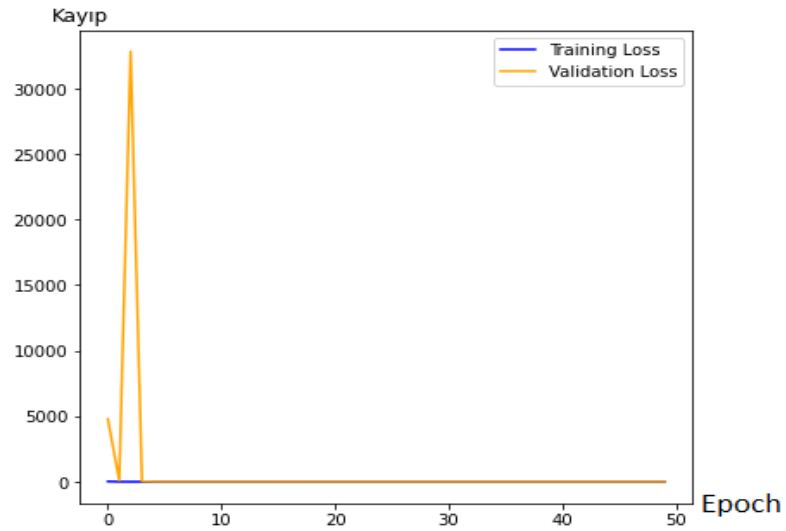
Transfer öğrenimi yöntemi ile ResNet50 modeli kullanılarak ve bazı yeni katmanlar eklenerek oluşturulan yeni model, Şekil 4.16'de gösterilmiştir. Veri setinin bu model ile eğitiminden alınan doğruluk sonuçları Şekil 4.17'deki grafikte gösterilmiş ve %94,3 doğruluk oranına ulaşılmıştır. Ayrıca eğitim sırasında oluşan kayıplar Şekil 4.18'deki grafikte gösterilmiştir.

Layer (type)	Output Shape	Param #
resnet50 (Functional)	(None, 2048)	23587712
dense_1 (Dense)	(None, 2)	4098
Total params: 23,591,810		
Trainable params: 23,538,690		
Non-trainable params: 53,120		

Şekil 4.16. ResNet50 modeli şeması




Şekil 4.17. ResNet50 modeli doğruluk grafiği



Şekil 4.18. ResNet50 modeli kayıp grafiği

Şekil 4.17 doğruluk grafiğine bakıldığında, 30. döngüde model en başarılı öğrenimini gerçekleştirmiştir. Daha sonraki döngülerde VL artmadığı için erken durdurma yapılarak eğitim sonlandırılmıştır. Şekil 4.18 kayıp grafiğine bakıldığında ise kaybın giderek azalması ve bu şekilde devam etmesi modelin başarılı bir şekilde öğrenim gerçekleştirdiğini göstermektedir. Eğitim sonucunda oluşturulan karmaşıklık matrisi Şekil 4.19'de gösterilmiştir. Bu matrise göre modelimiz; test veri setinde olan 0 sınıfındaki verilerin %94'ünü 0 olarak ve 1 sınıfındaki verilerin %93'ünü 1 olarak, doğru tahmin edebilmeyi başarmıştır.



Şekil 4.19. ResNet50 modeli karmaşıklık matrisi

Eğitim sonucunda modelden alınan performans ölçütlerinin sonuçları Çizelge 4.7 ve 4.8'da gösterilmiştir. Bu sonuçlara bakıldığında eğitim setindeki sınıfsal girdilerin birbirine yakın olması öğrenmeyi iyileştirmiştir.

