

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**KONVOLÜSYONEL YAPAY SİNİR AĞLARI VE GÖRÜNTÜ İŞLEME
TEKNİKLERİ İLE BİYOMEDİKAL GÖRÜNTÜLERDEN DİYABETİK
RETİNOPATİ TEŞHİSİ**

Alaeddin TÜRKMEN

**ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI**

**ANKARA
2021**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

KONVOLÜSYONEL YAPAY SİNİR AĞLARI VE GÖRÜNTÜ İŞLEME TEKNİKLERİ İLE BİYOMEDİKAL GÖRÜNTÜLERDEN DİYABETİK RETİNOPATİ TEŞHİSİ

Alaeddin TÜRKMEN

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Murat Hüsnü SAZLI

Şeker hastalığı olarak bilinen diabetes mellitusun retinada kan damarlarına hasar vererek meydana getirdiği bir komplikasyon diyabetik retinopati, dünya çapında görme kaybının başlıca nedenleri arasında gelmektedir. Belli bir seviyeye gelene kadar retina taraması olmaksızın farkedilemeyen diyabetik retinopatinin erken teşhisi hastada görme kaybının engellenebilmesi için oldukça önemlidir. Ülkemizde ve dünyada günden güne sayısı artan diyabetik retinopati hastasının muayene edilmesi veya düzenli izlenmesi doktorlar için yoğun bir süreçtir. Bu yüzden tıp uzmanlarının işlem yükünü hafifletmek ve süreci hızlandırmak önem taşımaktadır. Bu tez çalışmasında diyabetik retinopatiyi sağlıklı olarak veya hastalığın dört evresine göre sınıflandırabilecek bir sistem önerilmiştir. Retina görüntüleri bir dizi görüntü işleme aşamasından geçirildikten sonra görüntü sınıflandırma konusunda başarılı olan konvolüsyonel sinir ağı ile sınıflandırılmıştır. Bu sırada iki farklı görüntü işleme yöntemi kullanılarak bunların başarıma etkisi görülmüştür. Konvolüsyonel sinir ağı mimarisi olarak verimli bir mimari olan 2019 yılında tasarlanmış EfficientNet modeli tercih edilmiştir. Sonuçlara göre en iyi performans %85,18 doğruluk ve 0,91 kappa skoru ile elde edilerek önerilen modelin başarısı ortaya konmuştur.

Şubat 2021, 79 sayfa

Anahtar Kelimeler: Konvolüsyonel Sinir Ağları, Görüntü İşleme, Biyomedikal Görüntü, Diyabetik Retinopati, EfficientNet

ABSTRACT

Master Thesis

DIABETIC RETINOPATHY DIAGNOSIS USING CONVOLUTIONAL ARTIFICIAL NEURAL NETWORKS AND IMAGE PROCESSING TECHNIQUES

Alaeddin TÜRKMEN

Ankara University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering

Supervisor: Prof. Dr. Murat Hüsnü SAZLI

Diabetic retinopathy, a complication caused by diabetes mellitus by damaging blood vessels in the retina, is one of the main causes of vision loss worldwide. Early diagnosis of diabetic retinopathy, which cannot be detected without retinal scanning until it reaches a certain level, is very important in order to prevent vision loss in the patient. Examination or regular follow-up of diabetic retinopathy patients, whose number is increasing day by day in our country and around the world, is an intense process for doctors. Therefore, it is important to ease the processing burden of medical professionals and to speed up the process. In this thesis, a system that can classify diabetic retinopathy as healthy or according to the four stages of the disease is proposed. Retinal images are classified by convolutional neural network, which is successful in image classification after passing through a series of image processing stages. Meanwhile, using two different image processing methods, their effect on success was observed. The EfficientNet model, designed in 2019, which is an efficient architecture, was preferred as a convolutional neural network architecture. According to the results, the best performance was obtained with 85,18% accuracy and 0,91 kappa score, and the success of the proposed model was demonstrated.

February 2021, 79 pages

Key Words: Convolutional Neural Networks, Image Processing, Biomedical Image, Diabetic Retinopathy, EfficientNet

TEŐEKKÖR

Derin tecrübe ve bilgileriyle çalışmalarımı yönlendiren, arařtırmalarımın her safhasında öneri ve yardımlarını esirgemeyen danıřman hocam sayın Prof. Dr. Murat Hüsnü SAZLI'ya ve engin teknik bilgileriyle çalışmalarına ışık tutan sayın Haluk TANRIKULU hocama en derin duygularıyla teşekkür eder, saygılarımı sunarım.

Alaeddin TÜRKMEN

Ankara, Őubat 2021

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR.....	iii
SİMGELER DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER ve KAYNAK ÖZETLERİ	4
2.1 Diyabet.....	4
2.2 Göz ve Retina	6
2.3 Diyabetik Retinopati	8
2.4 Kaynak Özetleri.....	13
3. MATERYAL ve YÖNTEM.....	25
3.1 Materyal	25
3.2 Görüntü İşleme.....	27
3.2.1 Görüntü yumuşatma	28
3.2.1.1 Ortalama filtresi	28
3.2.1.2 Medyan (ortanca) filtre.....	29
3.2.1.3 Gauss bulanıklaştırma filtresi.....	30
3.2.1.4 Bilateral filtre.....	31
3.2.2 Histogram eşitleme	31
3.3 Derin Öğrenme	34
3.3.1 Derin öğrenme modeli oluşturma yöntemleri.....	36
3.3.1.1 Sıfırdan eğitim	37
3.3.1.2 Transfer öğrenme	37
3.3.2 Konvolüsyonel sinir ağları.....	37
3.3.2.1 Giriş katmanı	38
3.3.2.2 Konvolüsyon katmanı	39
3.3.2.3 Düzleştirilmiş doğrusal birim katmanı (ReLU).....	40
3.3.2.4 Havuzlama katmanı	42

3.3.2.5 Tam bağlantılı (fully connected) katman	42
3.3.2.6 Dropout katmanı	43
3.3.2.7 Sınıflandırma katmanı	44
3.3.2.8 Optimizasyon teknikleri	44
3.3.3 KSA mimarileri	44
3.3.3.1 AlexNet	45
3.3.3.2 VGGNet	45
3.3.3.3 ResNet	47
3.3.3.4 EfficientNet	47
3.4 Başarım ölçütleri	53
3.4.1 Karışıklık matrisi	54
3.4.2 Cohen kappa skoru	55
4. DENEYSEL ÇALIŞMA ve ARAŞTIRMA BULGULARI	57
4.1 Görüntü İşleme Aşamaları	57
4.2 Veriseti Tasnifi ve Etiketleme	60
4.3 EfficientNet-B7 Modeli	61
5. TARTIŞMA ve SONUÇ	67
KAYNAKLAR	70
ÖZGEÇMİŞ	79

SİMGELER DİZİNİ

cm	Santimetre
g	Gram
µm	Mikrometre

Kısaltmalar

AHE	Adaptif Histogram Eşitleme
APTOS	Asia Pacific Tele-Ophthalmology Society
CLAHE	Kontrast Sınırlı Adaptif Histogram Eşitleme
CPU	Merkezi işlem ünitesi
DR	Diyabetik Retinopati
FFA	Fundus floresein anjiyografi
GPU	Grafik işlem ünitesi
HA	Hemoraji
HE	Histogram Eşitleme
KSA	Konvolüsyonel Sinir Ağı
MA	Mikroanevrizma
NPDR	Non Proliferatif Diyabetik Retinopati
NV	Neovaskülerizasyon
OKT	Optik Koherens Tomografi
PDR	Proliferatif Diyabetik Retinopati
ReLU	Rectified Linear Unit
YSA	Yapay Sinir Ağı
YZ	Yapay Zeka

ŞEKİLLER DİZİNİ

Şekil 2.1 Diyabet tipleri	4
Şekil 2.2 Avrupa Ülkelerinde Karşılaştırılabilir Diyabet Prevalansı Oranları.....	5
Şekil 2.3 Gözün yapısı	7
Şekil 2.4 DR hastası ve sağlıklı bireylerin görüşleri.....	9
Şekil 2.5 DR klinik özellikleri.....	10
Şekil 2.6 DR'li retina ve sağlıklı retina.	11
Şekil 2.7 İki hastanın göz dibi, FFA ve OKT görüntüleri (Tang vd. 2019).....	13
Şekil 3.1 Çalışmanın akış diyagramı.....	25
Şekil 3.2 Verisetindeki görüntülerin dağılımı	26
Şekil 3.3 Retina veriseti görüntüleri.....	27
Şekil 3.4 Sayısal görüntü elde etme süreci (Gonzalez ve Woods 2014).....	27
Şekil 3.5 a) Gürültülü görüntü, b) standart ortalama filtresi kullanılmış, c) ağırlıklı ortalama filtresi kullanılmış.	29
Şekil 3.6 Bir piksel üzerinde 3x3 boyutunda medyan filtre uygulaması	29
Şekil 3.7 Ortalaması (0,0) ve standart sapması 1 olan gauss dağılım grafiği	30
Şekil 3.8 Gauss bulanıklaştırma filtresi.....	30
Şekil 3.9 Gauss filtresinin etkisi.....	31
Şekil 3.10 a) Koyu, b) parlak, c) düşük kontrast, d) yüksek kontrast görüntülerin histogram grafikleri (Gonzalez ve Woods 2014).....	32
Şekil 3.11 CLAHE ile histogramın kırılması (Koonsanit vd. 2017).....	33
Şekil 3.12 Retina görüntüsünün HE, AHE ve CLAHE karşılaştırması: a)Giriş görüntüsü, b)HE, c) AHE, d) CLAHE (Qureshi vd. 2019).....	34
Şekil 3.13 Makine öğrenmesi ve derin öğrenme yöntemlerini kıyaslanması	36
Şekil 3.14 Derin öğrenme modeli oluşturma yaklaşımları.....	37
Şekil 3.15 KSA katmanları.....	38
Şekil 3.16 RGB görüntü ile konvolüsyon işlemi (İnik ve Ülker, 2017).....	40
Şekil 3.17 Dolgulama işlemi (Aggarwal 2018).....	40
Şekil 3.18 Aktivasyon fonksiyonları ve türevleri (Sharma 2017).....	41
Şekil 3.19 ReLU fonksiyonunun özellik haritasına etkisi (Ergin 2018)	41
Şekil 3.20 1 adım ve 2 adım ile maksimum havuzlama (Aggarwal 2018)	42
Şekil 3.21 Tam bağlantılı katman	43

Şekil 3.22 Ağa dropout uygulanması	43
Şekil 3.23 AlexNet mimarisi (Krizhevsky vd. 2012).....	45
Şekil 3.24 VGGNet mimarisi (Bezdán ve Bacanin 2019).....	46
Şekil 3.25 VGGNet modelleri (Doğan ve Türkođlu 2019).....	46
Şekil 3.26 ResNet artık blok	47
Şekil 3.27 ResNet mimarisi.....	47
Şekil 3.28 a) Temel ađ örneđi, b)-d) ađ genişliđinin, derinliđinin veya çözünürlüđünün yalnızca bir boyutunu artıran geleneksel ölçeklendirmeler, e) EfficientNet'in bileşik ölçekleme yöntemi	49
Şekil 3.29 a) Genişlik (w), b) derinlik (d), c) çözünürlük (r) ölçekleme ve dođruluk iliřkisi	49
Şekil 3.30 Bileşik ölçeklendirme ve diđer yöntemlerin karşılařtırılması (Zhou vd. 2016)	51
Şekil 3.31 Depthwise ve pointwise konvolüsyon.....	52
Şekil 3.32 EfficientNet-B0 temel ađ yapısı.....	52
Şekil 3.33 EfficientNet modellerinin diđer modellerle karşılařtırılması (Tan ve Le 2019).....	53
Şekil 3.34 Karışıklık matrisi a) TP, b) TN, c) FP, d) FN deđerler (Singh 2018) ..	54
Şekil 4.1 Gauss bulanıklařtırma içeren görüntü işleme çıktıları	59
Şekil 4.2 CLAHE içeren görüntü işleme çıktıları	59
Şekil 4.3 Önerilen model.....	61
Şekil 4.4 Gauss bulanıklařtırma işleminin uygulanmış veriseti kayıp fonksiyonu grafiđi (sol), CLAHE işleminin uygulanmış veriseti kayıp fonksiyonu grafiđi (sađ)	62
Şekil 4.5 Gauss bulanıklařtırma işleminin uygulanmış test seti karışıklık matrisi	63
Şekil 4.6 CLAHE işleminin uygulanmış test seti karışıklık matrisi.....	63

ÇİZELGELER DİZİNİ

Çizelge 2.1 DR evre özellikleri (Chan vd. 2016)	12
Çizelge 2.2 Model ve parametreler (Wang vd. 2018)	17
Çizelge 3.1 Derin öğrenme mimarileri ve uygulama alanları (Jones 2017).....	36
Çizelge 3.2 κ değerlerinin yorumu	56
Çizelge 4.1 Test seti DR sınıflarının dağılımı	60
Çizelge 4.2 Performans bulguları	64
Çizelge 4.3 Önerilen model ile geçmiş çalışmaların kıyaslanması.....	64

1.GİRİŞ

Günümüzde tıbbi görüntüleme; sağlık taraması, erken tanı, tedavi seçimi ve takibi gibi tüm tıbbi süreçlerin temel bir bileşeni olmuştur. Hem akut bakımda hem de kronik hastalıkta hasta triyajı, görüntüleme kılavuzlu müdahaleler ve tedavi planlamasının optimizasyonu artık tüm alt uzmanlık alanlarında rutin klinik uygulamaya entegre edilmiştir (Bercovich ve Javitt 2018). Biyomedikal görüntü işleme alanındaki üst düzey gelişmeler de hastalık teşhis ve analizlerinin otomatik sürecini hızlandırmıştır. Görüntü işleme yoluyla retina hastalıklarını tespit etmek ve analiz etmek için çok sayıda araştırma yapılmış ve bilgisayarlı sistemler tasarlanmıştır. Benzer şekilde, mikroanevrizmalar, yumuşak eksüdalar, sert eksüdalar, pamuk görünümünde lezyonlar, fibrotik bantlar, diskte neovaskülarizasyon, hemorajiler ve traksiyonel bantlar dahil olmak üzere Diyabetik Retinopatiyi (DR) tespit etmek ve derecelendirmek için değişik algoritmalar tasarlanmıştır. Retinanın görsel muayenesi, DR ile ilişkili komplikasyonları teşhis etmek için hayati bir testtir (Noor-ul-huda vd. 2019).

Bir sistemin harici verileri doğru bir şekilde yorumlayabilme, bu verilerden öğrenme ve bu öğrendiklerini kullanabilme becerisi olarak tanımlanan yapay zekadaki (YZ) ilerlemeler sayesinde günümüzde görüntü tanıma, akıllı hoparlörler, insansız otomobiller veya insansız hava araçları gibi geçmiş çağların hayallerinin gerçekleştirilmesi sağlanmıştır (Haenlein ve Kaplan 2019). Yapay zekanın alt dalı olan makine öğrenmesi, aldığı veriye matematiksel ve istatistiksel işlemler uygulayarak elde ettiği çıkarımlar üzerinden yürüttüğü tahminlerin bilgisayar üzerinden modellenmesidir. Yapay sinir ağları (YSA), makine öğrenmesi problemleri için çokça kullanılmıştır. Donanımsal yetersizlikler ve diğer sorunlar nedeniyle bir ara durgunluk dönemine girmiş olan YSA, 2000'li yıllarla birlikte tekrar kullanılmaya başlanmış ve GPU teknolojisinin ilerlemesiyle birlikte YSA'nın sığ olan mimarisi derinleştirilmiştir (Şeker vd. 2017). Yapay zekanın ve makine öğrenmesinin bir kolu olan derin öğrenme; geleneksel makine öğrenmesi yöntemlerine göre daha fazla gizli katmana sahiptir, görüntü işleme konusunda daha hızlı ve daha verimlidir. Ayrıca, görüntü özneliklerini kendi kendine çıkarabilmektedir (Toğaçar ve Ergen 2019). Derin öğrenme; genel veri analizinde artan bir eğilimdir ve 2013'ün 10 atılım teknolojisinden biri olarak adlandırılmıştır, ayrıca son 5 yıldır tıbbi görüntüleme alanında yaygın olarak kullanılmaktadır. Derin öğrenmenin

medikal görüntüleme başarılı uygulamaları arasında anatomik yapıların öznelik çıkarımı, görüntü segmentasyonu, görüntü kaydı ve sınıflandırılması yer almaktadır (Kim vd. 2020).

Derin öğrenmenin özel bir mimarisi olan Konvolüsyonel Sinir Ağları (KSA), YSA kullanılarak memelilerin görsel korteksini modelleme girişimlerinin başarılı bir örneğidir. KSA mimarisinin geliştirilmesinin arkasındaki fikir, Hubel ve Wiesel'in bir kedinin görsel korteksinin lokal olarak duyarlı ve yönelim seçici nöronları üzerindeki öncü çalışmalarına dayanmaktadır. KSA birçok sabit görüntü sınıflandırma probleminin çözümünde üstün performans göstermiştir. Trafik işareti algılama gibi bazı uygulamalarda KSA tabanlı system, kıyaslama testlerindeki insan kapasitesini bile aşmıştır (Haykin 2009, Li vd. 2014). KSA modellerinin görüntüler üzerindeki başarımı, biyomedikal görüntüler üzerinde çalışan araştırmacıların görüntü üzerinde bu modeli kullanma faaliyetlerini artırmıştır.

Diyabet hastalığından kaynaklanan DR, dünya çapında orta yaşlı ve yaşlılarda görme kaybının başlıca sebebidir. DR'nin 4 evresi vardır; 1) Hafif non-proliferatif DR, 2) Orta non-proliferatif DR, 3) Şiddetli non-proliferatif DR, 4) Proliferatif DR. Her bir evrede retina damarlarında çeşitli bozulmalarla birlikte en son kan damarlarındaki sızıntılarla birlikte görme bozuklukları ve körlük meydana gelebilmektedir. Diyabet ve DR görülme oranı ve sıklığının yükselmesiyle birlikte hem gelişmekte olan hem de gelişmiş ülkelerdeki halk sağlığı merkezlerinde, hasta veya risk altındaki kişiler için DR tarama sisteminin uygulama ve bakım maliyetlerinin artması söz konusu olacaktır. Erken teşhis ve zamanında müdahale ile görme bozukluğu komplikasyonu engellenebilen DR'nin görme kaybı etkisini azaltılması için bu konuda yenilikçi yollar aranması ve uygun maliyetli tarama programlarının optimize edilmesi önemli bir husustur (Ting vd. 2016). Dünya Sağlık Örgütü verilerine göre, 2000 yılında 171 milyon kişi olan diyabetli hasta sayısının 2030'da 366 milyona çıkacağı tahmin edilmektedir (Wild vd. 2004). Farklı merkezlerden yapılan büyük çapta araştırmalara göre diyabet teşhisi konan bireyde ilk 5 yıl ağır DR görülmemekte fakat hastalığın süresi uzadıkça bu risk günden güne artmaktadır. Erken tanı ile durdurulabilen DR konusunda hasta bilgilendirilmeli ve kontrol takvimine uyması hususunun önemi vurgulanmalıdır (Apaydın ve Bilgin 2010).

Bu tez çalışmasında DR hastalığının derin öğrenme ve görüntü işleme metodları ile teşhis edilip sınıflandırılması hedeflenmektedir. Derin öğrenme modeli olarak sınıflandırma konusunda başarısı kanıtlanmış KSA seçilmiştir. Bu hedefe binaen Kaggle veri setindeki retinal görüntülere ilk olarak görüntü işleme yöntemleri uygulanarak KSA'nın hem işlem yükü azaltılmış hem de KSA girişine optimal bir giriş verisi sokulmuştur. Gauss bulanıklaştırma filtresi ve CLAHE (kontrast limitli adaptif histogram eşitleme) olmak üzere iki farklı görüntü işleme metodu kullanılarak görüntü işleme metodlarının modelin sınıflandırma başarımını ne derece etkilediği irdelenmiştir. KSA mimarisi olarak 2019 yılında Google tarafından oluşturulan daha az parametreyle daha verimli sonuçlar elde edebilen EfficientNet tercih edilmiştir. Görüntüler çoklu etiketli sınıflandırma yapılacak şekilde etiketlenmiştir. Çalışma Python programlama diliyle ve Keras, OpenCV gibi kütüphaneler ile yapılmıştır. Girdi retina görüntüsünü sağlıklı ya da DR'nin hastalıklı 4 evresinden biri olarak belirleyerek git gide iş yükü artan doktorlar için zaman alıcı olan sınıflandırma ve teşhis işleminde karar destek sistemi oluşturulması amaçlanmıştır. Ayrıca bu sayede daha çok kişiye teşhis konulabileceği ve erken tanı sayesinde hastalığın ilerlemeden durdurularak görme bozukluklarının önüne geçilebileceği öngörülmüştür ve bu sistemin hekim ihtiyacı olan bölgelerde ön tarama şeklinde kullanılarak hastaların durumlarından haberdar olabilecekleri kanısına varılmıştır. Literatürdeki diğer çalışmalarla kıyaslanarak çalışmaları değerlendirmenin, çalışmaların eksik yönlerini tartışmanın ve çözüm önerileri sunmanın bu konudaki literatürün zenginleştirilmesi adına önemli olduğu düşünülmüştür.

Bu tez 5 ana bölüm şeklinde oluşturulmuştur. Birinci bölüm olan "Giriş" bölümünde tez ana hatlarıyla ele alınmış, amaç ve içerik üzerinde durulmuştur. İkinci bölüm "Kuramsal Temeller ve Kaynak Özetleri" kısmında çalışmadaki söz konusu problem olan Diyabetik Retinopati; nedenleri, evreleri ve semptomları hakkında bilgi verilmiş olup bu konu hakkında ilgili kaynak araştırmalarına değinilmiştir. Üçüncü bölüm "Materyal ve Yöntem" kısmında problem çözümü için ilgili teknikler anlatılmıştır. Dördüncü bölüm "Deneysel Çalışma ve Araştırma Bulguları", bahsedilen yöntemlerin nasıl uygulandığı, uygulanan yöntemlerin sonuçlarının elde edildiği ve diğer metodlarla karşılaştırıldığı bölümdür. Beşinci bölüm "Tartışma ve Sonuç" bölümünde ise elde edilen veriler değerlendirilip öneriler belirtilmiştir.

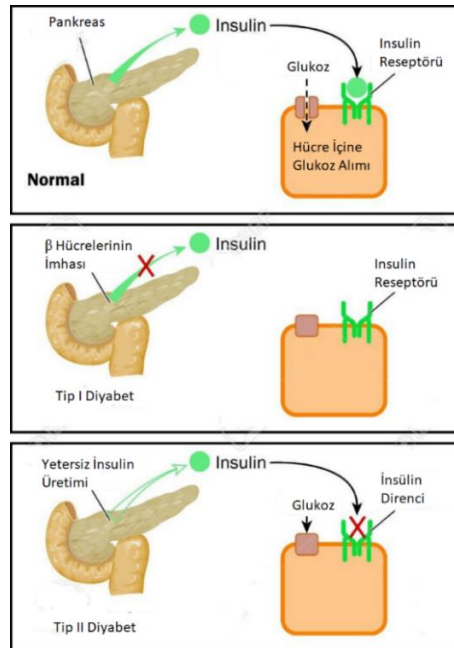
2.KURAMSAL TEMELLER ve KAYNAK ÖZETLERİ

2.1 Diyabet

İnsülin, kandaki şekeri (glikoz) kandan ayırarak hücre içinde kullanılmasını sağlayan pankreas adlı salgı bezinden üretilen hormondur. İnsülinin az üretilmesi, hiç üretilmemesi veya vücut dokularının insüline duyarsız hale gelmesiyle kandaki şeker seviyesinin yükselmesi (hiperglisemi), diyabet (diabetes mellitus) hastalığı olarak adlandırılır (Dinççağ 2011, Coşansu 2015).


Diyabet; Tip I diyabet, Tip II diyabet, Gestasyonel diyabet ve diğer spesifik türler olmak üzere 4 çeşitte kategorize edilebilir. En yaygın görülen diyabet formları Tip I ve Tip II'dir. Gestasyonel diyabet gebelik sırasında meydana gelen diyabeti tanımlarken bunların dışında özgül formlar mevcuttur.

- Tip I Diyabet: Pankreas β hücrelerinin işlevsizliğinden kaynaklanmaktadır. Bunun sonucunda eksik insülini vücut dışından tamamlamak gerekmektedir. Genç yaşlarda daha çok görülür.
- Tip II Diyabet: Vücuttaki insüline karşı duyarsızlaşma veya insüline karşı direnç söz konusu olur. Tüm diyabetlilerin yaklaşık %90'ını bu tür oluşturur. İlerleyen yaşlarda daha sık görülmektedir.



Şekil 2.1 Diyabet tipleri (Cancer and Fucoidan, 2020)

Dünya çapında Tip II diyabetli kişi sayısı son 20 yıl içerisinde 2 katından fazla artmıştır. Uluslararası Diyabet Federasyonu'nun yaptığı tahminlere göre, 2015 yılında 415 milyon diyabet hastası olduğu ve 2040'a kadar sayısının 642 milyon olacağı yönündedir (Zimmet vd. 2016). 2013 yılında Uluslararası Diyabet Federasyonu tarafından yayınlanan 'Altıncı Diyabet Atlası'na göre dünyadaki diyabetli nüfusun yaklaşık yarısı üç ülkede (Çin, Hindistan ve Amerika Birleşik Devletleri) yaşamaktadır. Bu atlasa göre 2035 yılında Türkiye, dünyada en yüksek diyabetli nüfusa sahip ilk 10 ülke arasında bulunacaktır. Aynı zamanda ülkemiz 7 milyondan fazla kişiyle Almanya ve Rusya'dan sonra Avrupa'da 20-79 yaş arası en fazla diyabetli hastanın bulunduğu ülkeler arasında 3. sırada yer almaktadır. Bununla birlikte diyabet prevalansı¹ ise şekil 2.2'de gösterildiği gibi Avrupa ülkeleri arasında en yüksek Türkiye'dedir. (TC Sağlık Bakanlığı ve Halk Sağlığı Kurumu, 2014).



