

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**



TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ORCID : - - -

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce

Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : / /

Tezin Savunma Tarihi : / /

Tez Danışmanı :
ORCID : - - -

Trabzon

ÖNSÖZ

“İyileştirilmiş Derin Öğrenme Modelleriyle Fundus Görüntülerinde Diyabetik Retinopatinin Sınıflandırılması” isimli bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Programı’nda hazırlanmıştır.

Tez çalışmam boyunca hiçbir desteğini esirgemeyen ve bilim insanı olma yolundaki ilk adımlarımı atarken kıymetli bilgileriyle ve tecrübesiyle yolumu aydınlatan danışman hocam Sayın Prof. Dr. Bekir DİZDAROĞLU’na teşekkürü bir borç bilirim. Ayrıca, yapıcı eleştirileri ve önerileri ile tezime katkıları bulunan saygıdeğer hocalarım Sayın Dr. Ramazan Özgür DOĞAN’a ve Sayın Dr. Öğr. Üyesi Özkan BİNGÖL’e, tez çalışması sürecinde de yardımını esirgemeyen Arş. Gör. Gülcan ASLAN’a teşekkür ederim.

Tez çalışması sürecinde bana desteklerini esirgemeyen Gümüşhane Üniversitesi Yazılım Mühendisliği Bölümü’ndeki bütün değerli hocalarıma ve asistan arkadaşlarıma teşekkürlerimi sunarım.

Son olarak, bugünlere gelmemde çok büyük paya sahip olan, hayatım boyunca hem maddi hem de manevi desteğini benden esirgemeyen, her durumda aldığım kararlarda ellerini omuzumda hissettiğim, bilgi ve tecrübelerinden her zaman yararlandığım aileme sonsuz teşekkürlerimi borç bilirim.

Bu tez çalışmasının bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Kübra UÇAR

Trabzon 2024

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “İyileştirilmiş Derin Öğrenme Modelleriyle Fundus Görüntülerinde Diyabetik Retinopatinin Sınıflandırılması” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Bekir DİZDAROĞLU’nun sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 18/09/2024

Kübra UÇAR

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	XI
SEMBOLLER VE KISALTMALAR DİZİNİ	XII
1.GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2.Literatür Çalışması.....	4
1.3. Fundus Görüntüleme Teknikleri	6
1.3.1 Oftalmoskop.....	6
1.3.2 Fundus Kamera.....	7
1.3.3 Fundus Floresein Anjiyografi.....	9
1.3.4 Indosiyanin Yeşili Anjiyografi.....	9
1.3.5 Tarayıcı (Scanning) Lazer Oftalmoskop.....	10
1.3.6 Optik Koherans Tomografi.....	11
1.4. Evrişimsel Sinir Ağı ve Modelleri	12
1.4.1 ResNet-50.....	15
1.4.2 MobileNet	17
1.4.3 EfficientNet.....	18
1.5.Transfer Öğrenme.....	20
1.6.Dikkat Mekanizması	21
1.6.1.Kategorik Dikkat Bloğu.....	22
1.6.2.Global Dikkat Bloğu.....	24
1.7. Çalışmada Kullanılacak Metrikler	24
2.YAPILAN ÇALIŞMALAR.....	27
2.1. Görüntü Ön İşleme.....	27

2.2. Veri oğaltma.....	28
2.3. CNN Modelleri.....	29
3. DENEYSEL ALIřMALAR, BULGULAR VE İRDELEME	32
4.SONULAR VE TARTIřMA.....	43
5.ÖNERİLER.....	44
6.KAYNAKLAR.....	45
ÖZGEMİř	



Yüksek Lisans

ÖZET

İYİLEŞTİRİLMİŞ DERİN ÖĞRENME MODELLERİYLE FUNDUS
GÖRÜNTÜLERİNDE DİYABETİK RETİNOPATİNİN SINIFLANDIRILMASI

Kübra UÇAR

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Bekir DİZDAROĞLU
2024, 48 Sayfa

Diyabetik retinopati (DR), şeker hastalığında en tehlikeli komplikasyonlarından biridir. Erken tanı ve tedavi, maliyetlerin azaltılabilmesi için son derece önemlidir. Diyabetik retinopati vakalarında kesin tanı konması oldukça zordur. Hastalığın evrelerinin tespit edilebilmesi fundus görüntülerinin uzman bir hekim tarafından incelenmesiyle mümkündür. Milyonlarca insanda görülen bu hastalığın evrelerini belirleme sürecinin basitleştirilmesi, tanı ve tedavi süreçlerinin hızlanmasını sağlayacaktır. Ancak etiketli verilerin oluşturulması maliyetli bir işlemdir ve uzman hekimler arasında görüş farklılıkları oluşturmaktadır. Bu durum, tanı sürecinde kullanılan yöntemlerin performansını da etkilemektedir.