Çizelge 4.7. ResNet50 modeli performans sonuçları

Model	Sınıflar	Kesinlik (%)	Duyarlılık (%)	F1-Skoru (%)
ResNet50	0	94	94	94
	1	93	93	93
	Ağırlıklı Ortalama	93,46	93,46	93,46

Çizelge 4.8. ResNet50 modeli doğruluk ve QWK sonuçları

Doğruluk (%)	94,3
QWK Eğitim Skoru (%)	87


4.2.3. EfficientNetB0

EfficientNet ağı ile ve yeni katmanlar eklenerek katarakt için yeni modeller oluşturulmuştur. Bu modeller farklı çözünürlüklere sahip EfficientNet ağlarıyla eğitilmiştir. Eğitimler sonucunda görüntü çözünürlüğü yüksek görüntülerle eğitilen ağlarda başarımın düştüğü gözlemlenmiştir. %92,6 doğruluk oranına sahip B0 ağının model şeması Şekil 4.20’de, doğruluk grafiği Şekil 4.21’de ve kayıp grafiği Şekil 4.22’de gösterilmiştir.


Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 192, 256, 3)]	0
efficientnet-b0 (Functional)	(None, 6, 8, 1280)	4049564
global_average_pooling2d (G1)	(None, 1280)	0
dense (Dense)	(None, 2)	2562

Total params: 4,052,126
Trainable params: 4,010,110
Non-trainable params: 42,016

Şekil 4.20. EfficientNetB0 modeli şeması



Şekil 4.21. EfficientNetB0 modeli doğruluk grafiği



Şekil 4.22. EfficientNetB0 modeli kayıp grafiği

Şekil 4.21 doğruluk grafiğine bakıldığında, 20. döngüde model en başarılı öğrenimini gerçekleştirmiştir. Daha sonraki döngülerde VL artmadığı için ve erken durdurma yapılarak eğitim sonlandırılmıştır. Şekil 4.22 kayıp grafiğine bakıldığında ise kaybın giderek azalması modelin başarılı bir şekilde öğrenim gerçekleştirdiğini göstermektedir. Eğitim sonucunda oluşturulan modeller hedeflenen başarıyı sağlamadığı için performans ölçütleri ve karmaşıklık matrisi hesaplamaları yapılmamıştır. Ayrıca katarakt görüntülerinden oluşan bu veri setinin EfficientNet ağında çözünürlüğün yükseltilmesiyle yapılan eğitimlerde daha verimsiz sonuçlar ortaya çıkardığı için B0 ağı tercih edilmiştir.

4.3. Farklı Yöntemlerle Oluşturulan Modellerin Karşılaştırılması

Transfer öğrenimi yöntemi ile daha önce oluşturulmuş modellere yeni katmanlar eklenerek ve bazı parametrelerde değişiklik yapılarak klasik DÖ ile eğitilen modellere göre çok daha başarılı sonuçlar elde edilmiştir. Çizelge 4.9’da eğitim sonuçları gösterilmiştir.

Transfer öğrenimi yöntemi kullanılmasının avantajları:

Daha az veri ile eğitim; sıfırdan oluşturulan modellerde büyük miktarda veri gerekmektedir. Bunun yerine önceden eğitilmiş modeller üzerinde yapılan küçük değişikliklerle daha az veri kullanarak başarılı sonuçlar elde edilmiştir. Performansı yüksek modeller; daha önceden eğitilen modellere yeni katmanlar eklenerek yapılan basit işlemlerde bile modelin başarısı yükselmiştir. Eğitim süresinin kısalması; Eğitilmiş

modelin ağırlıkları kullanılıp küçük deęişiklikler yapıldığında, az sayıda döngü ile yüksek başarı elde edilmiştir.