Şekil 2.2 Avrupa Ülkelerinde Karşılaştırılabilir Diyabet Prevalansı Oranları (TC Sağlık Bakanlığı ve Halk Sağlığı Kurumu, 2014)

¹ Prevalans, belirli bir süre içinde bir hastalığın toplumda görülme sıklığını gösteren ölçüttür. Belirli bir süre içindeki tüm eski ve yeni vakaların risk altındaki kişi sayısına bölünmesiyle hesaplanır.

1997-1998 yıllarında rastgele seçilmiş 20 yaş üstü 24.788 kişi ile gerçekleştirilmiş Türkiye Diyabet Epidemiyoloji Çalışması (TURDEP-I) sonuçlarına göre ülkemizde tip II diyabet prevalansı %7,2; BGT (bozulmuş glukoz toleransı) prevalansı ise %6,7 bulunmuştur. Çalışma hastaların %32'sinin durumundan haberdar olmadığını ortaya koymuştur. TURDEP-I'in devamı niteliğindeki 2010 Ocak-Haziran arasında gerçekleştirilen TURDEP-II ise diyabet prevalansının %16,5'e çıktığını saptamıştır (Satman vd. 2002, Satman vd. 2013).


Diyabetli hastaların %46'sını oluşturan yaklaşık 175 milyon kişi diyabetik olduğunun farkında değildir ve diyabetin neden olduğu komplikasyonlara karşı risk altındadır. Bu risklerin olası zararlarından ve maliyetinden kurtulmak için hastaların erken dönemde tanı ve tedavi olmaları çok büyük önem arz etmektedir. Tarama programları için yeterli bütçesi olmayan veya hastalıkların göz ardı edildiği bazı ülkelerde tanı almamış diyabetli hasta oranı %90'lara varmaktadır. Hatta bazı gelişmiş ülkelerde ise hastaların yaklaşık üçte biri hastalığından haberdar değildir (Spijkerman vd. 2003). Sonuç olarak diyabet ülkemizde ve dünya üzerinde en önemli halk sağlığı sorunlarının başında gelmektedir. Yapılan çalışmalarda teşhis edilmemiş diyabet rahatsızlığının hastalarda diyabetik nefropati, diyabetik retinopati ve diyabetik nöropati gibi komplikasyonların çoktan gelişmiş olabileceği gösterilmiştir. Bu yüzden diyabet ve neden olduğu komplikasyonların teşhis ve tedavi süreci önemli bir sorundur.

2.2 Göz ve Retina

Göz, dış dünyadaki görsel imgeleri algılayan duyu organıdır. Görme olayı, gözde bulunan ışığa duyarlı fotoreseptör hücrelerin beyne gönderdiği sinyaller vasıtasıyla gerçekleşir. Ağırlığı ortalama 10-12 g ve çapı yaklaşık 2,5 cm olan 2 adet göz, orbita denilen çukurlarda bulunmaktadır (Perkins ve Davson 2018).

Göz birbirine geçmiş 3 tabakadan oluşmaktadır. En dışta bulunan ilk tabakaya sert tabaka (sklera) ya da "gözakı" denir, göz kasları bu tabakadan tutunarak gözü hareket ettirir. Kan damarı bulunmayan bu tabaka gözü dış etkilere karşı korur. Bu tabaka öne doğru tümsekleşerek göze gelen ışığın ilk kırıldığı yer olan korneayı (saydam tabaka) oluşturur. Burada kırılan ışık göz merceğine gider. Sert tabaka ile ağ tabaka arasında yer alan damar

tabaka (koroid), gözü besleyen kan damarlarını bulundurmaktadır.



Şekil 2.3 Gözün yapısı (Gündoğan 2018)

Retina (ağ tabaka), gözün üçüncü tabakasıdır ve çok incedir. Nesnelere görüntüleri bu tabakada odaklanır ve buradan çıkan sinirler beyindeki görsel algıdan sorumlu olan oksipital kortekse gitmektedir. Duyusal retina aldığı ışığı sinirsel uyarıya çevirmektedir. Duyusal retina şu kısımlardan oluşmaktadır:

- I. Fotoreseptörler
- II. Bipolar hücreler
- III. Ganglion hücreleri
- IV. Amakrin ve horizontal hücreler
- V. Nöronlar dışında nöroglial hücelere benzeyen destek hücreleri

Retinada koni ve basil olarak isimlendirilen iki adet fotoreseptör bulunmaktadır.

- Basiller: Görevi alacakaranlıkta ve gece görmek olan basillerin çapı 2–5 μm , boyları 100–120 μm 'dir. Foveada hiç bulunmayan basillerin sayıları perifere doğru gittikçe artmaktadır.

- Koniler: Görevi renkli görme, keskin görme ve parlak ışıktaki görmedir. Boyları 65–75 µm, kalınlıkları 5–8 µm olan bu fotoreseptörlerin şekli silindriktir. Koniler mavi, yeşil ve kırmızı ışık spektrumundaki fotonları absorbe etmektedirler.

Bipolar hücrelerin dendritleri dışarıda fotoreseptörlerle, içeride ganglion ve amakrinlerle sinaps yaparak sinyal iletiminde rol oynarlar, iki kutuplu olduğu için bipolar denmiştir. Ganglion hücreler oluşan sinyali beynin görme merkezine ulaştıran kısımdır, hücre uzantılarının bir araya gelmesiyle optik siniri oluşturur. Horizontal hücreler görme uyarımının integrasyonunda yer almaktadır, amakrin hücreler bol dendritli aksonsuz hücrelerdir (İnan 2014, Gündoğan 2018).

Sıklıkla karşılaşılan retina hastalıkları şunlardır:

- Diyabetik retinopati,
- Retina yırtığı ve dekolmanı,
- Epiretinal membran,
- Makula deliği ve dejenerasyonu
- Retinitis pigmentosa
- Retinal ven ve arter tıkanıklıkları

2.3 Diyabetik Retinopati

Diyabetik retinopati, diyabetin en sık görülen mikrovasküler komplikasyonudur ve tüm hastalar kayda değer görme kaybına maruz kalmasa da, bu durum körlüğün önde gelen nedenidir. 20 yıllık bir diyabetin ardından, Tip I diyabetli hemen hemen tüm hastalarda en azından bir miktar retinopati olacaktır. Ayrıca, insüline bağımlı Tip II diyabetik hastaların yaklaşık % 80'i ve eksojen insülin gerektirmeyen Tip II diyabetik hastaların %50'sinde 20 yıl süren diyabet sonrası retinopati görülecektir (Stitt vd. 2013).

Retinopati, retinada gözün görme fonksiyonlarında bir bozulmaya neden olabilecek herhangi bir hasar anlamına gelmektedir. Retinopatiye genellikle retinal vasküler hastalık veya anormal kan akışı neden olmaktadır. Bunun sonucunda retinayı besleyen ince kan damarlarının zarar görerek damarlardan kan sızıntısına (hemoraji) neden olabilir. Ayrıca

diyabetik retinopatinin diğerk bir sonucu retina yüzeyinde kolayca kanayabilen yeni kan damarlarının oluşmasına neden olabilmesidir (NHS, 2008).

DR gelişen hastaların büyük çoğunluğunda hastalığın geç aşamalarına kadar ani görme kaybına neden olabilen makula ödemi dahil hiçbir semptom görülmeyebilir. Hastalığın hızlı ilerleyebilmesi, ortaya çıkan semptomların düzeltilmesi hem de hastalık ilerleme hızında düşüş meydana getirebilmek gibi durumlardan ötürü diyabetli hastaların düzenli olarak taranması önemlidir (Fraser vd. 2014). DR evresi ilerledikçe, şu semptomlar baş gösterebilir:

- Görme alanında koyu uçuşan noktalar veya çizgiler görmek
- Bulanık görme veya çift görme
- Renklerin görülmesinde bozulmalar
- Görme alanında kör nokta oluşması
- Görme yetisini kaybetme



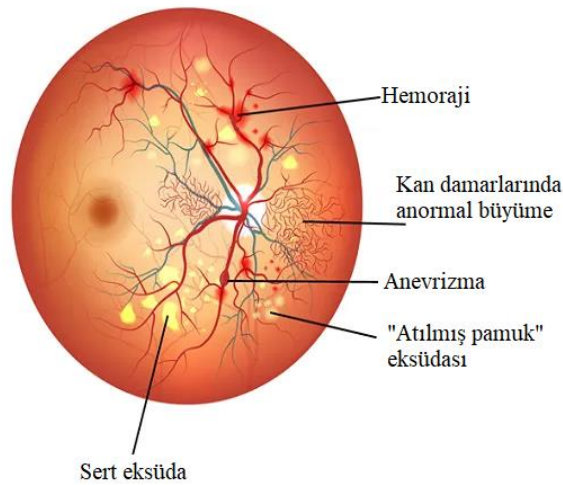
Şekil 2.4 DR hastası ve sağlıklı bireylerin görüşleri (Dishaeye 2017)

DR'nin retinada çeşitli anomalilere neden olabildiği klinik özellikleri şöyledir (Mookiah vd. 2013):

- I. Mikroanevrizmalar (MA): Retina hasarının en erken görünen belirtisi denebilir. Anormal geçirgenlik ve / veya retina kan damarlarının perfüzyonu olmaması MA oluşumuna neden olur. 125 mikrondan daha

- küçük kırmızı bir noktadır ve keskin kenar boşluklarına sahiptir.
- II. Sert eksüdalar: Anormal retinal damarlardan sızan lipoproteinler ve diğer proteinlerdir. Keskin kenar boşluklarına sahip küçük beyaz veya sarımsı-beyaz birikintiler olarak görünür. Genellikle kümeler veya halkalar halinde görülürler ve retinanın dış tabakasında bulunurlar.
 - III. Yumuşak eksüdalar veya atılmış pamuk eksüdası: Arteriolün tıkanması nedeniyle oluşmaktadır. Böylece retinaya kan akışı azalır, aksoplazmik akışı etkileyen ve retinal gangliyon hücre aksonlarında aksoplazmik birikintiye neden olan retina sinir lifi tabakasında iskemiye neden olur. Kalıntı birikimi burada atılmış pamuk eksüdası adı verilen sert beyaz lezyonlar olarak görülür.
 - IV. Hemorajiler (Kanamalar) (HA): Zayıf kılcal damarlardan çıkan kan sızıntıları nedeniyle oluşmaktadır. Şekilsiz ve / veya eşit olmayan yoğunluğa sahip kırmızı bir nokta olarak tanımlanır. Genellikle 125 mikrondan daha büyüktür.
 - V. Neovaskülarizasyon (NV): Retinanın iç yüzeyinde yeni kan damarlarının anormal büyümesidir. Bu kan damarları zayıftır ve sık sık vitreus oyuğuna kanayıp ve görmeyi engellemektedir.
 - VI. Makula ödemi: Retinanın şişmesidir. Makula çevresindeki anormal retinal kılcal damarlarındaki sızıntılardan kaynaklanmaktadır. Merkezi görüşü etkiler.


DR Klinik Özellikleri



Şekil 2.5 DR klinik özellikleri (Shutterstock 2020)

DR hastalığı retinadan çıkan anormal yeni kan damarlarının yokluğu veya varlığına göre iki ana formda incelenebilir: proliferatif DR ve non-proliferatif DR. DR şiddetine göre de ayrıca sınıflandırılabilir.

DR'nin erken aşamalarında, hastalığın etkileri hafiftir. Non-proliferatif DR (NPDR), retinadaki kan damarlarının çeperlerinden zayıflayarak ve şişerek mikroanevrizma oluşturmaya başladığı evredir. Bu zayıf kan damarları daha sonra retinaya sıvı salarak makulanın şişmesine neden olmaktadır. NPDR genellikle zor farkedilmektedir ve doktorlar ilk evrenin başlangıcını doğrulamak için fundus fotoğrafçılığı kullanmaktadırlar. NPDR ayrıca 'hafif', 'orta' ve 'şiddetli' şeklinde kategorilere ayrılabilir. Hafif ve orta derecede NPDR için proliferatif retinopatiye bir yıllık ilerleme riskleri sırasıyla yüzde 5 ve 15 iken, şiddetli kategorisinde bir yıllık riski yüzde 52 ve üstündedir.




Şekil 2.6 DR'li retina ve sağlıklı retina

İkinci evre olan proliferatif DR'de (PDR) gözün arkasındaki anormal yeni kan damarları oluşmasına (neovaskülarizasyon) müteakip bunun sonucunda vitreus kanaması, fibroz ve traksiyon retina dekolmanı meydana gelerek görüşü bulanıklaştırabilir. Bu kanama ilk kez ortaya çıktığında çok şiddetli olmayabilir. PDR, önceki NPDR aşamalarından sonra oluşabilmekte veya NPDR evresi geçirilmeden de ortaya çıkabilmektedir. Anormal damarlardan vitreus içine kanama retinaya giden ışık yolunu bloke ederse PDR'de görme kaybı akut olarak ortaya çıkabilmekteyken; bununla birlikte, buradaki kan sıklıkla yeniden emilmekte ve görme kendiliğinden düzelmektedir. Retina dekolmanı, makula iskemisi veya bu faktörlerin zaman zaman üst üste binmesiyle daha kalıcı görme kaybı meydana gelebilmektedir (Fraser vd. 2014).

Çizelge 2.1 DR evre özellikleri (Chan vd. 2016)

DR Tipi	Alt Evresi	Evrenin Klinik Özellikleri
NPDR	Hafif NPDR	En az 1 adet mikroanevrizma
	Orta NPDR	Mikroanevrizmadan daha fazla semptom oluşur, ancak şiddetli NPDR'den daha az semptom görülmelidir
	Şiddetli NPDR	Proliferatif DR belirtileri görülmeksizin '4-2-1 kuralı'na göre; 4 retina kadranının her birinde şiddetli intraretinal kanamalar ve mikroanevrizmalar, en az 2 retina kadranında şüpheye mahal vermeyecek venöz boncuklar, en az 1 retina kadranında intraretinal mikrovasküler anomaliler görülmelidir.
PDR		Neovaskülarizasyon veya Vitreus ya da preretinal kanama görülmelidir.

DR tanısı için bireylere periyodik rutin muayene yapılmalıdır. Bu kapsamda oftalmoskop vasıtasıyla göz dibi incelemesi, görme netliği ölçümü, göz içi basınç ölçümü ve biyomikroskopik muayene yapılabilir. Oftalmoskop, göz dibinin (fundus) incelenebilmesi için kullanılan; ışık kaynağı, içbükey küresel ayna ve çeşitli merceklerden oluşan tıbbi alettir. Hastanın göz dibini direkt olarak görüntüleyen direkt oftalmoskop ve retinanın ters, gerçek ve büyütülmüş görüntüsünü daha geniş görme alanında sunan indirekt oftalmoskop olmak üzere iki çeşittir. DR tanısı için bunun yanı sıra ek muayene yöntemleri bulunmaktadır. Fundus floresein anjiyografi (FFA) en çok kullanılan yardımcı tanı tekniğidir. Bu teknikte hastaya damardan 'floresein' isimli ilaç verilerek retina damarlarına ulaşması beklenmektedir. Floresein göz dibi damarlarına ulaştığında anjiyografi cihazı özel flaş ile retinanın siyah beyaz fotoğraflarını çekmektedir. Böylece damarlardaki sızıntı veya kanamalar rahatlıkla tespit edilebilmektedir. Optik Koherens Tomografi (OKT) cihazı retinaya gönderilen kızılötesi ışığı yakalayıp farklı doku katmanlarından gelen yansıma zamanı ve şiddet bilgileriyle dokuların yüksek çözünürlüklü kesitlerini oluşturmaktadır (Cebeci ve Akarçay 2012).



Şekil 2.7 İki hastanın göz dibi, FFA ve OKT görüntüleri (Tang vd. 2019)

2.4 Kaynak Özetleri

DR teşhis ve sınıflandırılması için yıllardır farklı yöntemler denenerek ilgili çalışmalar yapılmaktadır. YSA ve görüntü işleme teknikleri literatüre kazandırıldığından beri tıbbi görüntülerde teşhis ve sınıflandırma için bu yöntemlere ilgi artmıştır. DR hakkında da 2'li, 3'lü, 4'lü ve 5'li sınıflandırma çalışmaları yapılmıştır. İlgili literatüre bakıldığında bu konuda YSA ve yardımcı yöntemlerle yapılmış çalışmalara kısaca değinilebilir.

Pratt vd. (2016), Kaggle verisetindeki 80.000 DR görüntüsünün 5000'ini validasyon için ayırarak kalanını 10 konvolüsyon, 8 maxpooling, 2 dropout ve 3 tam bağlantı (fully connected) katmanına sahip KSA'nda eğitmiştir. Aktivasyon fonksiyonu olarak ReLu kullanmıştır. Verisetindeki farklı aydınlatma düzeyine sahip görüntülerin sınıflandırmayla ilgili gereksiz varyasyonlar oluşturmasını engellemek için renk normalizasyonu uygulanmış ardından 512x512 piksel boyutuna yeniden boyutlanmıştır. Eğitim sırasında görüntüler 0-90° arasında rastgele döndürülmüş, yatay ve dikey olarak kaydırılmış veya ters çevrilmiştir. 5000 görüntünün; Sağlıklı, Hafif NPDR, Orta NPDR, Şiddetli NPDR ve Proliferatif DR olarak 5'li sınıflandırılmasında %75 doğruluk (accuracy) , %95 özgüllük (specifity) ve %30 duyarlılık (sensitivity) elde edilmiştir.

Doshi vd. (2016), çalışmasında DR'nin 5'li sınıflandırılması için EyePACs (Kaggle)

verisetinden 72.390 görüntü eğitim, 5000 görüntü test için kullanılmıştır. Görüntüler önce 512x512 piksel boyutuna dönüştürülmüş, sonra bu RGB görüntülerin yeşil katmanı üzerinde histogram eşitleme ve normalizasyon işlemleri uygulanmıştır. Optimizasyon tekniği olarak Nesterov-Momentum kullanılmış üç KSA modeli içinde en yüksek 0,386 kuadratik kapa skoru, 3 farklı KSA modelinin birleştirilmesiyle oluşan modelde test edilmesi sonucunda ise 0,3996 kuadratik kapa skoru elde edilmiştir.

Alban ve Gilligan (2016), çalışmasında Kaggle verisetini kullanmış, çalışmada görüntülerin retina dairesi alanı dışındaki siyah alan kırılarak 256x256 boyutuna getirilmiştir. Görüntü üzerindeki gürültüler giderildikten sonra dengesiz verisetindeki sınıfları dengelemek için mevcut görüntülerin ayna görünütüsü alındıktan sonra 90°, 180° ve 270° çevrilmiş halleri verisetine eklenmiş ve veriseti 8 kat artırılmıştır. Sınıflandırma için GoogleNet ve AlexNet modelleri kullanılmıştır. AlexNet modeli 2'li sınıflandırma için 0,6695, 3'lü sınıflandırma için 0,5705, 5'li sınıflandırma için 0,4073; GoogleNet modeli ise 2'li sınıflandırma için 0,7105, 3'lü sınıflandırma için 0,5821, 5'li sınıflandırma için 0,4168 doğruluk oranı elde etmiştir.

Li vd. (2017) DR'yi 2'li sınıflandırmak için iki farklı veriseti kullanmıştır. DR1 veriseti 687 sağlıklı ve 327 hastalıklı olmak üzere 1014 görüntü, MESSIDOR veriseti 546 sağlıklı ve farklı seviyelerde olmak üzere 654 hastalıklı görüntü içermektedir. Görüntü işleme konusunda görüntülerde retina dairesi dışındaki siyah bölgeler kırılmış ve görüntüler 224x224 boyutuna getirilmiştir. Eğitim aşaması için ince ayarlı 4 model: AlexNet, VGG-s, VGGNet-vd-16 ve VGGNet-vd-19 kullanılmıştır. Tüm deneyler için 5 kat çapraz doğrulama metodu kullanılan deneylerde DR1 veriseti için VGGNet-vd-19 modeli %94,12 ve MESSIDOR veriseti için VGG-s modeli %92,01 doğruluk oranıyla en yüksek başarıyı göstermiştir.

Ghosh vd. (2017) DR'yi 2'li ve 5'li sınıflandırmak için Kaggle (EyePacs) verisetindeki 35.126 görüntüyü kullanmıştır. 3000x2000 boyutundaki görüntüler 512x512 boyutuna getirilmiş ve verisetindeki dengesizliğin olumsuz etkilerini gidermek için görüntüler görüntü zenginleştirme işlemleri kullanılarak artırılmıştır. Daha sonra görüntü normalizasyonu ve gürültü giderme teknikleri uygulanmıştır. Eğitim işlemi için 13 konvolüsyon, 5 maxpooling, 3 dropout, 2 maxout ve 1 tam bağlantılı katmana sahip bir KSA tasarlanmıştır. Optimizasyon tekniği olarak Nesterov-Momentum kullanılmıştır.

Model 3190 test görüntüsünde 2'li sınıflandırma için yaklaşık %95, 5'li sınıflandırma için %85 doğruluk oranı yakalamıştır.

Zhang vd. (2017) DR'yi 5'li sınıflandırma amacıyla Kaggle verisetindeki 35.000'in üzerindeki görüntüyü %60'ı eğitim %20'si validasyon ve %20'si test seti olacak şekilde ayırmıştır. Verisetinin %73'ünden fazlasının "0" sınıfını içermesi nedeniyle oluşacak dengesizliğin olumsuz etkilerini gidermek için maliyet duyarlı öğrenme (cost sensitive learning) ve azınlık sınıfların aşırı örneklenmesi (oversampling) metodları kullanılmıştır. Bu şekilde daha dengeli bir veriseti elde edildikten sonra görüntülerde retina dışı kalan bölge kırılmış, 512x512 boyutuna getirilmiş ardından renk ve parlaklık normalizasyonu yapılarak görüntü işleme adımları gerçekleştirilmiştir. Eğitim esnasında modelin aşırı öğrenmesini (overfitting) engellemek adına görüntüler rastgele bir şekilde yatay ve dikey çevrilmiş, gauss filtresiyle yumuşatılmış, kontrastıyla oynanmış ve 0°-360° arasında döndürülmüştür. Deney aşamasında ResNet modeli tercih edilmiş, hiperparametreler olarak öğrenme oranı başlangıçta 0,2 (her 5000 iterasyonda 2'ye bölünmektedir), mini batch boyutu 64, momentum 0,9 seçilmiştir ve 7000 test görüntüsünde yaklaşık %81 doğruluk oranı sağlanmıştır.

Gargeya ve Leng (2017) DR'yi hastalık var veya hastalık yok şeklinde derin öğrenme yöntemiyle 2'li sınıflandırmak adına Kaggle verisetinden 75.137 görüntü eğitim ve test için kullanmıştır. Ayrıca Messidor2 ve E-Ophtha verisetleri harici doğrulama için kullanılmıştır. Verisetindeki görüntülerin piksel değeri öncelikle 0-1 arasında ölçeklenmiş ardından görüntüler 512x512 boyutuna düşürülmüştür. Görüntüyü döndürme, kontrast ayarı gibi görüntü zenginleştirme tekniklerinden faydalanılmıştır. İlgili model, yerel verisetinde 5 kat çapraz doğrulama metoduyla %94 duyarlılık ve %98 özgüllük ile beraber 0,97 AUC (roc eğrisi altında kalan alan) skoru elde etmiştir. Bağımsız Messidor2 ve E-Ophtha verisetlerinde ise sırasıyla 0,94 ve 0,95 AUC skoru elde etmiştir.

Garcia vd. (2017) Kaggle verisetindeki farklı en boy oranı, aydınlık seviyesi ve renk ortalamasına sahip 35.126 görüntüyü göz küresi kalacak şekilde kırpmış, 128 gri seviyesine eşleştirmiş ve 256x256 boyutuna çevirmiştir. Yapılacak ikili sınıflandırmada görüntülerin %73,48'i sağlıklı görüntüleri, %26,52'si ise hastalıklı görüntüleri temsil etmektedir. Deneyler için 5 farklı sinir ağ metodu kullanılmıştır:

- i. Model1: Test seti için hastalıklı görüntü kadar sağlıklı görüntü kullanılarak veriseti %50-%50 dengelenmiştir. 0,01 öğrenme oranına sahip sıfırdan eğitilmiş 6 katmanlı bir KSA'dır.
- ii. Model2: Test seti için hastalıklı görüntü kadar sağlıklı görüntü kullanılarak veriseti %50-%50 dengelenmiştir. 0,01 öğrenme oranına sahip sıfırdan eğitilmiş 9 katmanlı bir KSA'dır.
- iii. VGG16: Test seti için hastalıklı görüntü kadar sağlıklı görüntü kullanılarak veriseti %50-%50 dengelenmiştir. 0,0001 öğrenme oranına sahip önceden eğitilmiş 16 katmanlı bir KSA'dır.
- iv. VGG16noFC1: Test seti için hastalıklı görüntü kadar sağlıklı görüntü kullanılarak veriseti %50-%50 dengelenmiştir. 0,0001 öğrenme oranına sahip sıfırdan eğitilmiş tam bağlantı katmanı olmayan 15 katmanlı bir KSA'dır.
- v. VGG16noFC2: Orijinal veriseti kullanılmıştır. 0,0001 öğrenme oranına sahip sıfırdan eğitilmiş tam bağlantı katmanı olmayan 15 katmanlı bir KSA'dır.