Evrşimsel sinir ağları kullanılarak diyabetik retinopatinin sınıflandırılması derin öğrenme yaklaşımlarından biridir ve son zamanlarda literatürde bu konu ile ilgili çok sayıda araştırma yapılmıştır. Bu çalışmada evrimsel sinir ağlarına dayalı öğrenme tabanlı bir yaklaşım kullanılarak, fundus görüntülerindeki DR evreleri tespit edilmiştir. Ayrıca çalışmada, evre sınıflandırma sürecinde kullanılan modellere kategorisel dikkat mekanizması eklenerek, sınıflandırma sonuçlarında iyileşme sağlanıp sağlanmadığı da incelenmiştir. Çalışmanın başarısı farklı ağ mimarları üzerinde eğitimler yapılarak test edilmiştir. Eğitimlerle elde edilen tüm mimarilerde iyileşme sağlandığı görülmüştür.

Anahtar Kelimeler: Diyabetik retinopati, Fundus görüntüsü, Evrşimsel sinir ağları, Görüntü önileme, Dikkat mekanizması

Master Thesis

SUMMARY

CLASSIFICATION OF DIABETIC RETINOPATHY IN FUNDUS IMAGES WITH IMPROVED DEEP LEARNING MODELS

Kübra UÇAR

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Prof. Dr. Bekir DİZDAROĞLU
2024, 48 Pages

Diabetic retinopathy (DR) is one of the most dangerous complications of diabetes. Early diagnosis and treatment is extremely important to reduce costs. It is very difficult to make a definitive diagnosis in cases of diabetic retinopathy. It is possible to determine the stages of the disease by examining fundus images by a specialist physician. Simplifying the process of determining the stages of this disease, which is seen in millions of people, will accelerate the diagnosis and treatment processes. However, the creation of labelled data is a costly process and creates differences of opinion among specialist physicians. This situation also affects the performance of the methods used in the diagnosis process.

Classification of diabetic retinopathy using evolutionary neural networks is one of the deep learning approaches and there have been many recent studies on this subject in the literature. In this study, DR stages in fundus images were detected using a learning-based approach based on evolutionary neural networks. In addition, the study also examined whether the categorical attention mechanism is added to the models used in the stage classification process and whether the classification results are improved. The success of the study was tested by training on different network architectures. It was observed that improvement was achieved in all architectures obtained by training.

Keywords: Diabetic retinopathy, Fundus image, Convolutional neural networks, Image preprocessing, Attention module

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. DR hastalığı için temsili lezyonları gösteren fundus görüntüsü.....	1
Şekil 2. Fundus Görüntüleri.....	3
Şekil 3. Welch Allyn PanOptic Plus Ophthalmoscope (oftalmoskop) cihazı	7
Şekil 4. Fundus Kamera görüntüsü	8
Şekil 5. Portatif fundus kamerası çekilen fundus görüntülerinin akıllı cihazda birleştirilmesi.....	8
Şekil 6. Erken ve geç dönem ICG’de koroid neovaskularizasyonlarına ait plak görünümü.....	10
Şekil 7. Heidelberg retina anjiyografisi ile alınan kıızıl ötesi ve otofloresans fundus görüntüsü	11
Şekil 8. Diyabetik retinopatili hastada okla belirtilen yüzeyel hiperreflektif çizgi nokta kanama alanını göstermektedir.....	12
Şekil 9. Evrişimli sinir ağı modeli	13
Şekil 10. Evrişim işlemi ve adım kaydırma	14
Şekil 11. Havuzlama işlemi	14
Şekil 12. Tam Bağlantı Katmanı.....	15
Şekil 13. ResNet34 Mimarisi görüntüsü.....	16
Şekil 14. ResNet mimarisine ait 3 katmanlı darboğaz bloğu görüntüsü.....	17
Şekil 15. MobileNetV3 yapı diagramı	18
Şekil 16. Model boyutu ve ImageNet doğruluğu görüntüsü.....	19
Şekil 17. Evrişimli sinir ağı modelinde transfer öğrenme.....	21
Şekil 18. Evrişimli sinir ağı modelinde dikkat mekanizması kullanma.....	22
Şekil 19. Global dikkat bloğunun yapısı.....	24
Şekil 20. Fundus görüntülerinde ön işlemler görüntüsü.....	27
Şekil 21. Fundus görüntüsü çoğaltma örnekleri	28
Şekil 22. APTOS-2019 eğitim veri kümesinde her bir sınıfa ait fundus görüntülerinin sayısını gösteren çubuk grafiği	29
Şekil 23. APTOS-2019 eğitim veri kümesinde her bir sınıfa ait fundus görüntülerinin sayısını gösteren pasta dilimi grafiği	29