Çizelge 4.9. Farklı ağ ve yöntemlerle oluşturulan modellerin karşılaştırılması

Kullanılan Ağ	Yöntem	Hastalık	Doğruluk
XceptionNet	Klasik Derin Öğrenme	DR	%72,3
EfficientNetB3	Klasik Derin Öğrenme	DR	%76,5
EfficientNetB4	Klasik Derin Öğrenme	DR	%76,8
EfficientNetB5	Klasik Derin Öğrenme	DR	%83,5
EfficientNetB6	Klasik Derin Öğrenme	DR	%84,1
ResNet50	Transfer Öğrenimi	DR	%93,9
DenseNet121	Transfer Öğrenimi	DR	%96,6
EfficientNetB0	Klasik Derin Öğrenme	Katarakt	%92,6
ResNet50	Transfer Öğrenimi	Katarakt	%94,3
Vgg16	Transfer Öğrenimi	Katarakt	%97,2

EfficientNet ağıyla eğitimde kullanılacak görüntü verilerinin çözünürlüğüne göre B0 ile B7 arasında seçim yapılabilir. Bu ağ ile yapılan eğitimlerde bazen görüntü çözünürlüklerinin yüksek olması sonucu pozitif yönde etkilerken bazen de eğitim parametrelerinin fazlaca artmasına sebep olarak negatif yönde etkileyebilmektedir. Yapılan eğitimlerde diyabetik retinopatide çözünürlüğün artması, sonucu pozitif yönde etkilemiş ve kataraktı negatif yönde etkilemiştir.

5. SONUÇ

Bu çalışmada, oftalmolojik hastalıkların hızlı tespiti ve sınıflandırılması amaçlanmıştır. Bu doğrultuda diyabetik retinopati ve katarakt hastalıkları için farklı DÖ ağları ve yöntemleri kullanılarak modeller oluşturulmuş ve modellerin yüksek başarı oranlarıyla hastalıkları tahmin etmesi sağlanmıştır. Bunun yanında klasik DÖ ile transfer öğrenimi yöntemi arasındaki fark gözlemlenmiştir.

Diyabetik retinopati hastalığının tespitinde en iyi sonuç; DenseNet121 ağı ve bununla birlikte transfer öğrenimi yöntemi ile oluşturulan modelin %96,6 doğruluk oranıyla hastalığı tahmin etmesiyle elde edilmiştir. Transfer öğrenimi yöntemi ile eğitilen ResNet50 ağı da buna yakın bir sonuç vermiştir.

Katarakt hastalığının tespiti için ise en iyi sonuç; Vgg16 ağı ve bununla birlikte transfer öğrenimi yöntemi ile oluşturulan modelin %97,2 doğruluk oranıyla hastalığı tahmin etmesiyle elde edilmiştir. Transfer öğrenimi yöntemi ile eğitilen ResNet50 ağı buna yakın bir sonuç vermiştir.

Her iki hastalığa dair elde edilen tahmin doğruluk oranları bildiğimiz kadarı ile literatürde sunulan yöntemlerden daha iyi sonuç vermektedir. Öte yandan her iki oftalmolojik hastalık için de klasik DÖ mimarileri ile oluşturulan modellerin, transfer öğrenimi yöntemine göre doğruluk oranlarının daha az olduğu yani hastalığın doğru tahmin edilmesinde daha yetersiz oldukları görülmüştür. Transfer öğrenimi yönteminin klasik DÖ yöntemlerinden en az %2 olmak üzere daha iyi bir sınıflandırma yapabildiği görülmüştür.

Elde edilen en yüksek doğruluk oranına sahip modeller web arayüzünde kullanılabilir hale getirilmiştir. Ayrıca web arayüzünden yüklenen hasta görüntü verileri AES simetrik şifreleme algoritmasıyla şifrelenerek hasta verisi gizliliği sağlanmıştır. Sunucuda toplanacak şifrelenmiş veriler, ileride daha iyi modellerin geliştirilmesinde kullanılacaktır.