Çalışma itibariyle Model1 45 dönem (epoch) sonucunda %63,6 doğruluk oranına, Model2 91 dönem sonucunda %66,4 doğruluk oranına, VGG16 80 dönem sonucunda %74,3 doğruluk, %62 duyarlılık ve %86 özgüllük oranına, VGG16noFC1 75 dönem sonucunda %72,7 doğruluk, %68 duyarlılık ve %77,6 özgüllük oranına ulaşmış olup, VGG16noFC2 ise 80 dönem sonucunda %83,68 doğruluk, %54,47 duyarlılık ve %93,65 özgüllük oranına ulaşarak en yüksek doğruluk oranını yakalamıştır.

Rakhlin (2018) DR'nin 2'li teşhisi adına derin KSA kullanmıştır. KSA modeli EyePACS tarafından sağlanan Kaggle veriseti üzerinde eğitilmiş (%30,5'i hastalıklı olmak üzere 81.670 görüntü), test işlemi ise Kaggle verisetinin ayrılmış bir kısmı (%30,5'i hastalıklı olmak üzere 7026 görüntü) ve Messidor-2 (%21,7'si hastalıklı olmak üzere 1748 görüntü) olmak üzere 2 ayrı veriseti üzerinde gerçekleştirilmiştir. Eğitim 19 katmanlı 8.013.393 parametreye sahip yeniden tasarlanmış VGG16 modeli üzerinde gerçekleştirilmiştir. Modelin etkililiğini artırmak için dropout, görüntü zenginleştirme ve görüntü önileme teknikleri kullanılmıştır. Görüntüler öncelikle normalize edilmiş, ilgili olmayan kısımlar kırılmış ve 540x540 boyutuna getirilmiştir. Sonuç olarak ilgili model 2'li sınıflandırma için Kaggle test setinde 0,92 AUC skoru, Messidor-2 test setinde 0,97 AUC skoru elde etmiştir.

Wang vd. (2018) DR evrelerini 5’li sınıflandırmak için farklı derin KSA mimarilerinin performanslarını karşılaştırmıştır. Deney, EyePACS tarafından sağlanan halka açık Kaggle veri kümesinden çıkarılan, DR evreleri dengeli seçilmiş toplam 166 fundoskopik görüntüye dayanılarak gerçekleştirilmiştir. Sınıflandırma modellerini eğitmek ve test etmek için 5 kat çapraz doğrulama yöntemi kullanılmıştır. Optimizasyon algoritması SGDM’dir. Deneyde kullanılan model ve parametreler çizelge 2.2’de verilmiştir.

Çizelge 2.2 Model ve parametreler (Wang vd. 2018)

Hiperparametreler	AlexNet	VGG16	InceptionNet V3
Başlangıç Öğrenme Oranı	0,0001	0,0001	0,001
Öğrenme Oranı Düşürme Faktörü	0,1	0,1	0,16
Mini Batch Boyutu	20	20	32
Momentum	0,9	0,9	0,9
Görüntü Boyutu	227x227	224x224	299x299

Modellerden AlexNet %37,43, VGG16 %50,03 ve InceptionNet V3 %63,23 doğruluk oranı tutturmuştur.

Lian vd. (2018) çalışmasında DR’nin KSA kullanılarak sınıflandırılması problemindeki KSA mimarileri, görüntü ön işleme, dengesiz veriseti ve hiperparametrelerin ince ayar faktörlerini incelemiştir. Çalışmada kullanılan veri seti EyePACS tarafından Kaggle aracılığıyla sağlanmaktadır. Veri seti 35.126 görüntüden oluşmakta ve her görüntü 0 (normal), 1 (hafif NPDR), 2 (orta NPDR), 3 (şiddetli NPDR) ve 4 (PDR) değerine karşılık gelen 0-4 etiketiyle DR evreleri manuel olarak derecelendirilmiştir. Görüntüler, çeşitli kamera türleri ve farklı görüş alanları kullanıldığından oldukça heterojendir. Çalışmada 3 KSA mimarisi: AlexNet, ResNet50 ve VGG16 kullanılmıştır. Verisetindeki görüntüler farklı çözünürlükte olduğundan hepsi 256x256 olarak değiştirilmiştir. Daha sonra görüntüdeki siyah boşluklar kırılmış ve görüntü Gauss filtresinden geçirilmiştir. Verisetindeki sınıf dengesizliğini gidermek için ise görüntülere yeniden örnekleme (resampling) uygulanmıştır. Baskın temsil edilen sınıfların sayısı indirgenmiş, azınlık sınıfları ise rastgele sağ/sol yönünde çevrilerek elde edilen görüntülerle temsil oranı

arttırılmıştır. Modeller sıfırdan eğitilmek yerine daha önce eğitilmiş modellerden ince ayar yapılarak probleme göre düzenlenmiştir. Son katman hariç tüm parametreler ImageNet'te önceden hazırlanmış ağırlıklar ile başlatılmıştır. Varsayılan öğrenme oranı 0,001'de tutulmuş ve her 27 dönemde bir 10 kat düşürülmüştür. Mini batch boyutu 25, momentum 0,9 seçilmiştir. Sonuç olarak 3506 görüntülük test setinde AlexNet %73,19; ResNet50 %76,41 ve VGG16 %79,04 doğruluk oranı sağlamıştır. En iyi sonucu VGG16 modeli sağladığından bu model görüntü işlemenin, sınıf dengesizliğinin ve ince ayarın başarımlarına etkisini gözlemek için tekrar bu faktörlerden biri dikkate alınmadan eğitilmiştir. VGG-NP (görüntü ön işleme yapılmamış model) %76,01; VGG-NR (dengelenmiş veriseti kullanılmayan model) % 72,76 ve VGG-NF (ince ayar yapılmadan sıfırdan eğitilmiş model) % 77,58 doğruluk oranı sağlamıştır ve bu faktörlerin doğruluk oranına ne denli etkide bulunduğu gösterilmiştir.

Lam vd. (2018) AlexNet ve GoogleNet modellerini eğiterek DR'yi 2'li, 3'lü ve 4'lü sınıflandırmak üzere test etmiştir. DR görüntüleri, 5 sınıf etiketli (normal, hafif, orta, şiddetli, proliferatif DR) 35.000 görüntülü Kaggle veri setinden ve 4 sınıf etiketli (normal, hafif, orta, şiddetli) 1200 renkli fundus görüntülü Messidor-1 veri setinden elde edilmiştir. Modeli verimli hale getirmek amacıyla, zor özellikleri öğrenmek için daha küçük ama daha ideal bir veri kümesi, Messidor-1 veri kümesine Kaggle verisetinin Hafif DR sınıfından 550 görüntü eklenmesiyle oluşturulmuştur. Eğitim seti 1077, validasyon seti 269 ve test seti 400 görüntüden oluşmaktadır. Görüntü ön işleme adımları şu şekildedir: retinanın dairesel görüntüsü Otsu metodu kullanılarak kırılmış ve görüntüler her kanaldan minimum piksel yoğunluğu çıkarılarak ve 0 ila 1 arasındaki pikselleri temsil etmek için ortalama piksel yoğunluğuna bölünerek normalize edilmiştir. Kontrast ayarı, kontrast limitli adaptif histogram eşitleme (CLAHE) algoritması kullanılarak yapılmıştır. Veri zenginleştirme için görüntüler rastgele yakınlaştırılmış ve döndürülmüştür. 256x256 çözünürlüklü görüntüler transfer öğrenme yaklaşımı ile önceden eğitilmiş AlexNet ve GoogLeNet mimarileri ile eğitilmiştir. GoogleNet 2'li, 3'lü ve 4'lü sınıflandırmada sırasıyla %74,5 (görüntü işleme, adam optimizör, 0,0001 öğrenme oranı), %68,75 (görüntü işleme, adagrad optimizör, 0,001 öğrenme oranı), %57,25 (ham görüntü, adam optimizör, 0,0001 öğrenme oranı) ile en yüksek doğruluk oranlarını yakalamıştır.

Chen vd. (2018) EyePACS tarafından sağlanan ve Kaggle web sitesinden elde edilen 35.126 görüntüye sahip verisetinin %80'ini eğitim %20'sini test için kullanarak DR'yi 5

sınıfta teşhis etmeyi amaçlamıştır. Görüntüler 299x299 boyutuna çevrildikten sonra görüntülere kırpma, döndürme, ölçekleme ve kontrast değiştirme işlemleri uygulanmıştır. Görüntünün her piksel değeriyle çevresindeki piksel değerlerinin ortalaması çıkarılmış ve ortalama %50 gri tonlamalı ile değiştirilerek kan damarlarının özellikleri daha görünür hale getirilmiştir. Son olarak tüm pikseller -1 ve 1 arasında normalize edilmiştir. KSA modeli olarak Inception v3 tercih edilmiştir. Optimizasyon için 0,001 başlangıç öğrenme oranıyla birlikte SGD seçilmiştir. Deney sonucunda DR'nin 5 evrede sınıflandırılması için önerilmiş model %80 doğruluk ve 0,64 kappa skoru elde etmiştir.

Kwasigroch vd. (2018) DR'nin var/yok şeklinde 2'li teşhisi ve hastalığın evrelerine göre 5'li sınıflandırılması adına KSA'dan faydalanmıştır. Veri seti dengesiz sınıflar içeren Kaggle'dan seçilmiştir. Eğitim seti 35.000, validasyon seti 1000 ve test seti 1000 görüntü içermektedir. Veri kümesindeki çeşitli görüntü boyutları nedeniyle 224x224 piksel sabit çözünürlüğe sahip olacak şekilde ölçeklendirilmiş ve sadece retina dairesini içerecek şekilde kırılmıştır. Daha sonra, piksellerin değerleri 0-1 aralığına normalize edilmiştir. Ardından veri kümesindeki örneklerin ortalamaları çıkarılmış ve standart sapmalarına bölünmüştür, böylece veri kümesinin ortalamasının 0 ve standart sapmasının 1 olması sağlanmıştır. Bunlara ek olarak görüntüler Gauss bulanıklaştırma filtresinden geçirilmiştir. KSA'nın performansını arttırmak için veri artırımı yapılmış; ters çevirme, yatay ve dikey öteleme, yakınlaştırma, yatay ve dikey döndürmeler gibi rastgele görüntü dönüşüm metodları uygulanmıştır. Transfer öğrenme yöntemi için 13 konvolüsyon katmanı, 5 maxpooling katmanı, 2 tam bağlantılı katman ve 2 dropout (0.5) katmanına sahip VGG-D mimarisi tercih edilmiştir. Mini batch boyutu 35 ve optimizasyon olarak 0,9 momentum ile SGD seçilmiştir. Görüntüler çoklu olarak etiketlenmiştir. Her sınıftan 200 örnek bulunan 1000 görüntülük test setinde model, hastalığın 2'li teşhisinde %81,7; evrelerine göre 5'li sınıflandırılmasında %50,8 doğruluk elde etmiştir. Bunlara ek olarak 0,776 kappa skoru, %89,5 duyarlılık ve %50,5 özgüllük yüzdesi bulunmaktadır.

Ignatius vd. (2019) DR sınıflandırılmasında 3 KSA modelini karşılaştırmıştır. Araştırmadaki sınıflandırma normal retina ve DR'li retinadan oluşan ikili sınıflandırmadır. 546 normal, 654 DR'li toplam 1200 görüntü içeren Messidor veriseti kullanılmıştır. Bu görüntülerin 600'ü eğitim 240'ı validasyon 360'ı test için ayrılmıştır. Görüntülerin retina dairesi dışındaki alan kırılmış, 512x512 piksel boyutuna getirilmiş ardından RGB görüntüler yeşil kanallı olarak çıkarılmış ve kontrastı artırılmıştır.

Kullanılan KSA modelleri: 2'şer konvolüsyon, maxpooling ve tam bağlantılı katmana sahip basit KSA modeli, LeNet modeli ve DRnet olarak adlandırılmış özelleştirilmiş modeldir. Test setinde KSA modeli %51,1; LeNet %53,3 ve DRnet %58,3 doğruluk oranı elde etmiştir. DRnet modelinin daha başarılı olmasının sebebi diğer modellerden DR özelliklerini öğrenebilecek kadar derin tasarlanmasıdır.

Sarki vd. (2019) çalışmasında hafif DR ve sağlıklı retinanın fundus görüntülerinden erken DR tespitinin performansının iyileştirilmesini amaçlamıştır. Bu kapsamda:

- Transfer öğrenimi metodu kullanılarak 13 KSA mimarisinin (Xception, VGG16, VGG19, ResNet50, InceptionV3, InceptionResNetV2, MobileNet, MobileNetV2, DenseNet121, DenseNet169, DenseNet201, NASNetMobile ve NASNetLarge) kapsamlı değerlendirmesi,
- Uygulama örnek çalışmasının özelliklerini yansıtacak şekilde ince ayar yapılması,
- Çeşitli optimizasyonların (RMSprop, SGD, Adagrad, Adadelta, Adam, Adamax ve Nadam) performans değerlendirmesi ve en uygununun seçimi,
- İki veri seti kombinasyonu kullanılması (Kaggle ve Messidor) ve bu veri setlerinde yapılan veri artırımının performansa etkisi

adımları uygulanmıştır. Sağlıklı/hafif DR sınıflandırılması için en verimli sonuç, RMSprop optimizasyon kullanılan ince ayarlı ResNet50 modelinin Kaggle+Messidor kombine veri setinin veri artırılması uygulanmış halinde %86 doğruluk elde etmesiyle bulunmuştur.

Arora ve Pandey (2019) DR'nin 5'li sınıflandırılması için bir derin öğrenme algoritması geliştirmiştir. Çalışmada 5 sınıf etiketli 35.126 görüntü içeren Kaggle veri seti kullanılmıştır. Verisetindeki görüntüler modele verilmeden 128x128 piksel boyutuna getirilmiştir. Ön işlemeden sonra, çeşitli parametrelerinin (döndürme, yakınlaştırma, ters çevirme vb). değerleri ayarlanarak veri setindeki görüntüler artırılmıştır. Deney tasarlanan KSA mimarisine öğrenme oranı 1000 örnek görüntü üzerinde gerçekleştirilmiştir. 0,001 öğrenme oranıyla 0,744 doğruluk oranı ve 0,8653 kayıp fonksiyonu değeri elde edilmiş ve 0,01 öğrenme oranına göre daha başarılı olmuştur.

Sharma vd. (2019) DR'yi saptama sürecinin otomasyonu için KSA kullanan bir model önermiştir. Deneyler, halka açık DR1 ve MESSIDOR veri setlerindeki 1014 ve 1200

fundus görüntüleri ile gerçekleştirilmiştir. Verisetindeki görüntülere renk normalizasyonu uygulanmış, görüntülerdeki gereksiz kısımlar kırılmış ve 128x128 piksel boyutuna getirilmiştir. Önerilen KSA modeli Kaggle veri kümesindeki 200 test görüntüsü üzerinde 5'li sınıflandırma için %74,04 doğruluk oranı elde etmiştir.

Singh vd.'nin (2019) çalışması iki ana bölüme ayrılabilir, ilki fundus görüntülerinin DR olan ve DR olmayan olarak iki retina kategorisine ayrılmasıdır. İkinci kısmı ise, retina görüntülerini hastalığın 5 evresine göre ayıran bir model oluşturmayı içermektedir. 2'li sınıflandırma için, Messidor ve Kaggle veri setinin görüntüler kullanılmıştır. Bununla birlikte 5'li sınıflandırma problemi özelinde de Kaggle veri seti kullanılmıştır. Kaggle tarafından sağlanan veriler, beş sınıfın tümü için dengesiz olduğundan görüntülerin 45, 90, 120, 180 ve 270 derecelik açılara döndürülmüş halleri de eklenerek veri kümesi büyütülmüş ve daha dengeli veri elde edilmiştir. 2'li ve 5'li sınıflandırma problemi için 2 KSA modeli oluşturulmuştur. 2'li sınıflandırma modelinde sırasıyla 32, 32 ve 64 nöron sayısına sahip 3 konvolüsyon katmanı kullanılmıştır. Ağdaki her katman ReLU aktivasyon fonksiyonu ile aktive edilmiş ve bunların ardından 2x2 filtreye sahip maxpooling katmanı ve ağa 2 tam bağlantılı katman eklenmiştir. Model, ikili sınıflandırma için gerekli olan bir sigmoid aktivasyon fonksiyonu ile bitmektedir. Yaklaşık 9600 eğitim görüntüsü ve 100 dönem için 4080 validasyon görüntüsü ile eğitilmiştir. 5'li sınıflandırma için, 24.000 eğitim görüntüsü ve 4800 validasyon görüntüsü ile 32, 64, 128 ve 512 filtrelili 4 konvolüsyon katmanına sahip KSA eğitilmiştir. Çoklu sınıflandırma problemi olduğundan softmax aktivasyon fonksiyonu kullanılmıştır. 2'li sınıflandırma için 4080 görüntülü validasyon setinde %71, 5'li sınıflandırma için 4800 görüntülü validasyon setinde %56 doğruluk oranı elde edilmiştir.

Challa vd. (2019) DR 5'li sınıflandırma için Kaggle verisetinden 20.000 eğitim görüntüsü ve 3000 test görüntüsü kullanmıştır. 20.000 görüntü barındıran eğitim seti dengesiz olduğu için veri artırma yöntemleri vasıtasıyla 30.000 görüntülük dengeli eğitim seti oluşturulmuştur. Görüntülerdeki kamera gürültüleri Gauss filtre yardımıyla giderilerek görüntüler model için daha uygun hale getirilmiştir. Ardından görüntüler kırılmış ve 224x224 boyutuna çevrilmiştir. Eğitim için tasarlanan 10 konvolüsyon katmanına sahip KSA, 200 dönemde 32 mini batch boyutu ile %86,64 doğruluk oranı, 0,6318 F1 skoru ve 0,46 kayıp (loss) değeri elde etmiştir.

Qummar vd. (2019) DR'yi evrelerine göre sınıflandırmak için beş derin KSA modelinden (Resnet50, Inceptionv3, Xception, Dense121, Dense169) oluşan bir topluluk modelini Kaggle veriseti ile eğitmiştir. Görüntüler 512x512 piksel boyutuna getirilmiş ve kırılmıştır. 35.126 görüntüye sahip verisetinin dengesiz sınıf dağılımının neden olacağı olumsuz sonuçları gidermek için; diğer sınıf görüntülerin veri artırımıyla baskın sınıf kadar görüntü elde edilmesi (oversampling) ve diğer sınıf görüntülerinden veri çıkararak azınlık sınıf kadar görüntü elde edilmesi (undersampling) yöntemleri uygulanmıştır. Veriseti eğitim, validasyon ve test için sırasıyla %64, %20 ve %16 oranlarında ayrılmıştır. 5 modelden oluşan topluluk modeli için mini batch boyutu 8, başlangıç öğrenme oranı 0,01 seçilmiştir. Topluluk modeli 5 evreli sınıflandırma için %80,8 doğruluk, % 51,5 duyarlılık, % 86,72 özgüllük, % 63,85 kesinlik ve % 53,74 F1 skoru elde etmiştir.

Nagaraj vd. (2019), 5 evreli DR sınıflandırması için transfer öğrenme yöntemini kullanmış ve VGG16 mimarisini modifiye etmiştir. VGG16 sınıflandırma modelinin eğitimi için Kaggle'dan elde edilmiş 35.126 görüntüden oluşan EyePACS veri kümesi kullanılmıştır. Görüntüler eğitimden önce 224x224 piksel boyutuna getirilmiştir. İlgili model 35.126 görüntü üzerinde eğitildikten sonra, 2938 görüntü üzerinde test edilmiş ve elde edilen en yüksek test doğruluğu % 73,72 olarak bulunmuştur.

Dekhil vd. (2019) fundus görüntülerini DR'nin beş aşamasından birinde sınıflandırmak için KSA'ya dayanan bilgisayar destekli bir tanı aracı sunmuştur. Eğitim seti, 1800'ü DR'li görüntüleri içeren yaklaşık 3600 görüntüden oluşmaktadır. Görüntüler VGG-16 transfer öğrenme eğitiminden önce kırılmış ve 224x224 pikselde boyutlandırılmıştır. Eğitim görüntüleri önerilen derin KSA'ya verilmiş ve ağırlıklar SGD iyileştirici ile optimize edilmesiyle tahmin edilmiştir. Giriş görüntüsünün kategorisini tespit etmek için KSA çıkışı bir DVM sınıflandırıcısı ile bağlanmıştır. Önerilen yaklaşım, 553 test görüntüsü için % 77'lik doğruluk ve % 78'lik kuadratik ağırlıklı kappa skoru elde etmiştir.

Chakravarthy vd. (2019) DR'yi derin öğrenme çerçevesinde, giriş görüntüsünün özelliklerini anlamak ve onu normal veya hasta görüntü olarak sınıflandırmak için bir model tasarlamıştır. Veriseti sınıflarını dengeli olarak hazırlamak amacıyla Kaggle, DRIVE ve MESSIDOR gibi ünlü veri setlerindeki görüntülerden meydana getirilmiştir. Bu veriseti, normal ve DR'li görüntülerin eşit dağılımıyla yaklaşık 12.000 yüksek çözünürlüklü görüntüden oluşmaktadır. Eğitim, validasyon ve test verileri oranı sırasıyla

%80, %10 ve %10 olarak alınmıştır. Görüntüler, standartlaştırılmış bir veri kümesi oluşturmak için 512x512 piksel sabit çözünürlük boyutuna ölçeklendirilmiştir. Büyük veri setlerinde önemli bir sorun olan aşırı öğrenmeyi önlemek amacıyla, modelin aynı görüntünün çeşitli yönlerini öğrenebilmesi için dinamik veri artırma gerçekleştirilmiş; döndürme, yatay ve dikey çevirme, yakınlaştırma gibi çeşitli dönüşümler yapılmıştır. Görüntü işleme teknikleri olarak görüntülere CLAHE, Yeşil Kanal Çıkarma + CLAHE ve Gauss Bulanıklaştırma işlemleri uygulanmıştır. Teşhis işlemi için DR-NET modeli önerilmiştir. Optimizer olarak Adam, aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Model %81 doğruluk ve 0,6 kappa skoru elde ederek DR-NET modelinin normal KSA'lara göre daha az parametre ile daha etkili sonuçlar ortaya koyabileceğini göstermiştir.

Tükel (2019) çalışmasında DR'nin 2'li sınıflandırılması için 546'sı sağlıklı ve 654'ü DR'li olan 1200 görüntülük Messidor veri setini kullanmıştır. Görüntülerdeki ihtiyaç olmayan siyah alan kırpıldıktan sonra görüntüler 256x256 boyutuna getirilmiş ve renk normalizasyonu uygulanmıştır. Çalışmada görüntü işleme tekniği olarak CLAHE tercih edilmiş ve bu tekniğin etkililiğini artırmak adına karınca aslanı algoritması uygulanmıştır. DR tespit işlemi için tasarlanan 8 katmanlı KSA; başlangıç öğrenme oranı 0,0001 ve optimizasyon tekniği olarak SGDM seçilerek 900 görüntü ile eğitilmiştir. Matlab üzerinde yapılan çalışma neticesinde önerilen model 300 test görüntüsü üzerinde %95 doğruluk, %96 özgülük, %96 duyarlılık ve %94 duyarlılık oranı yakalamıştır.

Al-Kamachy (2019) DR'nin 5'li sınıflandırılması çalışmasını sıfırdan inşa edilmiş 15 katmanlı KSA, MobileNet, VGG16, Inception-ResNetV2 ve InceptionV3 olmak üzere 5 model üzerinde gerçekleştirmiş ve bu modellerin başarımlarını kıyaslamıştır. Çalışma Kaggle platformu üzerinde Python dili ile gerçekleştirilmiş ve veri seti Kaggle veri setinden oluşturulmuştur. 1000 görüntü %80 eğitim, %10 validasyon ve %10 test seti olacak şekilde bölünmüş ve görüntüler 350x350 boyutuna getirilmiştir (MobileNet eğitimi esnasında 224x224 olarak ayarlanmıştır). Görüntülere renk normalizasyonu yapıldıktan sonra döndürme, kaydırma, çevirme gibi veri artırımı teknikleri uygulanmıştır. KSA model optimizasyon tekniği olarak 0,0001 başlangıç öğrenme oranıyla Adam optimizer seçilmiştir. Eğitim sonunda test seti üzerinde elde edilen sonuçlar: KSA modeli %67 doğruluk ve 0,5 AUC skoru, MobileNet %66 doğruluk ve 0,7 AUC skoru, VGG16 %57 doğruluk ve 0,53 AUC skoru, InceptionV3 %68 doğruluk ve

0,69 AUC skoru ve en başarılı model olan Inception ResNetV2 %68 doğruluk ve 0,69 AUC skoru elde etmiştir.