KAYNAKLAR

- AĞALDAY, F., & ÇINAR, A. (2021). Derin Öğrenme Mimarilerini Kullanarak Katarakt Tespiti. *European Journal of Science and Technology*. <https://doi.org/10.31590/ejosat.1012694>
- Aizenberg, I., Aizenberg, N. N., & Vandewalle, J. P. (2000). Multi-valued and universal binary neurons: Theory, learning and applications. Springer Science & Business Media.
- Anonim2022a <https://www.eyeops.com/contents/our-services/eye-diseases/diabetic-retinopathy> Erişim Tarihi: 30.03.2022. .
- APTOS 2019 Blindness Detection, (2019). <https://www.kaggle.com/c/aptos2019-blindness-detection/data>. Erişim Tarihi: 15.02.2022.
- Aravind, C., Ponnibala, M., & Vijayachitra, S. (2013). Automatic detection of microaneurysms and classification of diabetic retinopathy images using SVM technique. *International Journal of Computer Applications*, 975(8887), 1-5.
- Arslan, K., Üyesi, Ö., & Eylül Üniversitesi, D. (2020). Eğitimde Yapay Zeka ve Uygulamaları Artificial Intelligence and Applications in Education. In *Derleme Makale Western Anatolia Journal of Educational Sciences* (Vol. 11, Issue 1).
- Athira, R. V., & Ferlin, D. F. (2014). Detection of Retinal Hemorrhage using Splat Feature Classification Technique. *International Journal of Engineering Research and Applications*, 4, 327-330.
- Bellare, M., Desai, A., Jokipii, E., & Rogaway, P. (1997, October). A concrete security treatment of symmetric encryption. In *Proceedings 38th Annual Symposium on Foundations of Computer Science* (pp. 394-403). IEEE.
- BMr, P., & Raja, J. B. (2014). Automated Blood Vessel Segmentation in Retinal Image. *International Journal of Engineering and Computer Science*, 3, 5886-5890.
- Bortolin, S., & Welfer, D. (2013). Automatic detection of microaneurysms and hemorrhages in color eye fundus images. *AIRCC's International Journal of Computer Science and Information Technology*, 5(5), 21-37.
- BOZKURT, F. (2021). Derin Öğrenme Tekniklerini Kullanarak Akciğer X-Ray Görüntülerinden COVID-19 Tespiti. *European Journal of Science and Technology*, 149–156. <https://doi.org/10.31590/ejosat.898385>
- Buyukgoze, S. (2019). Dijital Sağlık Uygulamalarında Yapay Zeka. *VI. Uluslararası Bilimsel ve Mesleki Çalışmalar Kongresi-Fen ve Sağlık*, 7(10). <https://www.researchgate.net/publication/339091309>
- Ceyhan, M., Yolaçan, E. N., Üniversitesi, E. O., Fakültesi, M., Bölümü, M., & Kelimeler Öz, A. (2021). *GÖRÜNTÜ DOSYALARININ ŞİFRELENEREK GÜVENLİ ŞEKİLDE SAKLANMASI SAFE STORAGE OF IMAGE FILES BY ENCRYPTING* (Vol. 29, Issue 1). <https://orcid.org/0000-0002-0008-1037>
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1251-1258).
- Christopher, D. M., Prabhakar, R., & Hinrich, S. (2008). Introduction to information retrieval.
- Çilhoroz Y, & Işık O. (2021). Yapay Zeka: Sağlık Hizmetlerinden Uygulamalar. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 23(2), 573–588.