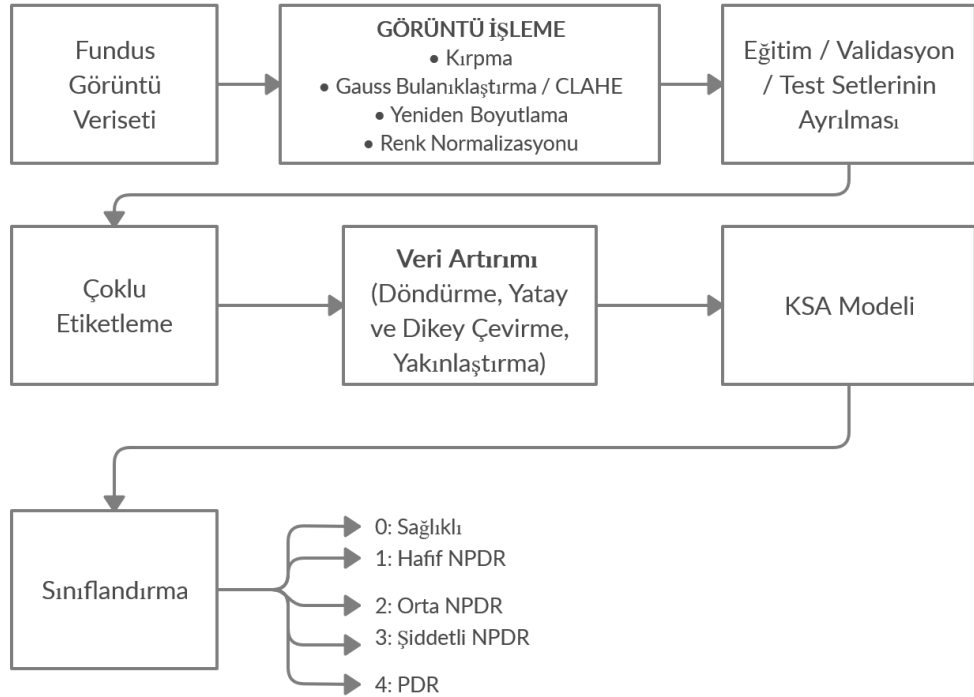
Doshi vd. (2020) fundus görüntülerini DR'nin 5 aşamasına ayırmak için farklı bir ön işleme tekniği ve yeni bir derin öğrenme mimarisi önermiştir. Bu çalışma için 35.216 görüntü içeren Kaggle ve 516 görüntüye sahip IDRID verisetleri birleştirilmiştir. Her iki veriseti için de sağlıklı ve orta seviye DR olan sınıf görüntüleri baskındır. Görüntülerin ön işleme tabi tutulması, derin öğrenme ağına beslenmeden önce kırpma, ölçek küçültme ve doldurmadan ibarettir. Ön işlemeden sonra elde edilen görüntüler $600 \times 600 \times 3$ boyutundadır. Görüntüleri sınıflandırmak için transfer öğrenme metoduyla InceptionV3 ağı ile eğitim işlemi uygulanmıştır. Giriş görüntülerinin $600 \times 600 \times 3$ boyutunda olması ve Inception V3 modelinin $300 \times 300 \times 3$ boyutunda giriş görüntüleri gerektirmesi nedeniyle önceden işlenmiş görüntüler dört parça haline getirilerek modele verilmiştir. Veriseti ayrılırken önce verisetinin %20'si test seti olarak ayrılmış, kalan görüntülerin de %80'i eğitim, %20'si validasyon için ayrılmıştır. Çalışma sonucunda Bilinear (4 komşu pikselin ağırlıklı ortalaması alınır) Ölçek Küçültme görüntü işleme metodu yapılmış görüntülerle, %83,15 doğruluk, % 81,2 duyarlılık, % 84,6 özgüllük ve Öğrenilmiş Görüntü Ölçek Küçültme (Learned Image Downscaling) görüntü işleme metodu yapılmış görüntülerde ise % 85,2 doğruluk, % 83,4 duyarlılık ve % 87,6 özgüllük elde edilmiş ve daha başarılı sonuçlar ortaya koyulmuştur.

Yukarıda verildiği üzere özellikle son yıllarda yapılmış DR tespit ve/veya sınıflandırma işlemleri adına yapılmış çalışmalardan şu sonuçlar ortaya konabilir:

- DR'nin farklı kategorilendirilme durumlarına göre 3'lü veya 4'lü sınıflandırma çalışmaları olsa da, çalışmalar genel olarak DR'nin “var” veya “yok” şeklinde tespiti olarak 2'li sınıflandırma ve hastalığın evrelerine göre 5'li sınıflandırma üzerine odaklanmıştır.
- Derin öğrenme modelinin daha verimli hale getirilmesi için hemen hemen her çalışmada görüntü işleme ve veri zenginleştirme teknikleri uygulanmıştır.
- Gelişen derin öğrenme ve transfer öğrenme metodları son yıllarda daha çok yaygınlaşmış, sınıflandırma ve tespit işlemlerinde başarı oranı artmıştır.

3.MATERYAL ve YÖNTEM

Tezin bu kısmında, çalışmada kullanılan veriler tanıtılmış, bunlar üzerinde uygulanan metod ve uygulama adımları aktarılmıştır. Çalışmanın bu adımları Şekil 3.1’de kısaca gösterilmiştir. DR sınıflandırma metodu, fundus görüntü veriseti üzerinde çeşitli görüntü işleme teknikleri uygulandıktan sonra verilerin uygun şekilde etiketlenerek ilgili KSA modeli üzerinde eğitim / test işlemleri yapılması ve bunun sonucunda görüntülerin sınıflandırılmasından ibarettir.



Şekil 3.1 Çalışmanın akış diyagramı

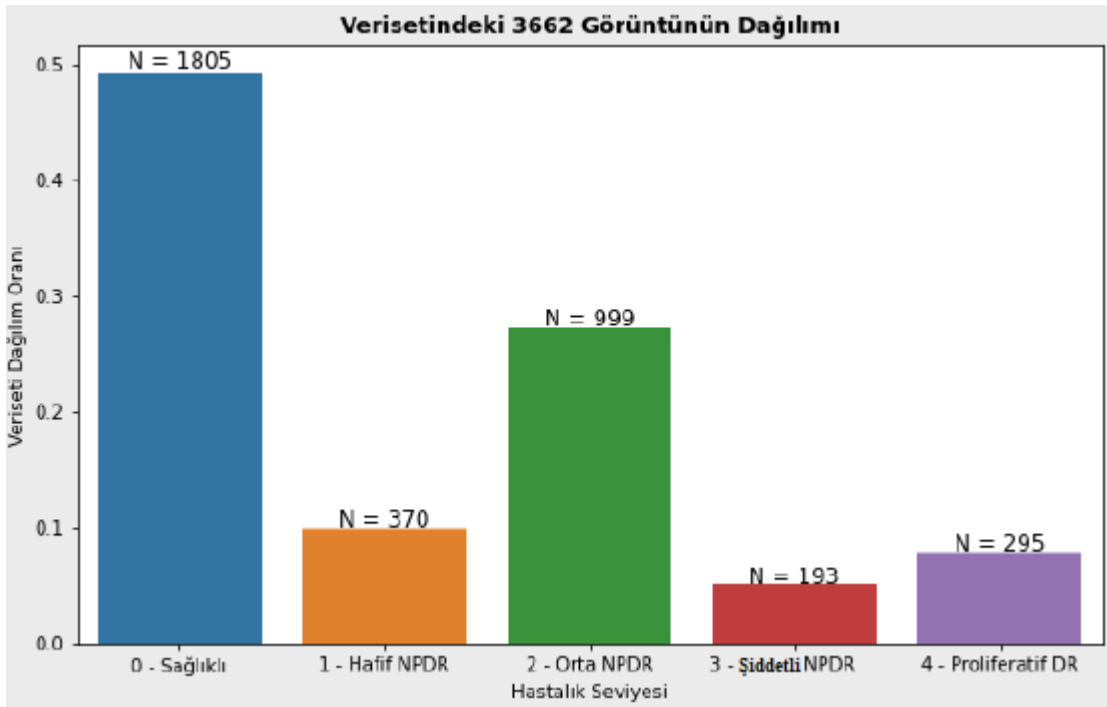
3.1 Materyal

Bu tez çalışmasında, DR hastalığının evrelerine göre 5’li sınıflandırılması için Kaggle APTOS 2019 (Asia Pacific Tele-Ophthalmology Society) yarışması veriseti kullanılmıştır. Veriseti, farklı görüntüleme koşulları altında fundus fotoğrafçılığı ile çekilmiş çok sayıda retina görüntüsü içermektedir. Bu çeşitli retina görüntüleri klinisyenler tarafından incelenerek 0 ila 4 arasında sınıflandırılmıştır. Retina görüntülerinin sınıflandırılması şu şekildedir:

- 0: Sağlıklı (DR yok)
- 1: Hafif Non-Proliferatif DR
- 2: Orta Non-Proliferatif DR
- 3: Şiddetli Non-Proliferatif DR
- 4: Proliferatif DR


Veriseti görüntüleri gerçek dünyadaki gibi gürültü içermekte, görüntü üzerinde artefaktlar bulunabilmekte ve görüntüler aşırı parlak veya aşırı karanlık olabilmektedir (Anonymous 2019).

Her DR seviyesi için farklı sayıda görüntü içeren veriseti toplam 3662 görüntü barındırmaktadır. Verisetinin görüntü sınıfı dağılımı Şekil 3.2 üzerinde gösterilmiştir.



Şekil 3.2 Verisetindeki görüntülerin dağılımı

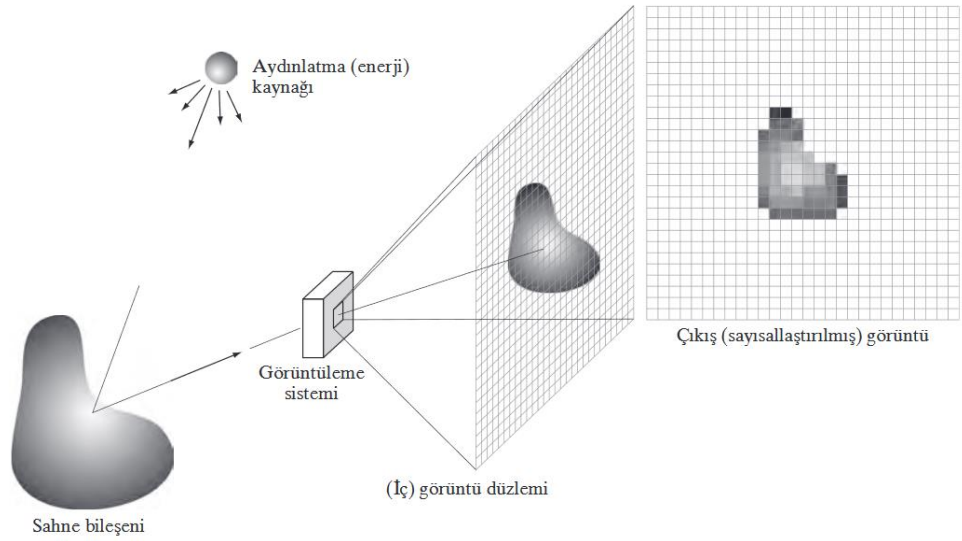
Verisetindeki her sınıftan farklı boyutlardaki rastgele örnek görüntüler Şekil 3.3 üzerinde gösterilmiştir.



Şekil 3.3 Retina veriseti görüntüleri

3.2 Görüntü İşleme

Aydınlatma kaynağı ve görüntüleme sistemleri yardımıyla gerçek dünyadaki objelerin görüntüleme sistemindeki izdüşümünün yakalanarak elektronik ortamda tutulması ve bu sayısal görüntüler üzerinde çeşitli teknikler ile fayda sağlanması süreçleri görüntü işleme olarak adlandırılmaktadır.



Şekil 3.4 Sayısal görüntü elde etme süreci (Gonzalez ve Woods 2014)

Görüntü işleme süreçleri için gürültü azaltmaya yönelik işlemler alçak seviye süreç, görüntülerin özneliklerini çıkarma odaklı işlemler orta seviye süreç ve toplanan görüntülere anlam verebilme süreçleri ise yüksek seviye süreç olmak üzere 3 tip bilgisayarlı süreç olduğu göz önüne alınmıştır (Gonzalez ve Woods 2014).

3.2.1 Görüntü yumuşatma

Görüntüde gürültü; görüntü üzerindeki ayrıntıları gizleyen, istenmeyen renk veya parlaklık dalgalanmalarıdır. Görüntü üzerindeki bu tip istenmeyen bozunmaları giderebilmek adına yumuşatma (smoothing) / bulanıklaştırma (blurring) filtreleri kullanılmaktadır. Bu filtreler düşük frekanslara izin verdiği için aynı zamanda alçak geçiren filtrelerdir, böylece frekans değerlerinin hızlıca değiştiği görüntünün keskin kenarları, parazit vs. yumuşatılarak giderilmiş olur. Bu işlem giriş görüntüsü ile filtre çekirdeğinin 2 boyutlu konvolüsyon işlemine tabi olması ile gerçekleşmektedir.

OpenCV kütüphanesinin sunduğu yumuşatma teknikleri:

- Ortalama Filtresi
- Medyan (Ortanca) Filtre
- Gauss Bulanıklaştırma Filtresi
- Bilateral Filtre

3.2.1.1 Ortalama filtresi

Ortalama filtresi, görüntüdeki her bir pikselin değerini filtre merkezine denk gelen piksel de dahil olmak üzere komşu piksellerin ortalamasıyla değiştirmektedir. Bu yöntem gürültülerin giderilmesi adına fayda sağlarken diğer taraftan görüntünün bulanıklaşmasına ve kenar hatlarının kaybolmasına neden olmaktadır. Bulanıklığı azaltma amacıyla filtre çekirdeği bazı piksellere ağırlık verecek şekilde değiştirilmektedir. Böylece görüntü ağırlıklı ortalamayla filtrelenmiş olmaktadır. Eşitlik 3.1’de 3x3 boyutunda standart ortalama filtresi, eşitlik 3.2’de 3x3 boyutunda ağırlıklı ortalama filtresi çekirdeği gösterilmiştir.

$$K = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (3.1)$$


$$K = \frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \quad (3.2)$$



Şekil 3.5 a) Gürültülü görüntü, b) standart ortalama filtresi kullanılmış, c) ağırlıklı ortalama filtresi kullanılmış

3.2.1.2 Medyan (ortanca) filtre

Medyan filtre, çekirdeğin merkezindeki pikselin değerini, merkez piksel ve komşu piksellerin değerlerini sıralayıp bulduğu medyan (ortanca) değer ile değiştirmektedir. Filtre her bir piksel üzerinde tek tek gezdirilerek bütün görüntüde uygulanmış olur. Bu filtre özellikle tuz biber gürültüsünde daha etkili sonuç vermektedir. Medyan filtrenin uygulaması Şekil 3.6'da gösterilmiştir.




Şekil 3.6 Bir piksel üzerinde 3x3 boyutunda medyan filtre uygulaması (Çayıroğlu 2018)

3.2.1.3 Gauss bulanıklaştırma filtresi

Gauss bulanıklaştırma filtresi görüntüdeki gürültüleri gidermek ve görüntüyü yumuşatmak adına kullanılan 2 boyutlu bir filtredir. Bu filtre temelde ortalama filtreye benzemektedir fakat filtre çekirdeği “Gauss çanı” şeklinde temsil edilebilen bir çekirdektir. 2 boyutlu Gauss fonksiyonunun denklemi eşitlik 3.3’te verildiği gibidir. Burada (x,y) konumu, σ ise standart sapmayı temsil etmektedir.

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3.3)$$



Şekil 3.7 Ortalaması (0,0) ve standart sapması 1 olan gauss dağılım grafiği (Fisher vd. 2003)

Bu ifadeler göz önüne alındığında örneğin x ve y değerleri için [-2,2] aralığı ve standart sapma $\sigma=1$ seçildiğinde Şekil 3.8’deki çekirdek ortaya çıkacaktır. Çekirdek görüntü üzerine uygulandıktan sonra her pikselin değeri çekirdekteki elemanların değerlerinin toplamına bölünerek normalize edilir.

$$\frac{1}{331} \times$$

-2	1	4	7	4	1
-1	4	20	33	20	4
0	7	33	55	33	7
1	4	20	33	20	4
2	1	4	7	4	1
	-2	-1	0	1	2

X

Şekil 3.8 Gauss bulanıklaştırma filtresi (Çayıroğlu 2018)

Gauss filtresinin etkililiđi standart sapmanın belirlenmesine bađlıdır. Standart sapma yükseldikçe pikseller arası deđer farkı düşmekte fakat görüntü daha bulanık olmaktadır.



Şekil 3.9 Gauss filtresinin etkisi

3.2.1.4 Bilateral filtre

Bilateral filtre görüntülerde gürültüleri gidermek adına doğrusal olmayan bir filtredir. Bu filtrenin özelliđi bir yandan görüntüyü yumuşatırken diđer taraftan görüntüdeki ayrıt özelliklerinin kaybolmasına engel olmasıdır. Uygulanma süresi diđer filtrelere göre daha uzundur.

3.2.2 Histogram eşitleme

Bir görüntüdeki renk deđerlerinin yoğunluk dağılımının grafiksel temsiline histogram adı verilmektedir. Grafiđin x eksenini gri seviye deđerlerini temsil ederken y eksenini ise bu deđerlerin görüntüde hangi sıklıkta bulunduđunu ifade etmektedir. Bu grafik görüntünün parlaklıđı ya da kontrastı hakkında bilgi verir. Gri renk uzayındaki piksellerin yeđinlik deđerleri 0-255 arasında bulunmaktadır. Siyah tonu temsil eden 0 deđerinden beyaz tonu temsil eden 255 deđerine yaklaştıkça renk tonları açılmaktadır. Koyu bir görüntünün histogram deđerleri grafiđin sol tarafında, açık bir görüntünün histogram deđerleri ise grafiđin sađ tarafında yoğunlaşmış şekildedir. Histogram grafiđi kontrast açısından incelendiğinde düşük kontrasta sahip bir görüntünün deđerlerinin yeđinlik ölçeđinin ortalarında dar bir alanda bulunduđu, yüksek kontrastlı görüntünün deđerlerinin ise yeđinlik ölçeđinde geniş bir alanı tuttuđu görülecektir (Gonzalez ve Woods 2014).

L bir görüntüdeki gri seviye sayısı olmak üzere $[0, L-1]$ yeğinlik seviyesi aralığındaki f ile temsil edilmiş görüntünün histogram denklemi eşitlik 3.4'te verilmiştir.

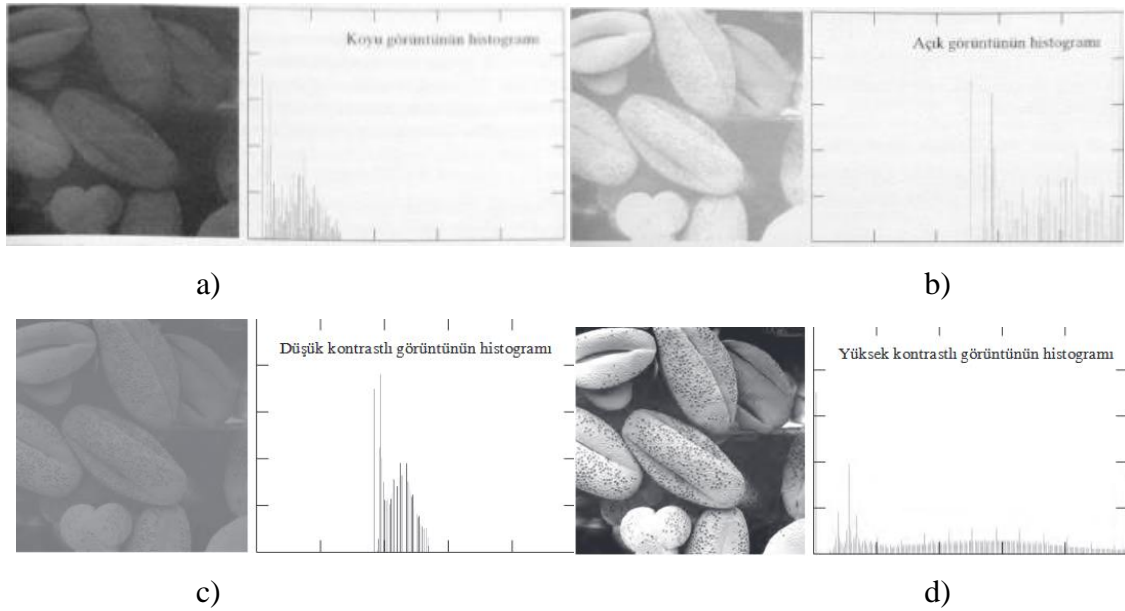
$$p_f(f_k) = \frac{n_k}{N}, \quad k = 0, 1, 2, \dots, L - 1 \quad (3.4)$$

Bu denklemde N : görüntüdeki toplam piksel sayısını,

f_k : k . gri seviye değerini,

n_k : görüntüdeki f_k düzeyli piksel sayısını,

p_f : f_k yeğinlik seviyesinin görüntüde oluşma olasılığını temsil etmektedir. Normalize edilmiş histogram değerlerinin toplamı 1'dir.



Şekil 3.10 a) Koyu, b) parlak, c) düşük kontrast, d) yüksek kontrast görüntülerin histogram grafikleri (Gonzalez ve Woods 2014)

Histogram eşitleme, görüntülerin kontrast seviyesini artırmayı sağlayan bir görüntü işleme tekniğidir. Bazı görüntüler görsel açıdan belirgin olmayan birçok önemli ayrıntı içermekte ve bu görüntüler görsel analiz için yeterli olmamaktadır. Bu ayrıntıların ortaya çıkarılması görüntünün yeğinlik aralığı genişletilmesiyle gerçekleşir. Histogram eşitleme işlemi şu adımları takip edilerek uygulanır (Gonzalez ve Woods 2014; Arısoy ve Dikmen 2014):

1. Öncelikle eşitlik 3.4'teki gibi görüntünün histogramı bulunup normalize edilir.
2. Elde edilmiş histogramdan kümülatif histogram çıkarılır. s_k , k . gri seviyesindeki

kümülatif histogramı temsil etmek üzere,


$$s_k = \sum_{i=0}^k \frac{n_i}{N} = \sum_{i=0}^k p(f_i) \quad (3.5)$$

denklemlerle kümülatif histogram tanımlanır.

3. Kümülatif histogram değerleri normalize edildikten sonra her bir değer görüntüde olması istenen en büyük değer ile çarpılır ve çıkan değer tam sayıya yuvarlatılır. Böylelikle yeni gri seviye değerleri elde edilmiş olur.
4. Görüntünün ilk değerleri ile elde edilmiş değerler eşleştirilir ve histogram eşitleme işlemi sağlanmış olur.

Histogram eşitleme işleminde bütün bir görüntünün yeğinlik dağılımı kullanılmasından ötürü görüntünün küçük bir alanındaki ayrıntıların zenginleştirilmesi ihtiyacı olduğunda beklenen sonucu verememektedir. Böyle bir durum söz konusu olduğunda adaptif histogram eşitleme (AHE) yöntemi tercih edilmelidir. AHE, yerel görüntü verileri üzerinde işlem yapma temelli olan değiştirilmiş bir histogram eşitleme tekniğidir. AHE'nin temel mantığı görüntüyü dikdörtgen şekilli birçok bölgeye birbiriyle çakışmayacak şekilde bölüp her bölge için standart histogram eşitleme işlemini uygulamaktır. Histogram eşitleme işlemi tamamlandıktan sonra bölünmüş bölgeler bilinear interpolasyon yöntemiyle birleştirilerek histogramı eşitlenmiş tam görüntü ortaya çıkarılır. AHE'nin en büyük dezavantajı ise gürültü ile özelliği ayırt edememesidir (Teo 2003). Bu durumu giderebilmek adına homojen bölgelerin kontrast artırımına sınır koyma ihtiyacı doğmuş ve kontrast sınırlı adaptif histogram işleme (CLAHE) geliştirilmiştir.

CLAHE yöntemi, histogramın görüntü üzerindeki amplifikasyonunun sınırlandırılması ve görüntünün lokal homojen bölgelerinde gürültülere neden olan bu histogramın kalan kısmının kırılarak tüm histogram bölgelerine dağıtılmasıyla gerçekleştirilir. Yeniden dağıtım ile birlikte histogram kırma sınırını tekrar aşacaktır. Bu sayede görüntüdeki yerel ayrıntılar görüntünün daha açık ve daha koyu bölgelerinde de geliştirilebilecektir (Koonsanit vd. 2017).




Şekil 3.11 CLAHE ile histogramın kırılması (Koonsanit vd. 2017)

CLAHE tekniğinin gerçekleştirilmesi şu adımlarla uygulanmaktadır. İlk olarak, görüntü AHE'deki gibi eşit büyüklüklerde birbiriyle örtüşmeyen bölgelere bölünmelidir. İkinci adımda her bir bölgenin histogramı hesaplanır ve belirlenen kırpma limitine göre histogram kırılır (Ma vd. 2018). Kırpma limiti ise eşitlik 3.6'da gösterildiği şekilde bulunur:

$$\beta = \frac{M \times N}{L} \left(1 + \frac{\alpha}{100} (s_{max} - 1)\right) \quad (3.6)$$

Burada β kırpma limiti olmak üzere; $M \times N$ her bölgedeki piksel sayısını, L histogram aralık değeri, α kırpma faktörünü (0-100), s_{max} maksimum eğim değerini ifade eder.

Kırpma limiti belirlendikten sonra histogramda kırpma limitinin üzerinde kalan alandaki pikseller tüm histograma eşit olarak dağıtılır. Histogramın kırılmasından sonra kontrastı artırmak için çeşitli dağılım fonksiyonları kullanılır. Varsayılan dağılım şekli uniformdur ve bununla birlikte rayleigh, eksponansiyel ve gauss dağılımları da kullanılabilir. Son olarak ise her bölge içinde histogram eşitlemesi yapılır ve bu bölgeler bilineer interpolasyon ile birleştirilerek CLAHE uygulanmış görüntü oluşturulur (Pujiono vd. 2013; Ertürk 2013). Standart histogram eşitleme, AHE ve CLAHE tekniklerinin görüntü üzerindeki etkileri Şekil 3.12 üzerinde gösterilmiştir.



Şekil 3.12 Retina görüntüsünün HE, AHE ve CLAHE karşılaştırması: a)Giriş görüntüsü, b)HE, c) AHE, d) CLAHE (Qureshi vd. 2019)

3.3 Derin Öğrenme

YSA, biyolojik beyin ve sinir sisteminden ilham alınarak tasarlanmıştır. Bir biyolojik


beynin en önemli ayırt edici özelliği ise öğrenme ve uyum sağlama yetenekleridir, oysa geleneksel bir bilgisayarın bu tür yetenekleri bulunmamaktadır. Buna karşın YSA'da her bir nöron, bağlı olduğu nöronlardan bu sinaptik bağlantılar aracılığıyla bilgi almakta ve bu giriş sinyallerinin ağırlıklı toplamını bir aktivasyon fonksiyonu üzerinden geçirerek çıktı üretmektedir. YSA katman sayısına bağlı olarak tek katmanlı veya çok katmanlı olmak üzere iki kategoriye ayrılmaktadır (Sazlı 2006). Daha sonra katman sayılarının artırılıp derinleştirilmesiyle daha karmaşık derin öğrenme kavramı doğmuştur.

Günümüzde bilişim teknolojilerinin gelişmesine orantılı olarak ses, görüntü, video, yazı vs. verilerin miktarı çok fazla artış göstermiştir. "Big data" olarak adlandırılan bu verileri analiz etmek için kullanılan geleneksel metodlar demode olmaya başlamıştır. Diğer taraftan YSA için engel teşkil eden yetersiz veri problemi sorun olmaktan çıkmaya başlamıştır. CPU ve GPU teknolojilerinin gelişmesiyle beraber de çok fazla katmanı ve nöronu ihtiva eden YSA'lar tasarlanıp eğitilmesi mümkün duruma gelmiştir. Daha derin ve daha geniş tasarlanan bu ağlar için "derin sinir ağları" ve bu ağların eğitim işlemleri de "derin öğrenme" şeklinde isimlendirilmeye başlanmıştır (Elmas 2018).


Makine öğrenmesi, sistemin açık bir şekilde programlanmadan kavramlardan ve bilgilerden otomatik olarak öğrenmesini sağlayan bir YZ alt dalıdır (Dargan vd. 2019). Geleneksel makine öğrenmesi teknikleri ile işlem yapabilmek için verinin öznitelik vektörünün çıkarılması gerekmektedir. Bu öznitelikler o alandaki uzman kişiler vasıtasıyla çıkarılır, bu durum daha fazla işlem yapılmasına ve daha çok zaman harcanmasına sebep olur. Derin öğrenme, makine öğrenmesi üzerinde çalışanların bu sorununu ortadan kaldırmıştır (İnik ve Ülker 2017). Derin öğrenmeyi farklı kılan özellik; ön işleme, öznitelik çıkarımı ve sınıflandırma gibi işlem basamaklarını tek ağda toplamasıdır (Elmas 2018).

Derin öğrenme kavramının literatüre girmesinden itibaren görüntü analizi, video analizi, nesne tanıma, ses işleme, robotik, hastalık teşhisi gibi birçok alanda kullanılmaya başlanmış ve problemlerin çözümünde yüksek doğruluk elde edilmiştir. Hatta bazı alanlarda insan performansının üzerine çıkmıştır. Sık kullanılan derin öğrenme mimarileri ve kullanıldığı alanlar çizelge 3.1'de verilmiştir. Bu tezde görüntü sınıflandırma konusunda başarılı olan KSA tercih edilmiştir.

GELENEKSEL MAKİNE ÖĞRENMESİ



DERİN ÖĞRENME




Şekil 3.13 Makine öğrenmesi ve derin öğrenme yöntemlerini kıyaslanması (Anonymous 2020)

Çizelge 3.1 Derin öğrenme mimarileri ve uygulama alanları (Jones 2017)

Derin Öğrenme Mimarisi	Uygulama Alanı
Konvlüsyonel Sinir Ağları (KSA)	Örüntü tanıma, video analizi, doğal dil işleme
Tekrarlayan Sinir Ağları (RNN)	Konuşma tanıma, elyazısı tanıma
Uzun Kısa Dönemli Bellek (LSTM) / Kapılı Tekrarlayan Birim Ağları (GRU)	Doğal dil metin sıkıştırma, konuşma tanıma, elyazısı tanıma, jest tanıma, görüntü altyazı
Derin İnanç Ağları (DBN)	Örüntü tanıma, bilgi çıkarma, doğal dil işleme, hata tahmini

3.3.1 Derin öğrenme modeli oluşturma yöntemleri

Derin öğrenme modeli oluşturulurken modeli eğitmek için genel olarak iki yaklaşım kullanılır. Bu yaklaşımların prensibi şekil 3.14'te gösterilmiştir.



Şekil 3.14 Derin öğrenme modeli oluşturma yaklaşımları (Mathworks 2020a)

3.3.1.1 Sıfırdan eğitim

Bu yaklaşımda derin öğrenme ağı kullanıcı tarafından baştan tasarlanmakta ve elde edilecek çok büyük miktarda etiketli veriseti ile eğitilmektedir. Ayrıca bu yaklaşımda genellikle yüksek özelliklere sahip bilgisayar donanımlarına ihtiyaç duyulmaktadır. Sıfırdan eğitimde ağın eğitimi haftalar boyunca sürebilmektedir (Janzen 2018, Mathworks 2020b).

3.3.1.2 Transfer öğrenme

Transfer öğrenme bir görev için geliştirilen modelin, diğer bir görevdeki modelin başlangıç noktası olarak yeniden kullanıldığı bir makine öğrenmesi yöntemidir. Model üzerinde ince ayar (finetuning) yapılarak model yeni göreve uygun hale getirilir. Önceden eğitilmiş modeller yeniden farklı problemler için kullanıldığı transfer öğrenme, modeli geliştirmek için gereken zaman, beceri, teknik kaynaklar bakımından kolaylık sağladığı için popüler bir yaklaşımdır (Brownlee 2019). Bundan dolayı bu tez çalışmasında bu yaklaşım tercih edilmiştir.


3.3.2 Konvolüsyonel sinir ağları

KSA ilk olarak (LeCun vd. 1998) tarafından tasarlanmış bir çok katmanlı algılayıcı türüdür (Şeker vd. 2017, Skansi 2018). KSA'nın ortaya atılmasındaki fikir (Hubel ve

Wiesel 1968) tarafından kedilerin görsel korteksi için yapılan araştırmalara dayanmaktadır. Görsel korteks, görme alanındaki belirli bölgelere duyarlı olan küçük hücre bölgelerine sahiptir. Başka bir deyişle, görme alanının belirli alanları uyarılırsa, görsel korteksteeki hücreler de etkinleştirilir. Ayrıca, uyarılan hücreler görsel alandaki nesnelerin şekline ve yönüne de bağlıdır. Örneğin, dikey kenarlar bazı nöronal hücrelerin uyarılmasına neden olurken, yatay kenarlar diğer nöronal hücrelerin uyarılmasına neden olur. Hücreler, katmanlı bir mimari kullanılarak bağlanır ve bu keşif, memelilerin bu farklı katmanları, farklı soyutlama seviyelerinde görüntülerin kısımlarını oluşturmak için kullandıkları düşüncesine yol açmıştır. Makine öğrenmesi açısından, bu ilke hiyerarşik öznitelik çıkarımına benzemektedir (Aggarwal 2018).

Birçok alanda başarılı bir biçimde kullanılan KSA en iyi sınavını görüntü analizi alanında vermektedir.

KSA mimarisi her adımında giriş verisinin öznitelik çıkarma, sınıflandırma gibi farklı işlemlere tabi tutulduğu birçok katmandan oluşur. Bunlar giriş katmanı, konvolüsyon katmanı, düzleştirilmiş doğrusal birim katmanı (ReLU), havuzlama katmanı, tam bağlantılı katman, sınıflandırma katmanı ve dropout katmanıdır.



Şekil 3.15 KSA katmanları (Saha 2018)

3.3.2.1 Giriş katmanı

KSA'nın ilk katmanı olan bu katmanda ham veriler ağa verilerek ağın eğitimi başlatılmaktadır. Giriş verilerinin boyutu ağın başarımlarını doğrudan etkilemektedir. Veri boyutu büyüdükçe başarımlar artabilirken diğer taraftan daha çok bellek ihtiyacı ve daha uzun işlem süresi ihtiyacı doğmaktadır (İnik ve Ülker 2017). Bu parametreler göz önünde bulundurularak optimum boyut tercih edilmelidir.

3.3.2.2 Konvolüsyon katmanı

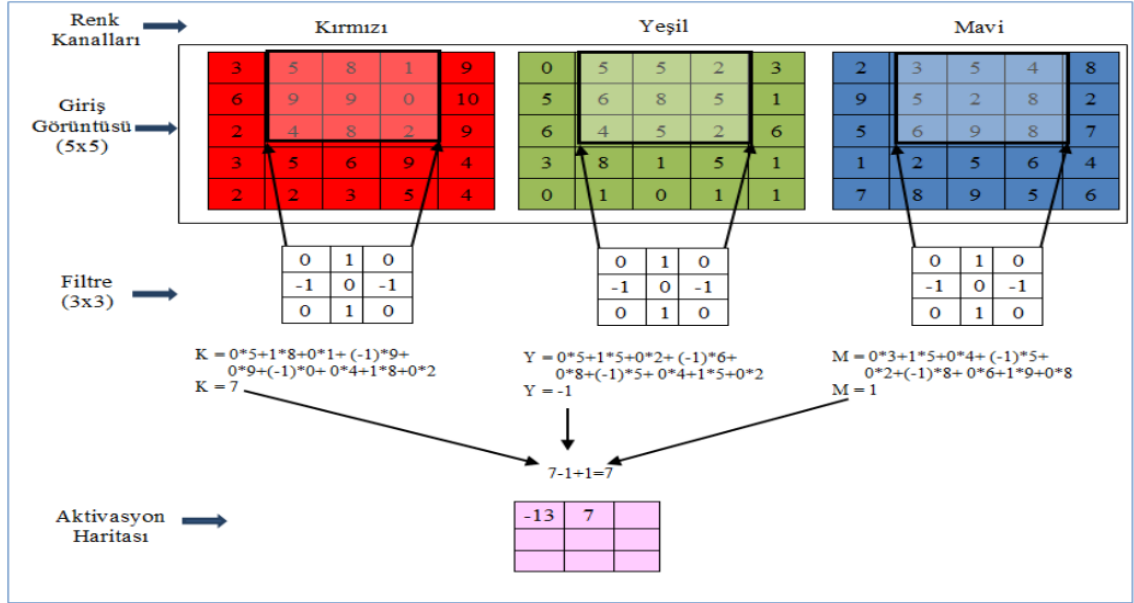
Konvolüsyon katmanı girdi görüntüsünün özellik haritasının çıkarıldığı, KSA mimarisinin temeli olan katmandır. Konvolüsyon, tensör adı verilen bir sayı dizisi olan girişe, çekirdek adı verilen küçük bir sayı dizisinin uygulandığı özellik çıkarma için kullanılan özel bir doğrusal işlem türüdür. Çekirdeğin her bir elemanı, giriş tensörünün elemanları üzerinde sağdan sola ve yukarıdan aşağı kaydırılarak her bir elemanla çarpılıp toplanır. Bu işlem, giriş tensörlerinin farklı özelliklerini çıkarmak için çok sayıda farklı çekirdekler ile uygulanarak tekrarlanır; farklı çekirdekler, bu nedenle, farklı özellik çıkarıcılar olarak düşünülebilir. Konvolüsyon işlemini tanımlayan iki temel hiperparametre, boyut ve çekirdek sayısıdır. Çekirdek boyutu 2x2, 3x3, 5x5 vs gibi olabilir. Çekirdek sayısı ise isteğe bağlıdır ve çıktı özelliği haritalarının derinliğini belirler (Yamashita vd. 2018). İlk konvolüsyon katmanları kenarlar, çizgiler ve köşeler gibi düşük seviyeli özellikleri, üst düzey konvolüsyon katmanları ise daha üst düzey özellikleri çıkarmaktadır. Konvolüsyon işleminin matematiksel gösterimi I iki boyutlu görüntü, K iki boyutlu çekirdek olmak üzere eşitlik 3.6'da verilmiştir (Goodfellow vd. 2016).

$$S(i,j)=(I*K)(i,j)=\sum_m\sum_n I(i+m,j+n)K(m,n) \quad (3.6)$$

Girdi görüntüsünün boyutu $N \times N \times D$ 'dir. N değerleri sırasıyla görüntünün yüksekliğini ve genişliğini, D ise kanal sayısını ifade etmektedir. Renkli görüntüler (RGB), "red", "green", "blue" olmak üzere üç kanal barındırdığından kanal sayısı 3'tür. Bu görüntü ile $k \times k \times D$ boyutunda bir filtre konvole edildiğinde elde edilecek özellik haritasının boyutu $(N-k+1) \times (N-k+1)$ olacaktır. $5 \times 5 \times 3$ boyutundaki RGB görüntüsü ile 3×3 boyutundaki çekirdeğin konvolüsyon işlemi Şekil 3.16'da gösterilmiştir. Çıkacak özellik haritasının boyutu $(5-3+1) \times (5-3+1) = 3 \times 3$ olacaktır (Hijazi vd. 2015). RGB görüntü ile konvolüsyon işlemi şekil 3.16 ile gösterilmiştir.


Konvolüsyon işlemi sonucu $(q+1)$ katmanındaki verinin boyutu q katmanına göre azalır. Bu özellik haritasının sınırlarındaki özelliklerin kaybedilmesi anlamına gelmektedir ve arzu edilmeyen bir durumdur. Boyut kaybını engellemek için görüntünün kenarlarına piksel eklenerek dolgu (padding) işlemi yapılmalıdır. Bu piksellerin değeri "0" olarak ayarlanacağı için hem boyut kaybı engellenmiş hem de özellik haritası değişikliğe uğramamış olacaktır. Aynı şekilde konvolüsyon işlemi sırasında çekirdeğin adım sayısı (stride) büyütüldüğünde de boyut kaybı olacağından dolgu işlemi yapılmalıdır (Aggarwal

2018).



Şekil 3.16 RGB görüntü ile konvolüsyon işlemi (İnik ve Ülker, 2017)

Piksel dolgulama işlemi şekil 3.17’de verilmiştir.






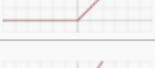
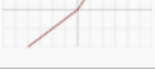




Şekil 3.17 Dolgulama işlemi (Aggarwal 2018)

3.3.2.3 Düzleştirilmiş doğrusal birim katmanı (ReLU)

Konvolüsyon katmanında sonra gelen bu katmanda konvolüsyon katmanından gelen verilerdeki negatif değerler sıfıra eşitlenmektedir. Bu katmanda aktivasyon fonksiyonları kullanıldığından aktivasyon katmanı olarak da adlandırılmaktadır. Aktivasyon

fonksiyonu, ağırlıklı toplam hesaplanarak ve daha sonra bias eklenerek bir nöronun aktive edilip edilmemesine karar verir. Aktivasyon fonksiyonunun amacı, bir nöronun çıkışına nonlineerlik kazandırmaktır (Tiwari 2019). Birçok aktivasyon fonksiyonu olsa da ReLU işlem yapma hızını artırdığı için en popüler fonksiyondur (Sharma 2017). Aktivasyon fonksiyonlarının denklemleri ve türevleri Şekil 3.18’de verilmiştir. ReLU fonksiyonunun özellik haritasına etkisi Şekil 3.19’da gösterilmiştir.

Aktivasyon fonksiyonu	Grafik	Denklem	Türev
Identity		$f(x) = x$	$f'(x) = 1$
Binary step		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{for } x \neq 0 \\ ? & \text{for } x = 0 \end{cases}$
Logistic (a.k.a Soft step)		$f(x) = \frac{1}{1 + e^{-x}}$	$f'(x) = f(x)(1 - f(x))$
Tanh		$f(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1$	$f'(x) = 1 - f(x)^2$
ArcTan		$f(x) = \tan^{-1}(x)$	$f'(x) = \frac{1}{x^2 + 1}$
Rectified Linear Unit (ReLU)		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
Parameteric Rectified Linear Unit (PReLU) ^[2]		$f(x) = \begin{cases} \alpha x & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} \alpha & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
Exponential Linear Unit (ELU) ^[3]		$f(x) = \begin{cases} \alpha(e^x - 1) & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} f(x) + \alpha & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
SoftPlus		$f(x) = \log_e(1 + e^x)$	$f'(x) = \frac{1}{1 + e^{-x}}$

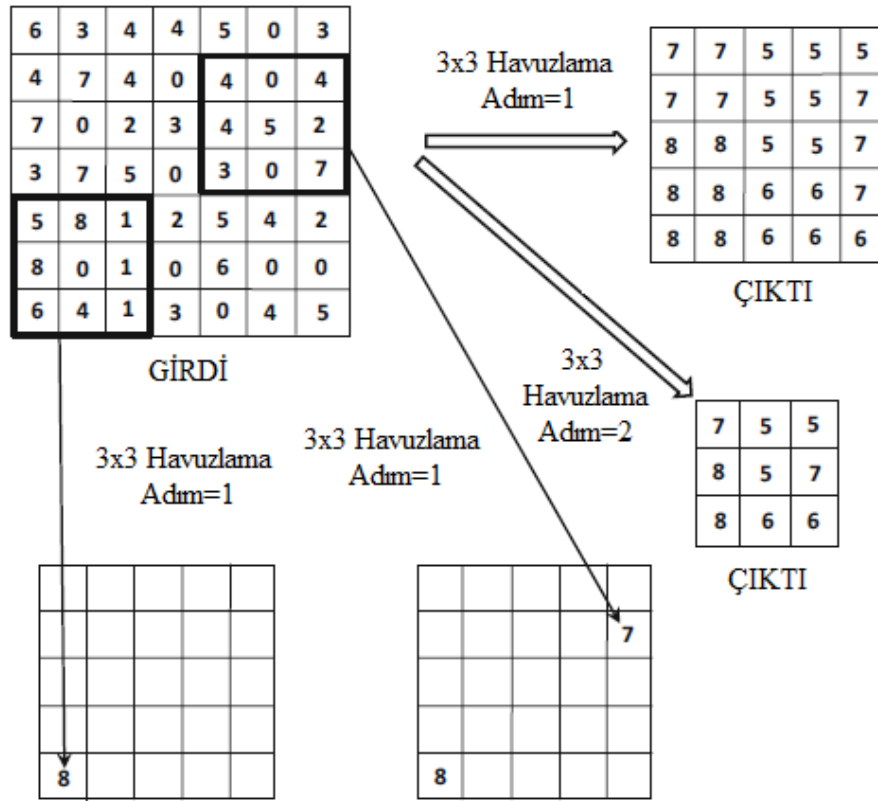
Şekil 3.18 Aktivasyon fonksiyonları ve türevleri (Sharma 2017)



Şekil 3.19 ReLU fonksiyonunun özellik haritasına etkisi (Ergin 2018)

3.3.2.4 Havuzlama (pooling) katmanı


Havuzlama katmanında verinin boyutu (genişlik ve yükseklik) bir sonraki katman için azaltılmaktadır. Bu işlem bazı bilgilerin kaybolmasına ve performansın düşmesine neden olsa da hesaplama kolaylığı sağlaması ve modelin aşırı ezberlemesini önlemesi açısından avantajlar sunmaktadır. Havuzlama filtreleri belirli adımlarla görüntü üzerinde gezdirilerek bazı değerleri seçmektedir. Bu seçim, tercihe göre filtre sınırları içindeki maksimum, ortalama veya minimum değerler üzerinden olur (Türkoğlu vd. 2020). Bir adım ve iki adım ile yapılmış maksimum havuzlama şekil 3.20’de gösterilmiştir.



Şekil 3.20 Bir adım ve iki adım ile maksimum havuzlama (Aggarwal 2018)

3.3.2.5 Tam bağlantılı (fully connected) katman


KSA'nın öznelik çıkarımı yapan katmanlarından gelen çıktı matrisleri tek boyutlu vektöre dönüştürülerek bu katmana bağlanır. Bu adımda, düzleştirilmiş özellik haritası bir sinir ağı üzerinden geçirilir. Bu adım giriş katmanı, tam bağlı katman ve çıkış katmanından oluşur. Tam bağlantılı katman, YSA'lardaki gizli katmana benzemektedir. Çıktı katmanı, tahmin edilen sınıfların alındığı yerdir (Chauhan 2020).



Şekil 3.21 Tam bağlantılı katman

3.3.2.6 Dropout katmanı

Aşırı öğrenme (overfitting), bir modelin eğitim setine özgü istatistiksel düzenleri ezberlemesi, dolayısıyla sonraki yeni veri kümesinde daha kötü performans göstermesi durumudur. Aşırı öğrenmiş bir model daha önce hiç görülmemiş veriler için genelleme yapamadığından bu durum makine öğrenmesindeki temel zorluklardan biridir (Yamashita 2018). Aşırı öğrenmeyi engellemek için bu katmanda ağ içinde ezber yapan bazı nöronlar belirlenen oranda rastgele deaktif edilir. Böylelikle ağa genelleme yeteneği kazandırılarak performansı artırılır.



Şekil 3.22 Ağa dropout uygulanması

3.3.2.7 Sınıflandırma katmanı

KSA'nın sınıf tayini yaptığı son katmandır. Verinin sınıflandırıldığı bu katmanda aktivasyon fonksiyonları ile sınıf sayısı kadar çıkış değeri üretilir. Çıkış değerleri 0-1 aralığındaki olasılıksal değerlerdir. En yüksek olasılık değerine sahip sınıf modelin tahmin ettiği sınıf olarak değerlendirilir (Türkoğlu vd. 2020).

3.3.2.8 Optimizasyon teknikleri

Derin öğrenmede amaç, modelin tahmin ettiği çıktı ile gerçek çıktı arasındaki farkı yani kayıp fonksiyonunu azaltmaktır. Optimizasyon teknikleri bu farkı, ağırlıkların optimum değerini yakalayarak azaltan tekniklerdir. Gradient descent (gradyan inişi) yöntemi kayıp fonksiyonunu azaltmak için en sık kullanılan optimizasyon tekniğidir. Toplu (batch) gradyan inişi, stokastik gradyan inişi ve mini-batch gradyan inişi olmak üzere üç tiptir.

Toplu gradyan inişinde her iterasyonda kayıp fonksiyonunun gradyanını hesaplamak ve ardından ağırlıkları güncellemek için tüm veri seti kullanılmaktadır. Tüm veri seti kullanıldığı için işlem süresi uzundur. Stokastik gradyan inişinde, gradyanı hesaplamak ve her yinelemede ağırlıkları güncellemek için tek bir örnek kullanılmaktadır. Bu şekilde rastgele bir örnek kullanmak, global minimuma ulaşmaya yardımcı olur ve lokal minimumda takılıp kalmayı önler. Mini-batch gradyan inişi ise tekli eğitim örneği yerine verilerin bir kısmının kullanıldığı stokastik gradyan inişinin bir varyasyonudur (Khandelwal 2018).

Gradyan inişi yöntemi temelli bazı optimizasyon teknikleri şunlardır: Momentum (SGDM), Nesterov hızlandırılmış gradyan (NAG), Adagrad, Adadelat, RMSprop, Adam, AdaMax ve Nadam.


3.3.3 KSA mimarileri

İlk KSA mimarisi, el yazısı sayıları sınıflandırmak üzere daha önce Yann LeCun tarafından tasarlanan LeNet olsa da derin öğrenme mimarileri 2012 yılındaki ImageNet yarışması ile popüler hale gelmiştir. Devam eden yıllarda farklı mimariler tasarlanmaya başlanmıştır.

Bu KSA mimarileri örüntü tanıma, sınıflandırma ve nesne tespiti başta olmak üzere birçok alanda başarılı sonuçlar ortaya koymaktadır (Doğan ve Türkoğlu 2019). Yaygın kullanılan bazı KSA mimarileri (AlexNet, VGGNet ve ResNet) ve bu tezde kullanılan EfficientNet mimarisi aşağıda açıklanmıştır.

3.3.3.1 AlexNet


AlexNet (Krizhevsky vd. 2012), 2012 yılında ImageNet yarışmasını kazanarak KSA ve derin öğrenme çalışmalarına yaygınlık kazandırmıştır. 5 konvolüsyon, 3 maxpooling, 2 dropout, 3 tam bağlı katman, 7 relu, 2 normalizasyon katmanına sahip toplam 25 katmandan oluşan AlexNet görüntüleri 1000 sınıftan birine sınıflandırmak üzere tasarlanmıştır. Eğitim süresini azaltmak için tanh fonksiyonu yerine ReLU tercih edilmiştir. Giriş görüntüsü boyutu 227x227x3 olan model iki paralel ağ şeklinde çalışmaktadır. Filtre boyutu 11x11 ve adım sayısı 4'tür. (Elmas 2018, Doğan ve Türkoğlu 2019).