- Daemen, J., & Rijmen, V. (1999). AES proposal: Rijndael.
- Daemen, J., Govaerts, R., & Vandewalle, J. (1993, August). Weak keys for IDEA. In Annual International Cryptology Conference (pp. 224-231). Springer, Berlin, Heidelberg.
- Dalmışlı K. V., & Ors B. (2008). *Gelişmiş Şifreleme Standardının - AES - FPGA Üzerinde Gerçeklenmesi*.
- DANDIL, E., & SERİN, Z. (2020). Derin Sinir Ağları Kullanarak Histopatolojik Görüntülerde Meme Kanseri Tespiti. *European Journal of Science and Technology*, 451–463. <https://doi.org/10.31590/ejosat.780705>
- Dechter, R. (1986). Learning while searching in constraint-satisfaction problems.
- Değirmenci A, Çankaya İ, & Demirci R. (2018). Gradyan Anahtarlamalı Gauss Görüntü Filtresi. *Duzce University Journal of Science and Technology*, 6(1), 196–215. <https://doi.org/doi.org/10.29130/dubited.345116>
- Deng, L., & Liu, Y. (Eds.). (2016). Deep learning in natural language processing. Springer.
- Deng, L., & Yu, D. (2014). Deep learning: methods and applications. *Foundations and trends® in signal processing*, 7(3–4), 197-387.
- Dietterich, T. G. (1990). Machine learning. *Annual review of computer science*, 4(1), 255-306.
- DOĞAN, F., & TÜRKOĞLU, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DÜMF Mühendislik Dergisi*, 10(2), 409–445. <https://doi.org/10.24012/dumf.411130>
- Duman, B., & Özsoy, K. (2022). A deep learning-based approach for defect detection in powder bed fusion additive manufacturing using transfer learning. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37(1), 361–375. <https://doi.org/10.17341/GAZIMMFD.870436>
- Dworkin, M. J., Barker, E. B., Nechvatal, J. R., Foti, J., Bassham, L. E., Roback, E., & Dray Jr, J. F. (2001). Advanced encryption standard (AES).
- El Naqa, I., & Murphy, M. J. (2015). What is machine learning?. In machine learning in radiation oncology (pp. 3-11). Springer, Cham.
- Fukushima, K., & Miyake, S. (1982). Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. In Competition and cooperation in neural nets (pp. 267-285). Springer, Berlin, Heidelberg.
- Gold, S., & Rangarajan, A. (1996). Softmax to softassign: Neural network algorithms for combinatorial optimization. *Journal of Artificial Neural Networks*, 2(4), 381-399.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT press.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Deep Residual Learning for Image Recognition*. <http://arxiv.org/abs/1512.03385>
- Hou, Y. (2014). Automatic segmentation of retinal blood vessels based on improved multiscale line detection. *Journal of Computing Science and Engineering*, 8(2), 119-128.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4700-4708).
- İnan, S., Hastanesi, A. D., Göz, H., Kliniği, A., & Geliş, T. / (2014). Diabetik Retinopati ve Etiyopatogenezi Diabetic Retinopathy and Etiopathogenesis. In *Kocatepe Tıp Dergisi Kocatepe Medical Journal* (Vol. 15, Issue 2).

- İnik, Ö., Ülker B A Bilgisayar, E., Bölümü, M., Üniversitesi, G., Üniversitesi, S., Konya, T., & Sorumlu, : (2017). *GAZİOSMANPAŞA BİLİMSEL ARAŞTIRMA DERGİSİ (GBAD) Gaziosmanpasa Journal of Scientific Research Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri*. <http://dergipark.gov.tr/gbad>
- İŞLER, B., & KILIÇ, M. Y. (2017). THE USE AND DEVELOPMENT OF ARTIFICIAL INTELLIGENCE IN EDUCATION. *Electronic Journal of New Media*, 5(1), 1–11. https://doi.org/10.17932/iau.ejnm.25480200.2021/ejnm_v5i1001
- Kaliski, B. (2001). The mathematics of the RSA public-key cryptosystem. RSA laboratories.
- Kaur, M., & Talwar, R. (2015). Automatic extraction of blood vessel and eye retinopathy detection. *European Journal of Advances in Engineering and Technology*, 2(4), 57-61.
- KELEŞ, A. (2018). Derin Öğrenme ve Sağlık Alanındaki Uygulamaları. *Journal of Turkish Studies*, 13(Volume 13 Issue 21), 113–127. <https://doi.org/10.7827/turkishstudies.14189>
- Kleawsirikul, N., Gulati, S., & Uyyanonvara, B. (2013, April). Automated retinal hemorrhage detection using morphological top hat and rule-based classification. In *3rd International Conference on Intelligent Computational Systems (ICICS 2013)* (pp. 39-43).
- KODAZ, H., & BOTSALI, F. M. (2010). SİMETRİK VE ASİMETRİK ŞİFRELEME ALGORİTMALARININ KARŞILAŞTIRILMASI. *Selcuk University Journal of Engineering Sciences*, 9(1), 10-23.
- KORKMAZ, Ş., & ALKAN, M. (2022). Derin Öğrenme Algoritmalarını Kullanarak Deepfake Video Tespiti. *Journal of Polytechnic*. <https://doi.org/10.2339/politeknik.1063104>
- Krishnaiah, P. R. (Ed.). (1980). *A Hand Book of Statistics (Vol. 1)*. Motilal Banarsidass Publishe.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- ME, C. J., & ME, C. J. (2015). Automatic detection and classification of diabetic retinopathy lesion using bag of visual words model. *International Journal of Scientific and Research Publications*.
- Mitchell, T. M., & Mitchell, T. M. (1997). *Machine learning (Vol. 1, No. 9)*. New York: McGraw-hill.
- Naik, D. (1995). Pole-filtered cepstral mean subtraction. In *1995 International Conference on Acoustics, Speech, and Signal Processing (Vol. 1, pp. 157-160)*. IEEE.
- Ökten, Ö. (1997). Standard digital signature algorithm (DSA) and secure hash algorithm (SHA) in public key cryptography (Master's thesis, Middle East Technical University).
- Özçelik, Y. B., & Altan, A. (2021). Diyabetik Retinopati Teşhisi için Fundus Görüntülerinin Derin Öğrenme Tabanlı Sınıflandırılması. *European Journal of Science and Technology*. <https://doi.org/10.31590/ejosat.1011806>