Şekil 3.23 AlexNet mimarisi (Krizhevsky vd. 2012)

3.3.3.2 VGGNet

(Simonyan ve Zisserman 2015) tarafından geliştirilen VGGNet, 2014 ImageNet yarışmasında %7,3 hata değeri elde etmiştir. VGGNet, katman sayısına göre 6 çeşit olarak tasarlanmıştır. Bu mimarinin diğer mimarilerden farkı konvolüsyon işlemi için 2x2'lik veya 3x3'lük filtre kullanmasıdır. Giriş boyutu 224x224x3'tür ve 3 tam bağlantılı katmana sahiptir. VGGNet çeşitlerinden VGG16 ve VGG19 literatürde sıkça kullanılmaktadır (Doğan ve Türkoğlu 2019). VGGNet mimarisi şekil 3.24 üzerinde ve VGGNet modellerinin çeşitleri şekil 3.25 üzerinde gösterilmiştir.




Şekil 3.24 VGGNet mimarisi (Bezdan ve Bacanin 2019)

A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64	conv3-64	conv3-64	conv3-64	conv3-64
	LRN	conv3-64	conv3-64	conv3-64	conv3-64
maxpool					
conv3-128	conv3-128	conv3-128	conv3-128	conv3-128	conv3-128
		conv3-128	conv3-128	conv3-128	conv3-128
maxpool					
conv3-256	conv3-256	conv3-256	conv3-256	conv3-256	conv3-256
conv3-256	conv3-256	conv3-256	conv3-256	conv3-256	conv3-256
			conv1-256	conv3-256	conv1-256
					conv1-256
maxpool					
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
			conv1-512	conv3-512	conv3-512
					conv3-512
maxpool					
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
			conv1-512	conv3-512	conv3-512
					conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					


Şekil 3.25 VGGNet modelleri (Doğan ve Türkoğlu 2019)

3.3.3.3 ResNet

Residual Network, kısaca ResNet, %3.6 hata oranıyla 2015 ImageNet yarışmasının kazananı olan 152 katmanlı bir KSA'dır. ResNet bu özelliği ile insan performansının üzerine çıkan ilk mimari olmuştur. Doğrusal ve ReLU katmanları arasında kalıntı değerlerinin (residual value) sonraki katmanlara besleyen blokların (residual blocks) eklenmesiyle daha hızlı bir model oluşturulacağı düşünülmüş ve klasik modellerden ayrılmıştır. Her kalıntı bloğunda iki adet 3x3 konvolüsyon filtresi bulunur, adım sayısı 2 seçilmiştir. Model derinleştikçe optimize edilmesi daha zor olmaktadır, ResNet için çözüm, aktivasyonu bir katmandan alıp başka bir katmanı beslemeye izin veren atlama bağlantısını kullanmaktır. Bunu kullanmak çok derin ağların eğitilmesini ve vanishing gradient sorununun ortadan kalkmasını sağlamaktadır. Parametre sayısını azaltmak için, 1000 sınıfın çıktısını almak için olan katman hariç ResNet'lerde tam bağlantılı katman kullanılmamıştır (Bezdan ve Bacanin 2019).



Şekil 3.26 ResNet artık blok (More 2020)



Şekil 3.27 ResNet mimarisi (More 2020)

3.3.3.4 EfficientNet

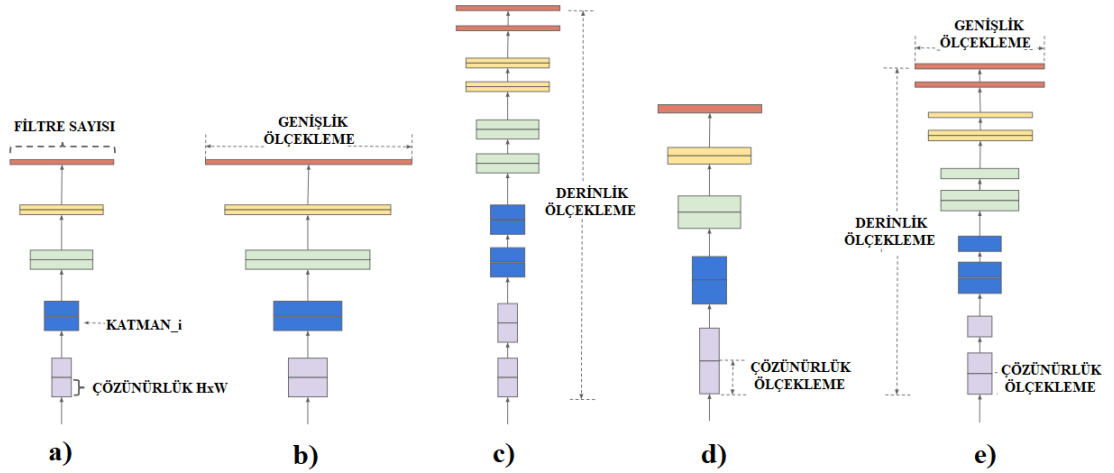
EfficientNet modeli, Google araştırma ekibinden Tan ve Le (2019) tarafından ortaya atılmıştır. Bu araştırmacılar, KSA model ölçeklendirilmesini incelemiş ve ağı

derinliğinin, genişliğinin ve çözünürlüğünün ölçeklendirilmesinde dengelemenin, ağ performansını etkilediğini belirlemiştir. Bu gözlem temelinde, ağın derinlik, genişlik ve çözünürlüğünün tüm boyutlarını eşit olarak ölçekleyen yeni bir ölçeklendirme yöntemi önermişlerdir (Kumar 2020). EfficientNet, B0'dan B7'ye kadar 8 tane modelden oluşmaktadır. Model büyüdükçe kullanılan parametre sayısı ve başarımları artmaktadır. Çalışmaya göre öncelikle temel model olan EfficientNet-B0 oluşturulur. Daha sonra doğruluğu ve model boyutunu artırmak için temel model, bileşik ölçeklendirme ile EfficientNet-B1'den, EfficientNet-B7'ye kadar büyütülebilir. Her artışta işlem gücü, yaklaşık iki katına çıkmaktadır (Kızrak 2019).

Önceki ölçekleme çalışmalarında, derinlik, genişlik ve çözünürlük parametrelerinden genellikle yalnızca biri ölçeklenmektedir. Ağın derinliği, bir ağdaki katman sayısına karşılık gelir. Genişlik, bir konvolüsyonel katmandaki filtrelerin sayısı ile ilişkilidir. Çözünürlük ise, giriş görüntüsünün yüksekliği ve genişliğidir. İki veya üç parametreyi keyfi olarak ölçeklemek mümkün olsa da, keyfi ölçekleme zahmetli manuel ayar gerektirmektedir ve buna rağmen çoğu zaman istenilen verimlilik ve doğruluk elde edilemez. Önerilen EfficientNet modeli yalnızca daha yüksek doğruluk sağlamakla kalmamakta, aynı zamanda son teknoloji modellere kıyasla parametreleri azaltarak modellerin verimliliğini de artırmaktadır (Tan ve Le 2019, Shahid 2020).


EfficientNet modeliyle faktörleri rastgele ölçekleyen geleneksel uygulamanın aksine, ağ genişliğinin, derinliğinin ve çözünürlüğünün bileşik ölçeklendirme (compound scaling) ile bir dizi sabit ölçekleme katsayısı ile eşit şekilde ölçeklendirilmesi önerilmiştir. Örneğin, 2^N kat daha fazla hesaplama kaynağı kullanmak istenildiğinde; o zaman ağ derinliği α^N , genişliği β^N ve görüntü boyutu γ^N artırılabilir, burada α , β , γ model üzerinde grid arama yöntemiyle belirlenen sabit katsayılardır (Tan ve Le 2019). EfficientNet modelinde önerilen bileşik ölçeklendirme yöntemi şekil 3.28'de verilmiştir.

Daha çok konvolüsyonel katman ekleyerek derinliği artırmak, ağın daha karmaşık özellikleri öğrenmesine olanak tanımaktadır. Ancak daha derin ağlar, yok olan gradyanlardan muzdariptir ve ağın eğitimi zorlaşmaktadır. Toplu normalizasyon ve atlama bağlantıları gibi yeni teknikler bu sorunu çözmede etkili olsa da deneysel çalışmalar, yalnızca ağın derinliğini artırmanın doğruluk artış oranını hızlıca doyurduğunu göstermektedir.



Şekil 3.28 a) Temel ağ örneği, b)-d) ağ genişliğinin, derinliğinin veya çözünürlüğünün yalnızca bir boyutunu artıran geleneksel ölçeklendirmeler, e) EfficientNet'in bileşik ölçekleme yöntemi (Kızrak 2019)

Ağların genişliğini ölçeklendirmek, katmanların daha ayrıntılı özellikleri öğrenmesine olanak tanır. Ancak, derinliğin artması durumunda olduğu gibi, genişliğin artırılması, ağın karmaşık özellikleri öğrenmesini engelleyerek doğruluk artışının azalmasına neden olur. Çözünürlüğü arttırmak, görüntü hakkında daha fazla ayrıntı sağlar ve dolayısıyla modelin daha küçük objeler hakkında çıkarım yapma becerisini geliştirir. Ancak diğer ölçeklendirme boyutları gibi, bu da kendi başına sınırlı doğruluk artışı sağlamaktadır (Shahid 2020). Daha büyük genişliğe, derinliğe veya çözünürlüğe sahip büyük ağlar, daha yüksek doğruluk elde etme eğiliminde olsa da doğruluk kazancı, şekil 3.29'da görüldüğü gibi % 80'lere ulaştıktan sonra hızla doyuma ulaşmaktadır.



Şekil 3.29 a) Genişlik (w), b) derinlik (d), c) çözünürlük (r) ölçekleme ve doğruluk ilişkisi (Kızrak 2019)

Bir KSA'nın i . katmanı şöyle tanımlanabilir: $Y_i = F_i(X_i)$. Burada F_i operatör, Y_i çıkış tensörü, X_i ise $\langle H_i, W_i, C_i \rangle$ boyutlu giriş tensörüdür. Buradan KSA şu şekilde ifade edilebilir:

$$\mathcal{N} = \odot_{i=1 \dots S} F_i^{L_i}(X \langle H_i, W_i, C_i \rangle) \quad (3.7)$$

Burada \mathcal{N} , KSA'yı ifade etmektedir. \odot operatörü, X girdisinin konvole edildiği filtrelerin bir listesini (L_1, L_2, \dots, L_S) belirtmek için kullanılır. i aşama numarasını göstermekte, F_i i . aşama için konvolüsyon işlemini ve L_i , i . aşamada F_i 'nin tekrarlanma sayısını temsil etmektedir. H_i , W_i ve C_i tensör boyutudur. L_i ağın derinliğini kontrol eder, C_i ise ağın genişliğinden sorumludur, H_i ve W_i ise giriş çözünürlüğünü etkilemektedir. Her katman için bu boyutları ölçeklendirecek bir dizi iyi katsayı bulmak, arama alanı çok büyük olduğundan imkansızdır. Arama alanını azaltmak amacıyla, tüm katmanların aynı şekilde ölçeklendirilmesi için sınırlamalar koyulmuştur. Arama model doğruluğunu maksimize etmek için bir optimizasyon problemi olarak formüle edilir (Espinoza 2019, Shadid 2020):

$$\begin{aligned} & \max_{d, w, r} \text{Accuracy}(\mathcal{N}(d, w, r)) \\ & \text{s.t. } \mathcal{N} = \odot_{i=1 \dots S} \hat{F}_i^{d - \hat{L}_i}(X \langle r - \hat{H}_i, r - \hat{W}_i, r - \hat{C}_i \rangle) \\ & \text{Memory}(\mathcal{N}) \leq \text{target_memory} \\ & \text{FLOPS}(\mathcal{N}) \leq \text{target_memory} \end{aligned} \quad (3.8)$$

d , w ve r ağ derinliğini, genişliğini, ve çözünürlüğünü ölçeklendirmek için kullanılan katsayılardır; \hat{F}_i , \hat{L}_i , \hat{H}_i , \hat{W}_i , \hat{C}_i temel ağda önceden tanımlanmış parametrelerdir.

Ağ genişliğini, derinliğini ve çözünürlüğünü eşit şekilde ölçeklendirmek için bileşik ölçeklendirme katsayısı φ kullanılan basit, ancak etkili bir ölçeklendirme tekniği önerilmektedir.

$$\text{derinlik: } d = \alpha^\varphi$$

$$\text{genişlik: } w = \beta^\varphi$$

$$\text{çözünürlük: } r = \gamma^\varphi$$

$$\text{s.t. } \alpha \cdot \beta^2 \cdot \gamma^2 \approx 2$$


$$\alpha \geq 1, \beta \geq 1, \gamma \geq 1 \quad (3.9)$$

$\alpha \cdot \beta^2 \cdot \gamma^2 \approx 2$ kısıtlaması, herhangi bir yeni ϕ için toplam FLOPS'un (saniyede yapılan kayan noktalı işlem sayısı) yaklaşık 2ϕ artacağından emin olmak için eklenir. Uygun katsayıları bulmak için aşağıdaki iki aşamalı prosedür uygulanır:

1. İlk olarak $\phi = 1$ 'e ayarlanır ve Denklem (3.8) ve (3.9)'a göre α , β , γ için grid araması yapılır. EfficientNet-B0 için en iyi değerlerin $\alpha = 1,2$, $\beta = 1,1$, $\gamma = 1,15$ olduğu tespit edilmiştir.
2. α , β , γ ayarlanır. ϕ , 2 ~ 7 arasında seçilerek, EfficientNet-B1'de B7'ye doğru farklı modeller ϕ 'ye göre elde edilmiş olur.

ϕ , kaç tane kaynağın mevcut olduğunu kontrol eden kullanıcı tanımlı, global bir ölçekleme faktörüdür, α , β ve γ ise sırasıyla bu kaynakların ağ derinliğine, genişliğine ve çözünürlüğe nasıl atanacağını belirleyen katsayılardır (Tan ve Le 2019).

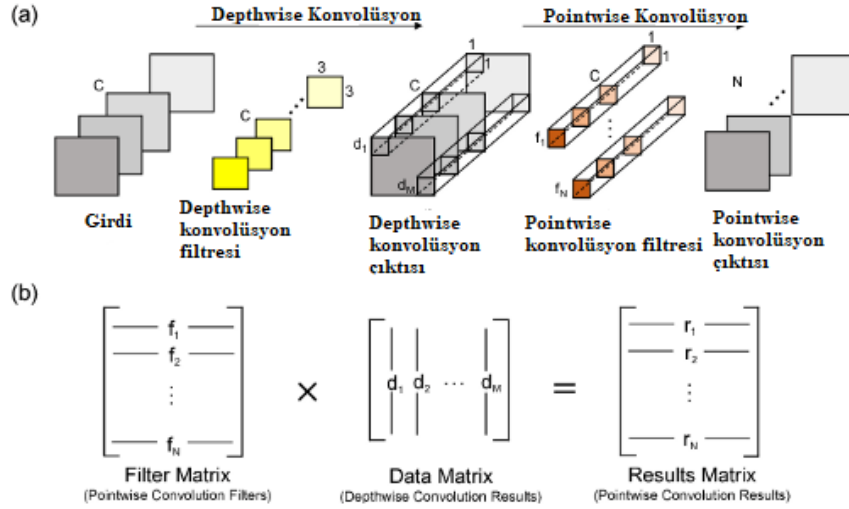
Şekil 3.30'da farklı ölçeklendirme yöntemlerine sahip birkaç temsili model için sınıf aktivasyon haritaları karşılaştırılmıştır. Bileşik ölçeklendirmeli model, daha fazla nesne detayı ile daha ilgili bölgelere odaklanma eğilimindeyken, diğer modeller nesne ayrıntılarından daha yoksun durumdadır (Tan ve Le 2019).



Şekil 3.30 Bileşik ölçeklendirme ve diğer yöntemlerin karşılaştırılması (Zhou vd. 2016)

EfficientNet modelinin ana yapı taşı, sıkıştırma ve uyarma optimizasyonunun eklendiği MBConv'dan (mobil ters çevrilmiş darboğaz evrişimi) oluşur. MBConv, MobileNet v2'de kullanılan ters çevrilmiş artık bloklara benzer. Bunlar, konvüsyonel katmanın başlangıcı ve sonu arasında bir kısayol bağlantısı oluşturur. Giriş aktivasyon haritaları, özellik haritalarının derinliğini artırmak için önce 1×1 evrişimler kullanılarak genişletilir.

Bunu, çıktı özelliği haritasındaki kanal sayısını azaltan 3x3 depthwise konvolüsyon ve pointwise konvolüsyon izler. Kısayol bağlantıları dar katmanları birbirine bağlarken, daha geniş katmanlar atlama bağlantıları arasında bulunur. Bu yapı, model boyutunun yanı sıra işlem sayısının azaltılmasına yardımcı olur (Shadid 2020). Konvolüsyon işlemi en az doğruluk kaybıyla hesaplama maliyetini en aza indirmek için depthwise konvolüsyon ve pointwise konvolüsyon (şekil 3.31) olarak 2'ye bölünmüştür (Kızrak 2019). EfficientNet-B0 temel ağ yapısı şekil 3.32'de gösterilmiştir.




Şekil 3.31 Depthwise ve pointwise konvolüsyon (Kızrak 2019)

Stage i	Operator $\hat{\mathcal{F}}_i$	Resolution $\hat{H}_i \times \hat{W}_i$	#Channels \hat{C}_i	#Layers \hat{L}_i
1	Conv3x3	224×224	32	1
2	MBCConv1, k3x3	112×112	16	1
3	MBCConv6, k3x3	112×112	24	2
4	MBCConv6, k5x5	56×56	40	2
5	MBCConv6, k3x3	28×28	80	3
6	MBCConv6, k5x5	28×28	112	3
7	MBCConv6, k5x5	14×14	192	4
8	MBCConv6, k3x3	7×7	320	1
9	Conv1x1 & Pooling & FC	7×7	1280	1

Şekil 3.32 EfficientNet-B0 temel ağ yapısı (Kızrak 2019)

EfficientNet modelleri ImageNet'teki diğer mevcut KSA'larla karşılaştırıldığında genel olarak mevcut KSA'lara göre hem daha yüksek doğruluk hem de parametre boyutunu ve FLOPS'u azaltarak daha iyi verimlilik elde etmiştir. Özellikle, EfficientNet-B7, mevcut en iyi KSA modeline göre 8,4 kat daha küçük ve 6,1 kat daha hızlı olurken, ImageNet

yarışmasında 66M parametre ile %84,4 doğruluk elde etmiştir. Benzer şekilde EfficientNet-B4, yaygın olarak kullanılan ResNet-50 modeliyle karşılaştırıldığında hemen hemen aynı sayıda parametre kullanarak ResNet-50'nin %76,3 doğruluk oranına karşılık EfficientNet-B4 %82,6 doğruluk oranı elde etmiştir (Tan ve Le 2019). EfficientNet modellerinin diğer modellere göre parametre sayısı / doğruluk oranı kıyaslaması şekil 3.33'te gösterilmiştir.



Şekil 3.33 EfficientNet modellerinin diğer modellerle karşılaştırılması (Tan ve Le 2019)

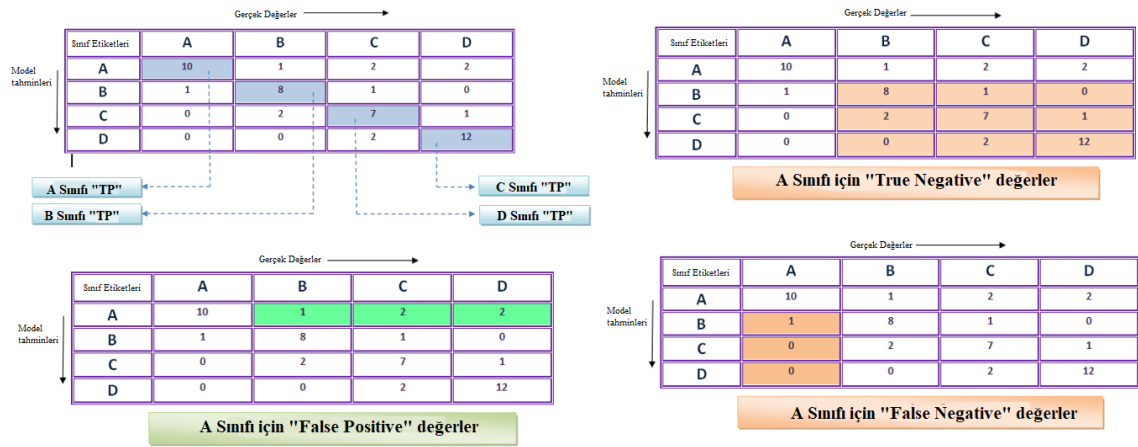
3.4 Başarım Ölçütleri

KSA modeli uygulanıp sınıf biçiminde çıktılar aldıktan sonra, test veri kümelerini kullanarak bazı ölçütlere dayalı bir şekilde modelin ne kadar etkili olduğu değerlendirilmektedir. DR'yi 5 sınıfa sınıflandıracak KSA modelinin performansı yorumlanırken karışıklık matrisi, cohen kappa skoru, doğruluk, kesinlik, duyarlılık ve F1 skoru gibi metrikler kullanılmıştır.

3.4.1 Karışıklık matrisi

Karışıklık matrisi (confusion matrix), sınıflandırma modelinin performansını tanımlayan bir tablodur. Sınıflandırıcı tarafından yapılan gerçek değerler ve tahmin sınıflandırmaları hakkında bilgi içerir ve bu bilgi sınıflandırıcının performansını değerlendirmek için kullanılmaktadır. Karışıklık matrisi, nesnenin gerçek sınıfını indekslediği ekseni ve sınıflandırıcının tahmin ettiği sınıfı indekslediği başka bir ekseni olmak üzere iki eksenli bir yapıdadır (Deng vd. 2016). Dört sınıflı bir sınıflandırma için karışıklık matrisi şekil 3.34 ile gösterilmiştir. Karışıklık matrisinden diğer performans metriklerinin çıkarılması için şu terimler kullanılmaktadır:

- True Positives (TP): Verinin gerçek sınıfı pozitifdir ve model "pozitif" olarak tahmin etmiştir. Tahmin edilen sınıf etiketi doğrudur, dolayısıyla "Gerçek Pozitif"tir.
- True Negatives (TN): Verinin gerçek sınıfı negatiftir ve model "negatif" olarak tahmin etmiştir. Tahmin edilen sınıf etiketi doğrudur, dolayısıyla "Gerçek Negatif"tir.
- False Positives (FP): Verinin gerçek sınıfı negatiftir, ancak model "pozitif" olarak tahmin etmiştir. Tahmin edilen sınıf etiketi yanlıştır, dolayısıyla "Yanlış Pozitif"tir.
- False Negatives (FN): Verinin gerçek sınıfı pozitifdir, ancak model "negatif" olarak tahmin etmiştir. Tahmin edilen sınıf etiketi yanlıştır, dolayısıyla "Yanlış Negatif"tir.



Doğruluk (accuracy), sınıflandırma modellerini değerlendirmek için bir ölçü birimidir. Toplam doğru tahmin sayısının toplam veri noktası sayısına bölünmesiyle hesaplanabilir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.10)$$

Duyarlılık (recall/sensitivity), doğru tahmin edilmiş pozitif verilerin toplam sayısının, toplam pozitif veri sayısına bölünmesi olarak tanımlanabilir. Yüksek duyarlılık, sınıfın doğru şekilde tanındığını göstermektedir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3.11)$$

Kesinlik (precision), doğru sınıflandırılmış pozitif verilerin toplam sayısını tahmin edilen toplam pozitif veri sayısına bölünmesiyle bulunur. Kesinlik, pozitif olarak etiketlenen verilerin ne kadarının gerçekten pozitif olduğunu gösterir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3.12)$$

F1 skoru, kesinlik ve duyarlılığın her ikisini de temsil eden bir ölçüme sahip olmak için yardımcı olan metriktir. Hem yanlış pozitifler hem de yanlış negatifler hesaba katılır. Özellikle dengesiz sınıf dağılımı için F1 skoru genellikle doğruluktan daha kullanışlıdır.

$$\text{F1 skoru} = \frac{2 \times \text{kesinlik} \times \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}} \quad (3.13)$$

3.4.2 Cohen kappa skoru

Cohen kappa skoru κ , kategorik değişkenler arasındaki uyumun bir ölçüsüdür. κ , uyumun tesadüfen oluşma olasılığını hesaba kattığı için, genellikle diğer doğrulama yöntemlerinden daha sağlam bir ölçü olduğu düşünülmektedir (Cohen 1960). Cohen kappa skoru, hem çok sınıflı hem de dengesiz sınıf problemlerini çok iyi idare edebilen bir performans metriğidir. Cohen kappa skoru κ denklem 3.14'te ifade edildiği gibi bulunabilir.

$$\kappa = \frac{P_o - P_e}{1 - P_e} \quad (3.14)$$

Burada P_o olasılığı puanlayıcılar arasındaki uyumu, P_e ise bu uyumun tesadüfen ortaya çıkma olasılığını ifade etmektedir. P_o ve P_e ise şu şekilde çıkarılır:

$$P_o = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.15)$$

$$P_e = \frac{(TN + FP)(TN + FN) + (TP + FN)(TP + FP)}{(TP + TN + FP + FN)^2} \quad (3.16)$$

Landis ve Koch (1977), κ değerlerini Çizelge 3.2'deki gibi yorumlamışlardır:

Çizelge 3.2 κ değerlerinin yorumu

κ	Yorum
< 0	Uyum yok
0.0 — 0.20	Önemsiz derecede uyum
0.21 — 0.40	Orta derecede uyum
0.41 — 0.60	İyi derecede uyum
0.61 — 0.80	Önemli derecede uyum
0.81 — 1.00	Neredeyse mükemmel uyum

4. DENEYSEL ÇALIŞMA ve ARAŞTIRMA BULGULARI

Bu bölümde tez çalışmasının konusu olarak retina görüntülerinin, iki farklı görüntü işleme tekniği de kullanarak KSA mimarilerinden EfficientNet-B7 ile DR'nin 5 evresine göre sınıflandırma işlemi adımları anlatılarak elde edilen sonuçlar ortaya konulacaktır. İşlemler; Numpy, Pandas, OpenCV, Keras gibi kütüphaneler kullanılarak Python programlama dilinde uygulanmıştır. Çalışma ortamı için Jupyter Notebook formatında çalışma yapmaya imkan tanıyan ve ücretsiz GPU desteği sunan Google Colab bulut servisi tercih edilmiştir. Google Colab üzerinde yapılan bu çalışmada NVIDIA Tesla P100 PCIe 16 GB rastgele erişilebilir bellek kullanılmıştır. 3662 görüntülük DR veriseti bölüm 3.1'de belirtildiği gibi Kaggle üzerinden temin edilmiştir.

4.1 Görüntü İşleme Aşamaları

Veriseti görüntülerindeki özelliklerin KSA modeli eğitiminde daha net öğrenilebilmesi, görüntülerin standart hale getirilmesi ve işlem maliyetini düşürebilmek için görüntüler bir dizi işleme aşamalarından geçirilmiştir. Ayrıca Gauss bulanıklaştırma ve CLAHE teknikleri ayrı ayrı uygulanarak bu iki tekniğin KSA başarımına etkisi karşılaştırılmıştır.

Gauss bulanıklaştırma filtresi kullanılan metotta, öncelikle görüntüler, retina dairesi dışındaki siyah boşluklardan arındırılarak sadece tıbbi özelliklerin olduğu alanların kalması sağlanmıştır. Ardından kamera gürültülerini gidermek ve görüntü özelliklerini belirgin hale getirmek amacıyla OpenCV kütüphanesinden cv2.GaussianBlur komutu ile Gauss bulanıklaştırma filtresi uygulanmıştır. Python dilinde bu işlem şu şekilde tanımlanmaktadır (OpenCV 2019):

```
cv2.GaussianBlur(src, ksize, sigmaX[, dst[, sigmaY]]) → dst
```

- src: Herhangi kanal sayısına sahip girdi görüntüsüdür.
- ksize: Gauss filtre boyutu. [yükseklik, genişlik]. Pozitif ve tek sayı şeklinde ayarlanabilir. Ksize, [0, 0] olarak ayarlanmışsa sigma değerlerinden hesaplanır.
- sigmaX: X eksenini boyunca filtrenin standart sapmasıdır.
- sigmaY: Y eksenini boyunca filtrenin standart sapmasıdır, sigmaY = 0 ise, sigmaX'e eşit olacak şekilde ayarlanır, her iki sigma da sıfıra eşitse, sırasıyla ksize

değerlerinden hesaplanır.

- dst: Girdi görüntüsüyle aynı boyut ve tipte çıktı görüntüsüdür.

Filtre boyutu (0,0) ve sigmaX değeri 10 olarak seçilerek filtreli görüntü elde edildikten sonra cv2.addWeighted komutuyla orijinal görüntü üzerine bindirilerek görüntünün yerel ortalama rengi çıkarılmıştır. cv2.addWeighted komutunun uygulanması şu şekildedir (OpenCV 2019):

$$\text{cv2.addWeighted(src1, alpha, src2, beta, gamma[, dst[, dtype]]) \rightarrow \text{dst}$$

- src1: İlk girdi görüntüsü
- alpha: İlk girdinin ağırlık katsayısı
- src2: İkinci girdi görüntüsü
- beta: İkinci girdinin ağırlık katsayısı
- gamma: Toplama eklenecek skaler değer
- dtype: Çıktının derinliği (isteğe bağlıdır)
- dst: Çıktı görüntüsü


addWeighted komutu iki görüntünün ağırlıklı toplamını hesaplama işlemi şöyle ifade edilebilir:

$$\text{dst} = \text{alpha} * \text{src1} + \text{beta} * \text{src2} + \text{gamma} \quad (4.1)$$

Uygulamada alpha = 4, beta = -4 ve gamma = 128 seçilerek orijinal görüntü ve gauss filtreli görüntü ağırlıklı olarak eklenmiştir. Böylece yüksek geçiren süzgeç kullanılmış gibi görüntü ayrıtları belirgin hale getirilmiştir. Ardından görüntüler 224x224 piksel boyutuna ayarlanmış ve renk normalizasyonu uygulanmıştır. RGB değerlerinin normalizasyonu, her pikselin değeri, tüm kanallar (R, G, B) üzerindeki piksel değerinin toplamına (255) bölünerek yapılmaktadır. Bu işlemler sonrası elde edilen işlenmiş retina görüntüleri şekil 4.1’de gösterilmiştir.


CLAHE yönteminin görüntülere uygulanmasında da öncelikle görüntüde retina dairesi kalacak biçimde siyah boşluk içeren alanlar kırılmış ve görüntüler 224x224 piksel boyutuna getirilmiştir. Daha sonra OpenCV kütüphanesi vasıtasıyla RGB renk uzayındaki görüntü L*a*b* renk uzayına dönüştürülmüştür. L*a*b* renk uzayında L*; L*=0 siyahı ve L*=100 beyazı temsil etmek üzere açıklığı (lightness), a*; +a* kırmızıyı ve -a* yeşili temsil etmek üzere kırmızı/yeşil değerini ve b*; +b* sarıyı ve -b* maviyi

temsil etmek üzere sarı/mavi değerini temsil etmektedir.



Şekil 4.1 Gauss bulanıklaştırma içeren görüntü işleme çıktıları

Ardından dönüştürülen görüntünün L^* , a^* ve b^* kanalları ayrılmış ve L^* kanalı üzerinde CLAHE uygulanmıştır. `cv2.createCLAHE(clipLimit, tileGridSize)` komutu ile kırpma limiti 4 olarak ve giriş görüntüsünü bölecek ızgara (8,8) olarak belirlenmiştir. CLAHE işlemi uygulandıktan sonra L^* , a^* ve b^* kanalları tekrar birleştirilmiş ve görüntü tekrar RGB renk uzayına dönüştürülerek renk normalizasyonu uygulanmıştır. Bu işlemler sonrası elde edilen işlenmiş retina görüntüleri Şekil 4.2’de gösterilmiştir.




Şekil 4.2 CLAHE içeren görüntü işleme çıktıları

4.2 Veriseti Tasnifi ve Etiketleme

Verisetinde bulunan 3662 görüntünün 2645'i eğitim, 504'ü validasyon ve 513'ü test seti olarak ayrılmıştır. DR sınıflarının test seti içindeki dağılımı çizelge 4.1 üzerinde gösterilmiştir.

Çizelge 4.1 Test seti DR sınıflarının dağılımı



DR verilerinin etiketlenmesi için farklı bir yaklaşım kullanılmıştır. Görüntülere sıralı sınıflandırma yapılacak şekilde çoklu etiketleme uygulanmıştır. Cheng vd. (2008)'e göre bu yöntemde model tahmin yaparken O_1, O_2, \dots, O_K sırasına göre çıkış düğümlerini taramaktadır. Tarama işlemi bir düğümün çıktısı önceden tanımlanmış eşik T 'den (ör: 0.5) daha küçük olduğunda veya hiç düğüm kalmadığında durmaktadır. Çıktısı T 'den büyük olan son O_K düğümünün k indeksi, verinin tahmin edilen sınıfını vermektedir. Ayrıca DR'nin ileri seviye sınıfları daha düşük seviye sınıfların semptomlarını da göstereceğinden ileri seviye sınıfların etiketlenmesinde düşük sınıflarda bulunan semptomlar da temsil edilmektedir. Bu durumda görüntü etiketleri 5 DR sınıfı için şöyle düzenlenmiştir:

- Sağlıklı (0): [1,0,0,0,0]
- Hafif NPDR (1): [1,1,0,0,0]
- Orta NPDR (2): [1,1,1,0,0]
- İleri NPDR (3): [1,1,1,1,0]
- PDR (4): [1,1,1,1,1]

4.3 EfficientNet-B7 Modeli

Eğitimden önce Keras kütüphanesinin alt modülü olan ImageDataGenerator ile veri artırımı yapılmıştır. Bu işlem ile aşırı öğrenmeyi azaltmak ve modele genelleştirme yeteneği kazandırmak amaçlanmıştır. Bu kapsamda modül içerisinde zoom_range = 0.1 (rastgele yakınlaştırma aralığı), horizontal_flip = True (görüntüyü yatay ekseninde çevirme), vertical_flip = True (görüntüyü dikey ekseninde çevirme), rotation_range = 360 (görüntünün 0-360° arasında rastgele döndürülmesi) şeklinde ayarlanarak görüntülerde rastgele değişimler yapılmıştır.

Veriseti üzerinde yapılacak tüm işlemler tamamlandıktan sonra transfer öğrenme metodu ile EfficientNet-B7 modeli kurulmuştur. Modelin ağırlıkları ImageNet verisetindeki ağırlıklar olarak ayarlanmış ve ince ayar ile o veriseti için olan sınıflandırma katmanı kaldırılarak modele ortalama havuzlama katmanı, Dropout katmanı (0.5 oranında) ve beş hastalık aşamasına karşılık gelen beş düğüme sahip sınıflandırma katmanı, çoklu etiketli yaklaşıma uygun olan sigmoid aktivasyon fonksiyonu ile beraber eklenmiştir. Toplam 64.110.485 parametre içeren modelin yapısı Şekil 4.3'te gösterilmiştir.


Layer (type)	Output Shape	Param #
efficientnet-b7 (Model)	(None, 7, 7, 2560)	64097680
global_average_pooling2d_1 ((None, 2560)	0
dropout_1 (Dropout)	(None, 2560)	0
dense_1 (Dense)	(None, 5)	12805
=====		
Total params: 64,110,485		
Trainable params: 63,799,765		
Non-trainable params: 310,720		

Şekil 4.3 Önerilen model

Modelin girdi boyutu 224x224x3 olacak şekilde ayarlanmış, optimizasyon tekniği olarak Adadelta seçilmiştir. Adadelta, eğitim boyunca öğrenme oranlarının sürekli olarak azalması ve manuel olarak seçilen bir global öğrenme oranına duyulan ihtiyaç problemlerini gidermek için uyarlanabilir bir öğrenme oranına dayanan stokastik bir

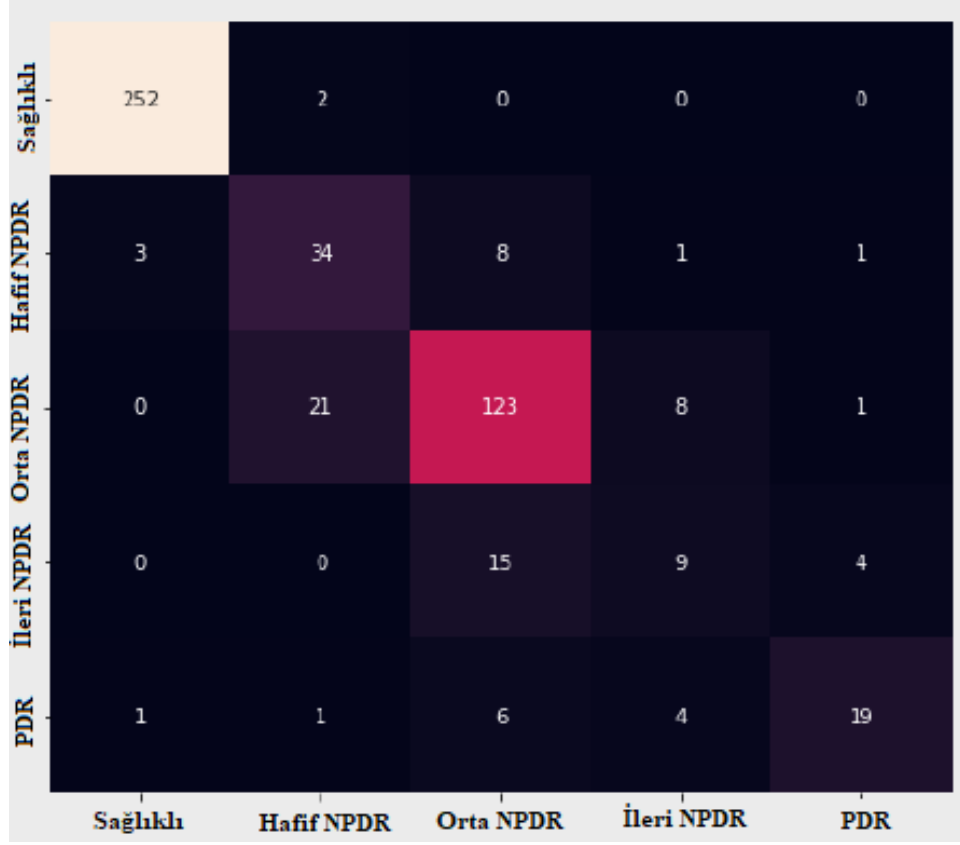
gradyan iniş yöntemidir. Adadelta, Adagrad'ın bir uzantısıdır ve öğrenme oranının sert düşüşünü azaltmaya çalışır. Böylece, Adadelta birçok güncelleme yapıldığında bile öğrenmeye devam etmektedir. Adadelta optimizasyon tekniğinin orijinal versiyonunda $learning_rate = 1.0$ değerindedir (Keras 2020).

Modelin eğitiminde belirli dönem sayısı boyunca öğrenme işlemi durduysa öğrenme oranı belirli değerde azaltılarak modelin tekrar öğrenmeye devam etmesi istenmektedir. Bu işlem Keras kütüphanesinin ReduceLRonPlateau modülüyle yapılmaktadır. Eğitim devam ederken val_loss (validasyon seti kayıp değeri) 4 dönem boyunca azalma göstermediği takdirde öğrenme oranı 0.2 oranında düşecektir. Ayrıca minimum kayıp değerini yakalamak ve modelin aşırı ezberlemesini önlemek adına EarlyStopping modülü kullanılmıştır. Bu modüle göre 12 dönem boyunca val_loss değeri, en düşük val_loss değerinden aşağı değere düşmezse eğitim bitirilecektir. Eğitim 50 dönem boyunca sürecek şekilde ayarlanmış; EarlyStopping tekniği ile Gauss bulanıklaştırma işlemi uygulanmış veriseti 0.09787 val_loss değeri ile 26 dönemde, CLAHE işlemi uygulanmış veriseti 0.10614 val_loss değeri ile 23 dönemde tamamlanmıştır. Eğitim boyunca kayıp fonksiyonlarının değişimini gösteren grafikler şekil 4.4'te gösterilmiştir.




Şekil 4.4 Gauss bulanıklaştırma işlemi uygulanmış veriseti kayıp fonksiyonu grafiği (sol), CLAHE işlemi uygulanmış veriseti kayıp fonksiyonu grafiği (sağ)

Eğitilen EfficientNet-B7 modeli 513 görüntülük test setlerine uygulandığında bulunan karışıklık matrisleri ve oradan elde edilen diğer başarımlar aşağıda verilmiştir.



Şekil 4.5 Gauss bulanıklaştırma işlemi uygulanmış test seti karışıklık matrisi



Şekil 4.6 CLAHE işlemi uygulanmış test seti karışıklık matrisi

Karışıklık matrislerinden elde edilen sonuçlara göre EfficientNet-B7 KSA modelinin iki farklı görüntü işleme metodu kullanılmış test setleri üzerindeki performans bulguları çizelge 4.2 ile verilmiştir.

Çizelge 4.2 Performans bulguları

	Gauss Bulanıklaştırma İşlemi Uygulanmış Veriseti	CLAHE İşlemi Uygulanmış Veriseti
Doğruluk	0,851852	0,842105
Kesinlik	0,850695	0,848504
Duyarlılık	0,851852	0,842105
F1 Skoru	0,849842	0,844196
Kappa Skoru	0,913599	0,912854

Önerilen modelden elde edilen sonuçlar ile literatürdeki özellikle son yıllarda yapılmış çalışmaların sonuçlarının karşılaştırma çizelgesi, çizelge 4.2 ile verilmiştir. DR sınıflandırma çalışmalarının genellikle 2'li ve 5'li sınıflandırma şeklinde yapıldığı görülmüştür. Tez çalışmamızda önerilen EfficientNet-B7 modelinin DR'nin 5 evresine göre sınıflandırılmasında verimli sonuçlar elde ettiği anlaşılmıştır.

Çizelge 4.3 Önerilen model ile geçmiş çalışmaların kıyaslanması

Çalışma	Veriseti	Metot	Görüntü Sayısı	Görüntü Boyutu	Performans Sonucu
2'li Sınıflandırma					
Alban ve Gilligan (2016)	Kaggle	AlexNet ve GoogleNet	35.126	256x256	Doğruluk: AlexNet %66,95; GoogleNet %71,05
Li vd. (2017)	DR1	VGGNet-vd-19	1014	224x224	Doğruluk: %94,12
Ghosh vd. (2017)	Kaggle	KSA	3190	512x512	Doğruluk: %95
Gargeya ve Leng (2017)	Kaggle	KSA	15.000	512x512	Duyarlılık: %94 Özgüllük: %98 AUC: 0,97

Çizelge 4.3 Önerilen model ile geçmiş çalışmaların kıyaslanması (devam)

Garcia vd. (2017)	Kaggle	VGG16noFC2	35.126	256x256	Doğruluk: %83,68 Duyarlılık: %54,47 Özgüllük: %93,65
Rakhlin (2018)	Messidor-2	VGG16	1748	540x540	AUC: 0,97
Lam vd. (2018)	Kaggle + Messidor-1	GoogleNet	400	256x256	Doğruluk: %74,5
Kwasigroch vd. (2018)	Kaggle	VGG-D	1000	224x224	Doğruluk: %81,7
Ignatius vd. (2019)	Messidor-1	DRNet	360	512x512	Doğruluk: %58,3
Sarki vd. (2019)	Messidor-1 + Kaggle	ResNet50			Doğruluk: %86
Singh vd. (2019)	Messidor-1 + Kaggle	KSA	4080	150x150	Doğruluk: %71
Chakravarthy vd. (2019)	Kaggle + Drive + Messidor-1	DRNet	1200	512x512	Doğruluk: %81 Kappa: 0,6
Tükel (2019)	Messidor-1	KSA	300	256x256	Doğruluk: %95
3'lü Sınıflandırma					
Alban ve Gilligan (2016)	Kaggle	AlexNet ve GoogleNet	35.126	256x256	Doğruluk: AlexNet %57,05; GoogleNet %58,21
Lam vd. (2018)	Kaggle + Messidor-1	GoogleNet	400	256x256	Doğruluk: %68,75
4'lü Sınıflandırma					
Lam vd. (2018)	Kaggle + Messidor-1	GoogleNet	400	256x256	Doğruluk: %57,25
5'li Sınıflandırma					
Pratt vd. (2016)	Kaggle	KSA	5000	512x512	Doğruluk: %75 Özgüllük: %95 Duyarlılık: %30
Doshi vd. (2016)	Kaggle	KSA	5000	512x512	Kappa: 0,3996
Alban ve Gilligan (2016)	Kaggle	AlexNet ve GoogleNet	35126	256x256	Doğruluk: AlexNet %40,73; GoogleNet %41,68
Ghosh vd. (2017)	Kaggle	KSA	3190	512x512	Doğruluk: %85

Çizelge 4.3 Önerilen model ile geçmiş çalışmaların kıyaslanması (devam)

Zhang vd. (2017)	Kaggle	ResNet	7000	512x512	Doğruluk: %81
Wang vd. (2018)	Kaggle	InceptionNet-V3	166	299x299	Doğruluk: %63,23
Lian vd. (2018)	Kaggle	VGG16	3506	256x256	Doğruluk: %79,04
Chen vd. (2018)	Kaggle	InceptionNet-V3	7023	299x299	Doğruluk: %80 Kappa: 0,64
Kwasigroch vd. (2018)	Kaggle	VGG-D	1000	224x224	Doğruluk: %50,8 Kappa: 0,776
Arora ve Pandey (2019)	Kaggle	KSA	1000	128x128	Doğruluk: %74,4
Sharma vd. (2019)	DR1 + Messidor1	KSA	200	128x128	Doğruluk: %74,04
Singh vd. (2019)	Kaggle	KSA	4800	150x150	Doğruluk: %56
Challa vd. (2019)	Kaggle	KSA	3000	224x224	Doğruluk: %86,64 F1 Skoru: %63,18
Qummar vd. (2019)	Kaggle	Ensemble Model	5608	512x512	Doğruluk: %80,8 Duyarlılık: %51,5 Özgüllük: %86,72 Kesinlik: %63,85 F1 Skoru: %53,74
Nagaraj vd. (2019)	Kaggle	VGG16	2938	224x224	Doğruluk: %73,72
Dekhil vd. (2019)	Kaggle	VGG16	553	224x224	Doğruluk: %77 Kappa: 0,78
Al-Kamachy (2019)	Kaggle	Inception ResNetV2	100	350x350	Doğruluk: %68 AUC: 0,69
Doshi vd. (2020)	Kaggle + IDRID	InceptionV3	7610	600x600	Doğruluk: % 85,2 Duyarlılık: % 83,4 Özgüllük: % 87,6
Önerilen Model (Gauss Bulanıklaştırma Uygulanmış)	Kaggle	EfficientNet-B7	513	224x224	Doğruluk: %85,18 F1 Skoru: %84,98 Kappa: 0,91

5. TARTIŞMA ve SONUÇ

İnsülin hormonunun eksikliği veya yokluğu nedeniyle ortaya çıkan diyabetes mellitus yani şeker hastalığı, görme hücrelerinin bulunduğu retinaya hasar verebilen DR komplikasyonunu doğurmaktadır. Tüm dünyada ve Avrupa'nın en yüksek diyabet prevalansına sahip ülkemizde DR komplikasyonunun artışı bireyler için ciddi sorunlar teşkil etmektedir. Bu yüzden en sık görülen körlük sebebi olan bu hastalığın erken dönemde fark edilebilmesi, hasta bireyleri kalıcı hasarlardan uzaklaştırmak adına büyük önem taşımaktadır. Buradan hareketle teşhis süreçlerini hızlandırabilmek, tıp uzmanlarının iş yükünü hafifletebilmek ve kararlarını kuvvetlendirebilmek adına yapay zeka temelli sistemler önerilmektedir.

Bu tez çalışmasında retina görüntülerinden DR hastalığını sağlıklı, hafif NPDR, orta NPDR, şiddetli NPDR ve PDR şeklinde 5 sınıf ile derecelendirerek teşhis etmek amaçlanmıştır. DR sınıflandırma işlemi temelde görüntü işleme teknikleri ve derin öğrenme metotları kullanılarak yapılmıştır. Çalışmada kullanılan Kaggle (APTOS 2019) veriseti çeşitli gürültüler içerdiğinden görüntü özneliklerinin daha verimli bir şekilde çıkarılarak sınıflandırma başarımını artırmak adına görüntü işleme tekniklerine ihtiyaç duyulmuştur. Görüntüler üzerinde Gauss bulanıklaştırma filtresi ve CLAHE olmak üzere ayrı ayrı iki teknik uygulanmıştır. Böylece bu iki farklı görüntü işleme tekniğinin de aynı sınıflandırma problemi üzerindeki başarıma etkisi kıyaslanmıştır. Görüntü boyutları 224x224 piksel boyutuna getirilerek standartize edilmiştir. Sınıflandırma işlemi çoklu etiketli sınıflandırma (multi-label classification) problemi şeklinde ele alınarak hedef sınıfın önceki sınıftaki semptomları da kapsayacak şekilde tahmin edilmesi sağlanmış, böylece modelin tahmini ile gerçek değer arasındaki farkın düşürülerek isabetli tahmin oranının artırılması amaçlanmıştır. Sınıflandırma aşaması için 2019 yılında Google tarafından tasarlanmış bir KSA mimarisi olan EfficientNet ince ayar yapılarak kullanılmıştır. Bileşik ölçeklendirme yöntemiyle muadili modellere göre daha az parametre kullanarak daha verimli sonuçlar veren EfficientNet-B7 modeli, DR sınıflandırma sürecinde başarılı sonuçlar ortaya koymuştur.

EfficientNet-B7 modeli Kaggle verisetinden alınan 513 test görüntüsünde; Gauss bulanıklaştırma filtresi ile %85,18 doğruluk, %85,06 kesinlik, %85,18 duyarlılık, %84,98 F1 skoru ve 0,9135 Kappa skoru elde etmiş, CLAHE ile %84,21 doğruluk, %84,85

kesinlik, %85,21 duyarlılık, %84,41 F1 skoru ve 0,9128 Kappa skoru elde etmiştir. Gauss bulanıklaştırma filtresi ile görüntünün ortalama yerel renginin çıkarıldığı görüntü işleme tekniğinin, CLAHE tekniğine göre az da olsa daha yüksek performans ortaya koyduğu görülmüştür.

DR tespit çalışmaları, “hasta” ve “sağlıklı” olarak ikili sınıflandırma ve hastalığın her evredeki belirtilerine göre beş sınıflı sınıflandırma çoğunlukla olmak üzere, bazı evreler birleştirilerek üçlü ve dördü sınıflandırma şeklinde de yapılmaktadır. Hastalığın sınıflanacağı sınıf sayısı artırıldıkça modelin doğru tahmin etme işlemi zorlaşmakta ve buna bağlı olarak başarımlar düşmektedir. Bunu önlemek için modelin daha karmaşık özellikleri öğrenebilecek şekilde eğitilmesi gerekmektedir. Önerilen EfficientNet-B7 modeli yaklaşık %85 doğruluk ve 0,91 kappa skoru ile DR sınıflandırma için başarılı bir performans sergilemiştir. Modelin hastalığın hangi aşamalarını daha net algılayabildiğine bakıldığında, elde edilen karışıklık matrisleri incelendiğinde önerilen modelin verisetindeki “sağlıklı” etiketli görüntüleri neredeyse kesin bir şekilde sınıflandırabildiği buna karşılık bazı diğer sınıflar için aynı kesinliği yakalayamadığı görülmektedir. Özellikle “ileri NPDR” etiketli görüntüleri, model diğerlerine göre daha az algılamaktadır. Bu durum kullanılan verisetindeki sınıfların dağılımının homojen olmamasından ve verisetinde en az sayıda bulunan sınıfın “ileri NPDR” etiketli görüntüler olmasından kaynaklanmaktadır.