- Peking University International Competition on Ocular Disease Intelligent Recognition, (2019). <https://odir2019.grand-challenge.org>. Erişim Tarihi: 17.02.2022.
- POLAT, H., & ÖZERDEM, M. S. (2021). Derin Transfer Öğrenimi Yaklaşımı ile Kamusal Alanda Medikal Maske Kullanımının Otomatik Kontrolü. *Türk Doğa ve Fen Dergisi*, 10(2), 191–198. <https://doi.org/10.46810/tdfd.948098>
- Powers, D. (2007). Evaluation: From precision, recall and F-factor to ROC, informedness, markedness & correlation (Tech. Rep.). Adelaide, Australia.
- Purpura, P. (2007). Security and loss prevention: An introduction. Butterworth-Heinemann.
- Reza, A. W., Eswaran, C., & Hati, S. (2009). Automatic tracing of optic disc and exudates from color fundus images using fixed and variable thresholds. *Journal of medical systems*, 33(1), 73-80.
- Ricci, E., & Perfetti, R. (2007). Retinal blood vessel segmentation using line operators and support vector classification. *IEEE transactions on medical imaging*, 26(10), 1357-1365.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 3(3):210–229, 1959.
- Schneier, B. (1993, December). Description of a new variable-length key, 64-bit block cipher (Blowfish). In *International Workshop on Fast Software Encryption* (pp. 191-204). Springer, Berlin, Heidelberg.
- Schneier, B., Kelsey, J., Whiting, D., Wagner, D., Hall, C., & Ferguson, N. (1998). Twofish: A 128-bit block cipher. *NIST AES Proposal*, 15(1), 23-91.
- Selent, D. (2010). Advanced encryption standard. *Rivier Academic Journal*, 6(2), 1-14. Erişim adresi: <https://www2.rivier.edu/journal/roaj-fall2010/j455-selent-aes.pdf>
- Selvathi, D., & Vaishnavi, P. L. (2011, July). Gabor wavelet based blood vessel segmentation in retinal images using kernel classifiers. In *2011 International Conference on Signal Processing, Communication, Computing and Networking Technologies* (pp. 830-835). IEEE.
- SujithKumar, S. B., & Singh, V. (2012). Automatic detection of diabetic retinopathy in non-dilated RGB retinal fundus images. *International Journal of Computer Applications*, 47(19).
- Sun, Z., Bebis, G., & Miller, R. (2006). On-road vehicle detection: A review. *IEEE transactions on pattern analysis and machine intelligence*, 28(5), 694-711.
- Sundhar, C. (2019). Automatic screening of fundus images for detection of diabetic retinopathy. *International Journal of Communication and Computer Technologies*, 2(1), 29-29.
- Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.
- Tjandrasa, H., Arieshanti, I., & Anggoro, R. (2015). Classification of non-proliferative diabetic retinopathy based on segmented exudates using K-Means clustering. *IJ Image, Graphics and Signal Processing*, 1, 1-8.
- TOĞAÇAR, M. (2021). X-ışınlı Göğüs İmgelerini Kullanarak Solunum Yolu Hastalıklarının Tespitinde Kuantum Transfer Öğrenme Modelinin Rolü. *Düzce*