İleriki çalışmalarda verisetindeki sınıfların dengesiz olması sebebiyle bazı sınıflar üzerinde düşen model performansını artırabilmek için eğitim esnasında kullanılan verisetindeki azınlık sınıfı görüntülerin sayısı oversampling yöntemi ile sayıca baskın olan sınıfın sayısına yaklaştırılabilir veya SMOTE yöntemiyle sentetik görüntüler oluşturularak verisetinin dengelenmesi sağlanabilir. Problemin çözümüne farklı bir yaklaşım türü olarak öncelikle model, önce daha başarılı olduğu “sağlıklı” / “hasta” şeklinde ikili sınıflandırılacak şekilde eğitilip görüntüleri sınıflandırdıktan sonra “hasta” tahminli görüntülerin kendi içinde tekrar hastalığın dört seviyesine göre sınıflandırılabilir. Böylece azınlık olan hastalıklı sınıfların çoğunluk sağlıklı sınıftan ayrı tutularak her sınıfın kendi başarımlarını artırılabilir. Retina görüntü veriseti hastanelerden sınıflar dengeli olacak şekilde toplanıp manuel olarak hazırlanabilir. Görüntüyü daha da ayrıntılandırarak görüntü işleme teknikleri ve daha yüksek çözünürlüklü görüntüler kullanılabilir. Örneğin görüntü ayrıtlarını daha başarılı bir

şekilde koruyan bilateral filtre gibi görüntü işleme teknikleri görüntüler üzerinde uygulanabilecektir. Diğer taraftan DR tespit ve sınıflandırma işlemi birkaç derin öğrenme modelinin birleştirilmesiyle oluşan topluluk modeli oluşturularak tek bir mimariden oluşan modellere kıyasla daha sağlıklı sonuçlar alınabilecektir. Bunların yanı sıra görüntü özniteliklerinin derin öğrenme metodlarıyla çıkarılıp, bunun devamında sınıflandırma işleminin geleneksel makine öğrenmesi metodlarıyla gerçekleştirildiği hibrit yöntemler kullanılabilir.

KAYNAKLAR

- Aggarwal, C. C. 2018. Neural Networks and Deep Learning. Springer, 497 ,Cham, Switzerland.
- Alban, M. ve Gilligan, T. 2016. Automated detection of diabetic retinopathy using fluorescein angiography photographs. Report of standford education.
- Al-Kamachy, I. 2019. Classification of diabetic retinopathy using pre-trained deep learning models. Yüksek lisans tezi. Çankaya Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, 92, Ankara.
- Anonymous. 2019. Web Sitesi: <https://www.kaggle.com/c/aptos2019-blindness-detection/data/>, Erişim Tarihi: 12.07.2020.
- Anonymous. 2020. Web Sitesi: <https://www.guru99.com/machine-learning-vs-deep-learning.html/>, Erişim Tarihi: 26.07.2020.
- Apaydın, K. C. ve Bilgin, A. B. 2010. Diyabetik retinopatide erken tanı ve medikal tedavi. Journal of Retina Vitreus,18(4), 61-65.
- Arısoy, M. ve Dikmen, Ü. 2014. Manyetik Belirti Haritalarının Histogram Eşitleme Yöntemi Kullanılarak İyileştirilmesi. Hacettepe Üniversitesi Yerbilimleri Uygulama ve Araştırma Merkezi Dergisi, 35(2), 141-168.
- Arora, M. ve Pandey, M. 2019. Deep Neural Network for Diabetic Retinopathy Detection, 2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon), 14-16 February, 189-193. Faridabad, India.
- Bercovich, E. ve Javitt, M. C. 2018. Medical Imaging: From Roentgen to the Digital Revolution, and Beyond. Rambam Maimonides Medical Journal, 9(4), e0034.
- Bezdan, T. ve Džakula, N. B. 2019. Convolutional Neural Network Layers and Architectures. In Sinteza 2019-International Scientific Conference on Information Technology and Data Related Research, 445-451. Singidunum University.
- Brownlee J. 2019. Web Sitesi: <https://machinelearningmastery.com/transfer-learning-for-deep-learning/>, Erişim Tarihi: 27.07.2020.
- Cancer and Fucoidan. 2020. Web Sitesi: <https://www.cancerandfucoidan.com/fucoidan-and-diabetes/>, Erişim Tarihi: 18.02.2020.
- Cebeci, Z. ve Akarçay, K. 2012. Diyabetik Retinopati. Klinik Gelişim Dergisi, 25, 16-19.
- Chakravarthy, S.N., Singhal, H. ve Narasimha Yadav R., P. 2019. DR-NET: A Stacked

- Convolutional Classifier Framework for Detection of Diabetic Retinopathy. 2019 International Joint Conference on Neural Networks (IJCNN), July, 1-7, Budapest, Hungary.
- Challa, U. K., Yellamraju, P. ve Bhatt, J. S. 2019. A Multi-class Deep All-CNN for Detection of Diabetic Retinopathy Using Retinal Fundus Images. In International Conference on Pattern Recognition and Machine Intelligence, Vol 11941, 191-199, Springer, Cham.
- Chan, R., Falkner-Radler, C., Bhaleeya, S., Chapman, K., Coombs, P., Klufas, M. ve Patel, S. 2016. Web Sitesi: <https://www.aao.org/topic-detail/diabetic-retinopathy-europe/>, Eriřim Tarihi: 11.03.2020
- Chauhan, N. S. 2020. Web Sitesi <https://www.kdnuggets.com/2020/06/introduction-convolutional-neural-networks.html/>, Eriřim Tarihi: 30.07.2020.
- Chen, H., Zeng, X., Luo, Y. ve Ye, W. 2018. Detection of Diabetic Retinopathy using Deep Neural Network. 2018 IEEE 23rd International Conference on Digital Signal Processing (DSP), 1-5.
- Cheng, J., Wang, Z. ve Pollastri, G. 2008. A neural network approach to ordinal regression. 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence), 1279-1284.
- Cohen, J. 1960. A Coefficient of Agreement for Nominal Scales. Educational and Psychological Measurement, 20(1), 37-46.
- Cořansu, G. 2015. Diyabet: Kresel Bir Salgın Hastalık. Okmeydanı Tıp Dergisi, cilt.31, 1-6.
- Çayırođlu, İ. 2018. Web Sitesi: http://www.ibrahimcayirođlu.com/Dokumanlar/GoruntuIsleme/GoruntuIsleme_Ders_Notlari-5.Hafta.pdf/, Eriřim Tarihi: 18.04.2020.
- Dargan, S., Kumar, M., Ayyagari, M. R. ve Kumar, G. 2019. A survey of deep learning and its applications: A new paradigm to machine learning. Archives of Computational Methods in Engineering, 1-22.
- Davson, H. ve Perkins, E.S. 2020. Web Sitesi: <https://www.britannica.com/science/human-eye/>, Eriřim Tarihi: 09.03.2020
- Dekhil, O., Naglah, A., Shaban, M., Ghazal, M., Taher, F. ve El-Baz, A. 2019. Deep Learning Based Method for Computer Aided Diagnosis of Diabetic Retinopathy. 2019 IEEE International Conference on Imaging Systems and Techniques (IST), 1-4.
- Deng, X., Liu, Q., Deng, Y. ve Mahadevan, S. 2016. An improved method to construct basic probability assignment based on the confusion matrix for

- classification problem. *Information Sciences*, 340, 250–261.
- Dishaeye Hospital, 2017. Web Sitesi: <http://www.dishaeye.org/blog/diabetic-retinopathy-guide/>, Erişim Tarihi: 19.02.2020
- Doğan, F. ve Türkoğlu, İ. 2019. Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme . *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.
- Doshi, D., Shenoy, A., Sidhpura, D. ve Gharpure, P. 2016. Diabetic retinopathy detection using deep convolutional neural networks. 2016 International Conference on Computing, Analytics and Security Trends (CAST), 261-266.
- Doshi, N., Oza, U. ve Kumar, P.P. 2020. Diabetic Retinopathy Classification using Downscaling Algorithms and Deep Learning. 2020 7th International Conference on Signal Processing and Integrated Networks (SPIN), 950-955.
- Elmas, Ç. (2018). *Yapay zeka uygulamaları*. Seçkin Yayıncılık, 424 ,Ankara.
- Erakgün, T. 2017. Web Sitesi: <http://tansuerakgun.com/tr/hastaliklar/diabetik-retinopati/>, Erişim Tarihi: 20.02.2020
- Ergin T. 2018. Web Sitesi: <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad/>, Erişim Tarihi: 29.07.2020.
- Erturk, S. 2013. Improved region of interest for infrared images using Rayleigh Contrast-Limited Adaptive Histogram Equalization. In *Proceedings of the International Conference on Image Processing, Computer Vision, and Pattern Recognition (IPCV)* (p. 1). The Steering Committee of The World Congress in Computer Science, Computer Engineering and Applied Computing (WorldComp).
- Espinoza, A.Z. 2019. *An Application of Deep Learning Models to Automate Food Waste Classification*. Yüksek lisans tezi, Portland State University, Electrical and Computer Engineering, 125, Portland.
- Fisher, R., Perkins, S., Walker, A. ve Wolfart, E. 2003. Web Sitesi: <https://homepages.inf.ed.ac.uk/rbf/HIPR2/gsmooth.htm/>, Erişim Tarihi: 15.06.2020.
- Fraser, C. E., D’Amico, D. J. ve Trobe, J. 2014. *Diabetic retinopathy: Classification and clinical features*. UpToDate. Waltham, MA: UpToDate Inc.
- García, G., Gallardo, J., Mauricio, A., López, J. ve Del Carpio, C. 2017. Detection of Diabetic Retinopathy Based on a Convolutional Neural Network Using Retinal Fundus Images. In *International Conference on Artificial Neural Networks*, Vol 10614, 635–642, Springer, Cham.

- Gargeya, R. ve Leng, T. 2017. Automated Identification of Diabetic Retinopathy Using Deep Learning. *Ophthalmology*, 124(7), 962-969.
- Ghosh, R., Ghosh, K. ve Maitra, S. 2017. Automatic detection and classification of diabetic retinopathy stages using CNN. 2017 4th International Conference on Signal Processing and Integrated Networks (SPIN), 550-554.
- Gonzalez, R. C. ve Woods, R. E. 2014. Sayısal görüntü işleme: üçüncü baskıdan çeviri. Palme Yayıncılık, 954, Ankara.
- Goodfellow, I., Bengio, Y. ve Courville, A. 2016. Deep learning. MIT Press, 802, Cambridge.
- Gündoğan, F. Ç. 2018. Web Sitesi: <https://gozdoktor.net/gozun-yapisi/>, Erişim Tarihi: 09.03.2020
- Haenlein, M. ve Kaplan, A. 2019. A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, 61(4), 5–14.
- Haykin, S. 2009. *Neural Networks and Learning Machines*. Pearson Education, Inc., Upper Saddle River, Third Edition, 906, New Jersey.
- Hijazi, S., Kumar, R. ve Rowen, C. 2015. Using convolutional neural networks for image recognition. Cadence Design Systems Inc.: San Jose, CA, USA, 1-12.
- Hubel, D. ve Wiesel, T. 1968. Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology*, 195 (1), 215-43.
- Ignatius, H., Chandra, R., Bohdan, N. ve Dharma, A. 2019. Comparison of Convolutional Neural Network Model in Classification of Diabetic Retinopathy. *Jurnal Penelitian Pos dan Informatika*, 9, 141-150.
- İnan, S. 2014. Retina anatomisi. *Kocatepe Tıp Dergisi* 15(3), 355-359.
- İnik, Ö. ve Ülker, E. 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3), 85-104.
- Janzen, J. 2018. Web Sitesi: <https://joshjanzen.com/cnn-transfer-learning-vs-build-from-scratch>, Erişim Tarihi: 27.07.2020.
- Jones, M. T. 2017. Web Sitesi: <https://developer.ibm.com/technologies/artificial-intelligence/articles/cc-machine-learning-deep-learning-architectures/>, Erişim Tarihi: 26.07.2020.
- Keras, 2020. Web Sitesi: <https://keras.io/api/optimizers/adadelta/>, Erişim Tarihi: 13.08.2020.

- Khandelwal, R. 2018. Web Sitesi: <https://medium.com/@arshren/gradient-descent-5a13f385d403/>, Erişim Tarihi: 11.08.2020.
- Kim, M., Yan, C., Yang, D., Wang, Q., Ma, J. ve Wu, G. 2020. Deep learning in biomedical image analysis. *Biomedical Information Technology*, 239–263.
- Kızrak, A. 2019. Web Sitesi: <https://medium.com/@ayyucekizrak/ölçeklendirme-ile-cnn-modelinin-doğruluk-ve-verimliliğini-artırma-efficientnet-cb6f2b6512de/>, Erişim Tarihi: 05.08.2020.
- Koonsanit, K., Thongvigitmanee, S., Pongnapang, N. ve Thajchayapong, P. 2017. Image enhancement on digital x-ray images using N-CLAHE. 2017 10th Biomedical Engineering International Conference (BMEiCON), 1-4.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E. 2012. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, 1097-1105.
- Kumar V. 2020. Web Sitesi: <https://analyticsindiamag.com/implementing-efficientnet-a-powerful-convolutional-neural-network/>, Erişim Tarihi: 31.07.2020.
- Kwasigroch, A., Jarzembinski, B. ve Grochowski, M. 2018. Deep CNN based decision support system for detection and assessing the stage of diabetic retinopathy. 2018 International Interdisciplinary PhD Workshop (IIPhDW), 111-116.
- Lam, C.K., Yi, D., Guo, M. ve Lindsey, T. 2018. Automated Detection of Diabetic Retinopathy using Deep Learning. *AMIA Summits on Translational Science Proceedings*, 2018, 147 - 155.
- Landis, J. ve Koch, G. 1977. The Measurement of Observer Agreement for Categorical Data. *Biometrics*, 33(1), 159-174.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P. 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. ve Chen, M. 2014. Medical image classification with convolutional neural network. 2014 13th International Conference on Control Automation Robotics & Vision (ICARCV), 10-12 Dec, 844-848, Singapore.
- Li, X., Pang, T., Xiong, B., Liu, W., Liang, P. ve Wang, T. 2017. Convolutional neural networks based transfer learning for diabetic retinopathy fundus image classification. 2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), 14-16 Oct, 1-11, Shanghai.
- Lian, C., Liang, Y., Kang, R. ve Xiang, Y. 2018. Deep convolutional neural networks for

- diabetic retinopathy classification. In Proceedings of the 2nd International Conference on Advances in Image Processing (ICAIP '18), 68–72, Association for Computing Machinery, New York, NY, USA.
- Ma, J., Fan, X., Yang, S., Zhang, X. ve Zhu, X. 2018. Contrast Limited Adaptive Histogram Equalization-Based Fusion in YIQ and HSI Color Spaces for Underwater Image Enhancement. *Int. J. Pattern Recognit. Artif. Intell.*, 32(07), 1854018, 1-26.
- Mathworks, 2020a. Web Sitesi: <https://www.mathworks.com/discovery/transfer-learning.html/>, Erişim Tarihi: 20.06.2020.
- Mathworks. 2020b. Web Sitesi: <https://www.mathworks.com/discovery/deep-learning.html>, Erişim Tarihi: 27.07.2020.
- Mookiah, M. R., Acharya, U. R., Chua, C. K., Lim, C. M., Ng, E. Y. ve Laude, A. 2013. Computer-aided diagnosis of diabetic retinopathy: a review. *Computers in biology and medicine*, 43(12), 2136–2155.
- More, O. 2020. Web Sitesi: <https://becominghuman.ai/resnet-convolution-neural-network-e10921245d3d/>, Erişim Tarihi: 27.08.2020.
- Nagaraj, G., Sumanth, S. C., Harish, C. G., R. ve Indiramma, M. 2019. Deep Learning Framework for Diabetic Retinopathy Diagnosis. 2019 3rd International Conference on Computing Methodologies and Communication (ICCMC), 27-29 March, 648-653, Erode, India.
- NHS (National Health Services), 2008. Web Sitesi: http://www.nhs.uk/translation/turkish/Documents/Diabetic_retinopathy_Turkish_FIN_AL.pdf/, Erişim Tarihi: 10.03.2020.
- Noor-ul-huda, M., Tehsin, S., Ahmed, S., Niazi, F.K. ve Murtaza, Z. 2019. Retinal images benchmark for the detection of diabetic retinopathy and clinically significant macular edema (CSME). *Biomedical Engineering / Biomedizinische Technik*, 64(3), 297-307.
- OpenCV 2019. Web Sitesi: <https://docs.opencv.org/2.4/modules/imgproc/doc/filtering.html#gaussianblur/>, Erişim Tarihi: 10.08.2020.
- Özgür, F. 2013. Web Sitesi: <http://bilheal.bilkent.edu.tr/aykonu/ay2013/diabet/diabet.htm/>, Erişim Tarihi: 08.03.2020.
- Pratt, H., Coenen, F., Broadbent, D. M., Harding, S. P. ve Zheng, Y. 2016. Convolutional Neural Networks for Diabetic Retinopathy. *Procedia Computer Science*, 90, 200–205.
- Pujiono, P. N., Purnama, I. K. E. ve Hariadi, M. 2013. Color enhancement of underwater

coral reef images using contrast limited adaptive histogram equalization (CLAHE) with Rayleigh distribution. The Proceedings of the 7th ICTS, Bali, 15-16 May 2013.

Qummar, S., Khan, F., Shah, S., Khan, A., Shamshirband, S., Rehman, Z., Khan, I.A. ve Jadoon, W. 2019. A Deep Learning Ensemble Approach for Diabetic Retinopathy Detection. In IEEE Access, vol. 7, 150530-150539.

Qureshi, I., Ma, J. ve Shaheed, K. 2019. A hybrid proposed fundus image enhancement framework for diabetic retinopathy. Algorithms, 12(1), 14.

Rakhlin, A. 2018. Diabetic Retinopathy detection through integration of Deep Learning classification framework. bioRxiv, 225508.

Saha, S. 2018. Web Sitesi: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53/>, Erişim Tarihi: 25.06.2020.

Sarki, R., Michalska, S., Ahmed, K., Wang, H. ve Zhang, Y. 2019. Convolutional neural networks for mild diabetic retinopathy detection: an experimental study. bioRxiv, 763136.

Satman, I., Omer, B., Tutuncu, Y., Kalaca, S., Gedik, S., Dinccag, N., Karsidag, K., Genc, S., Telci, A., Canbaz, B., Turker, F., Yilmaz, T., Cakir, B., Tuomilehto, J. ve TURDEP-II Study Group 2013. Twelve-year trends in the prevalence and risk factors of diabetes and prediabetes in Turkish adults. European journal of epidemiology, 28(2), 169–180.

Satman, I., Yilmaz, T., Sengül, A., Salman, S., Salman, F., Uygur, S., Bastar, I., Tütüncü, Y., Sargin, M., Dinççag, N., Karsidag, K., Kalaça, S., Ozcan, C. ve King, H. 2002. Population-based study of diabetes and risk characteristics in Turkey: results of the turkish diabetes epidemiology study (TURDEP). Diabetes care, 25(9), 1551–1556.

Sazlı, M. H. 2006. A brief review of feed-forward neural networks. Communications, Faculty Of Science, University of Ankara, 50(1), 11-17.

Shahid A. 2020. Web Sitesi: <https://towardsdatascience.com/efficientnet-scaling-of-convolutional-neural-networks-done-right-3fde32aef8ff/>, Erişim Tarihi: 05.08.2020.

Sharma S. 2017. Web Sitesi: <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6/>, Erişim Tarihi: 29.07.2020.

Sharma, H. S., Singh, A., Chandel, A. S., Singh, P. ve Sapkal, P. A. 2019. Detection of Diabetic Retinopathy Using Convolutional Neural Network. Proceedings of International Conference on Communication and Information Processing

(ICCIP) 2019.

- Shutterstock. 2020. Web Sitesi: <https://www.shutterstock.com/tr/image-illustration/diabetic-retinopathy-normal-eye-retina-328135913/>, Erişim Tarihi: 21.02.2020.
- Simonyan, K. ve Zisserman, A. 2015. Very Deep Convolutional Networks for Large-Scale Image Recognition. CoRR, abs/1409.1556.
- Singh, S. 2018. Web Sitesi: <https://medium.com/@shubhanshi.shubh860/confusion-matrix-in-machine-learning-cd7333d72f5d/>, Erişim Tarihi: 07.08.2020.
- Singh, T. M., Bharali, P. ve Bhuyan, C. 2019. Automated Detection of Diabetic Retinopathy. 2019 Second International Conference on Advanced Computational and Communication Paradigms (ICACCP), 1-6, IEEE.
- Skansi, S. 2018. Introduction to Deep Learning - From Logical Calculus to Artificial Intelligence. Springer, 187, Cham, Switzerland.
- Spijkerman, A. M., Dekker, J. M., Nijpels, G., Adriaanse, M. C., Kostense, P. J., Ruwaard, D., Stehouwer, C. D., Bouter, L. M. ve Heine, R. J. 2003. Microvascular complications at time of diagnosis of type 2 diabetes are similar among diabetic patients detected by targeted screening and patients newly diagnosed in general practice: the hoorn screening study. Diabetes care, 26(9), 2604–2608.
- Stitt, A. W., Lois, N., Medina, R. J., Adamson, P. ve Curtis, T. M. 2013. Advances in our understanding of diabetic retinopathy. Clinical science (London, England : 1979), 125(1), 1–17.
- Şeker, A., Diri, B. ve Balık, H. 2017. Derin Öğrenme Yöntemleri Ve Uygulamaları Hakkında Bir İnceleme. Gazi Mühendislik Bilimleri Dergisi, 3(3), 47-64.
- Tan, M. ve Le, Q. 2019. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. Proceedings of the 36th International Conference on Machine Learning, in PMLR 97:6105-6114.
- Tang, W. Y., Zhang, T., Shu, Q. M., Jiang, C. H., Chang, Q., Zhuang, H. ve Xu, G. Z. 2019. Focal choroidal excavation complicated with choroidal neovascularization in young and middle aged patients. International journal of ophthalmology, 12(6), 980–984.
- TC Sağlık Bakanlığı ve Halk Sağlığı Kurumu. 2014. Türkiye Diyabet Programı 2015-2020. Türkiye Halk Sağlığı Kurumu, Ankara. Yayın No:816.
- Teo, C. K. 2003. Digital enhancement of night vision and thermal images. Yüksek lisans tezi, Naval Postgraduate School, 93, Monterey, California.

- Ting, D. S., Cheung, G. C. ve Wong, T. Y. 2016. Diabetic retinopathy: global prevalence, major risk factors, screening practices and public health challenges: a review. *Clinical & experimental ophthalmology*, 44(4), 260–277.
- Tiwari, S. 2019. Web Sitesi: <https://www.geeksforgeeks.org/activation-functions-neural-networks/>, Erişim Tarihi: 29.07.2020.
- Toğaçar, M. ve Ergen, B. 2019. Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(1), 109-121.
- Tükel, T. 2019. Görüntü işleme ve evrişimsel sinir ağları kullanılarak diyabetik retinopati hastalığının tespiti. Yüksek lisans tezi. Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, 81, Isparta.
- Türkoğlu, M., Hanbay, K., Sivrikaya, I. S. ve Hanbay, D. 2020. Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1) , 334-345.
- Wang, X., Lu, Y., Wang, Y. ve Chen, W. 2018. Diabetic Retinopathy Stage Classification Using Convolutional Neural Networks. 2018 IEEE International Conference on Information Reuse and Integration (IRI), 465-471.
- Wild, S., Roglic, G., Green, A., Sicree, R. ve King, H. 2004. Global prevalence of diabetes: estimates for the year 2000 and projections for 2030. *Diabetes care*, 27(5), 1047–1053.
- Yamashita, R., Nishio, M., Do, R.K. ve Togashi, K. 2018. Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 9(4), 611 - 629.
- Zhang, D., Bu, W. ve Wu, X. 2017. Diabetic retinopathy classification using deeply supervised ResNet. 2017 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computed, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld / SCALCOM / UIC / ATC / CBDCOM / IOP / SCI), 1-6, San Francisco, CA.
- Zimmet, P., Alberti, K. G., Magliano, D. J. ve Bennett, P. H. 2016. Diabetes mellitus statistics on prevalence and mortality: facts and fallacies. *Nature Reviews Endocrinology*, 12(10), 616–622.

ÖZGEÇMİŞ

Adı Soyadı : Alaeddin TÜRKMEN

Doğum Yeri : Kayseri

Doğum Tarihi : 18.10.1994

Medeni Hali : Bekar

Yabancı Dili : İngilizce

Eğitim Durumu (Kurum ve Yıl)

Lise : Sema Yazar Anadolu Lisesi (2012)

Lisans : Erciyes Üniversitesi Mühendislik Fakültesi Biyomedikal Mühendisliği
Bölümü (2017)

Yüksek Lisans : Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik
Mühendisliği Anabilim Dalı (Eylül 2017 - Şubat 2021)