- Torrey, L., & Shavlik, J. (2010). Transfer learning. In Handbook of research on machine learning applications and trends: algorithms, methods, and techniques (pp. 242-264). IGI global.
- TTB-UDEK Etik Çalışma Grubu (2010). Uzmanlık Dernekleri için Etik Kılavuzlar
- Turkoglu, M., Hanbay, D., & Sengur, A. (2019). Multi-model LSTM-based convolutional neural networks for detection of apple diseases and pests. *Journal of Ambient Intelligence and Humanized Computing*. <https://doi.org/10.1007/s12652-019-01591-w>
- Tymchenko, B., Marchenko, P., & Spodarets, D. (2020). *Deep Learning Approach to Diabetic Retinopathy Detection*. <http://arxiv.org/abs/2003.02261>
- UYSAL, I., & Doğan, N. (2021). How reliable is it to automatically score open-ended items? an application in the turkish language. *Journal of Measurement and Evaluation in Education and Psychology*, 12(1), 28–53. <https://doi.org/10.21031/epod.817396>
- Wang, L., Guo, S., Huang, W., & Qiao, Y. (2015). Places205-vggnet models for scene recognition. arXiv preprint arXiv:1508.01667.
- Witten, I. H., Frank, E., Hall, M. A., Pal, C. J., & DATA, M. (2005). Practical machine learning tools and techniques. In Data Mining (Vol. 2, No. 4).
- Yalcin, N., Alver, S., & Uluhatun, N. (2018). Classification of retinal images with deep learning for early detection of diabetic retinopathy disease. *26th IEEE Signal Processing and Communications Applications Conference, SIU 2018*, 1–4. <https://doi.org/10.1109/SIU.2018.8404369>
- Yapıcı, M. M., Tekerek, A., & Topaloğlu, N. (2019). Performance Comparison of Convolutional Neural Network Models on GPU. *2019 IEEE 13th International Conference on Application of Information and Communication Technologies (AICT)*, 1–4. <https://doi.org/10.1109/AICT47866.2019.8981749>
- Yıldırım, M. (1995). DES ve DES benzeri şifreleme sistemlerinin diferansiyel kripto-analizi (Doctoral dissertation).
- Yılmaz, M., Ballı, S., Sıtkı, M., Üniversitesi, K., Enstitüsü, F. B., Ve, E., Eğitimi, B., Dalı, A., Fakültesi, T., Sistemleri, B., Bölümü, M., & Muğla, T. (2016). *VERİ ŞİFRELEME ALGORİTMALARININ KULLANIMI İÇİN AKILLI BİR SEÇİM SİSTEMİ GELİŞTİRİLMESİ* (Issue 2).
- Zhang, L., Li, J., Zhang, I., Han, H., Liu, B., Yang, J., & Wang, Q. (2017). Automatic cataract detection and grading using Deep Convolutional Neural Network. *Proceedings of the 2017 IEEE 14th International Conference on Networking, Sensing and Control, ICNSC 2017*, 60–65. <https://doi.org/10.1109/ICNSC.2017.8000068>