Şekil 24.	APTOS-2019 eğitim veri kümesinde eğitim ve test görüntülerinin oranlarını gösteren pasta dilimi grafiği.....	33
Şekil 25.	Çalışmada kullanılan CNN modeli.....	33
Şekil 26.	ResNet50 modeline ait eğitim veri seti için elde edilen grafikler.....	35
Şekil 27.	ResNet50+CABNet+Dropout modeline ait eğitim veri seti için elde edilen grafikler	36
Şekil 28.	EfficientB0 modeline ait eğitim veri seti için elde edilen grafikler	37
Şekil 29.	EfficientB0+CABNet+Dropout modeline ait eğitim veri seti için elde edilen grafikler	37
Şekil 30	MobileNetV3Large modeline ait eğitim veri seti için elde edilen grafikler.....	38
Şekil 31.	MobileNetV3Large+CABNet+Dropout modeline ait eğitim veri seti için elde edilen grafikler	39
Şekil 32.	ResNet50 modeline ait diyabetik retinopatinin seviyelerinin kestirimi için elde edilen hata matrisi.....	40
Şekil 33.	ResNet50+ CABNet + Dropout modeline ait diyabetik retinopatinin seviyelerinin kestirimi için elde edilen hata matrisi.....	40
Şekil 34.	EfficientB0 modeline ait diyabetik retinopatinin seviyelerinin kestirimi için elde edilen hata matrisi	41
Şekil 35.	EfficientB0+CABNet+Dropout modeline ait diyabetik retinopatinin seviyelerinin kestirimi için elde edilen hata matrisi	41
Şekil 36.	MobileNetV3Large modeline ait diyabetik retinopatinin seviyelerinin kestirimi için elde edilen hata matrisi	42
Şekil 37.	MobileNetV3Large +CABNet+Dropout modeline ait diyabetik retinopatinin seviyelerinin kestirimi için elde edilen hata matrisi	42

TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Tablo1. DR hastalığı seviyelerine ait bulgular.....	2
Tablo 2. EfficientNetB0 Ağı	19
Tablo 3. Karışıklık Matrisi.....	25
Tablo 4. Orijinal CNN Modellerinde kullanılan Test Veri Kümesi için elde edilen nicelik sonuçları.....	34
Tablo 5. Dikkat Mekanizması eklentili CNN Modellerine ait test veri kümesinin nicelik sonuçları.....	34

SEMBOLLER VE KISALTMALAR DİZİNİ

CAB	: Kategorik Dikkat Bloğu
GAB	: Global Dikkat Bloğu
CNN	: Evrişimli Sinir Ağı
ICG	: İndisiyonin Yeşili Anjiyografi
FFA	: Fundus Floresein Anjiyografi
SLO	: Tarayıcı Lazer Oftalmoskop
GMP	: Global Maksimum Havuzlama




1. GENEL BİLGİLER

1.1. Giriş


Diyabetik retinopati (DR), diyabet hastalığının en ciddi komplikasyonlarından biridir ve retinada hasara yol açarak körlüğe neden olmaktadır. Diğer bir deyişle Retina dokusunu meydana getiren kan damarlarında hasara yol açarak sıvı sızıntısına ve görme kaybına yol açmaktadır (Tymchenko vd., 2020). Diyabetik retinopati günümüzde görme kaybının temel nedenlerinden biridir (Zheng vd., 2012). Diyabetik retinopati tanısı konulan bir hastada, küçük damarlarda mikroanevrizma durumu, retinal kanamalar sinir liflerinin şişmesi veya lipid sızıntıları gibi dokusal bozulmalar görülebilir. DR hastalığına ait anevrizma, eksuda vb. lezyonları gösteren temsili çizim ise, Şekil 1’de verilmiştir. DR, hastalığın gelişim evrelerine göre, görünür DR yok (normal), hafif DR, orta DR, ciddi DR ve proliferatif DR evreleri olarak isimlendirilen beş farklı sınıfa ayrılmıştır (Bakınız Tablo 1). Şekil 2’de bu beş sınıfa ait etiketli görüntüler verilmiştir. Şekil 2.a’da normal etiketli görüntü, Şekil 2.b’de hafif DR etiketli görüntü, Şekil 2.c’de orta DR etiketli görüntü, Şekil 2.d’de ciddi DR etiketli görüntü, Şekil 2.e’de proliferatif DR etiketli görüntü verilmiştir.

Şekil 1. DR hastalığı için temsili lezyonları gösteren fundus görüntüsü (URL-1, 2024).



Tablo 1. DR hastalığı seviyelerine ait bulgular

Diyabetik Retinopati Seviyesi	Bulgular
0- DR Yok	-
1- Hafif DR	Küçük damar genişlemeleri (Mikroanevrizma) ve ufak retina kanamaları
2- Orta DR	Minimum 1 kadranda mikroanevrizma veya kanama bulunmalıdır. Ayrıca • Retinal kanama • Lipid sızıntıları (Sert eksuda) • Sinir liflerinde şişme (yumuşak eksuda) • Venöz lümen düzensizliği görülebilir.
3- Ciddi DR	Aşağıdaki bulgulardan birine rastlanmalıdır: • Her kadranda 20'den fazla retina içi kanama • En az 2 kadranda belirgin venöz lümen düzensizliği • En az 1 kadranda kılcal damarların anormal dallanması veya genişlemesi
4- Proliferatif DR	Aşağıdakilerden biri bulunmalıdır: • Neovaskularizasyon • Preretinal hemoraj (subhiyaloid aralıkta veya iç sınırlayıcı membran altında)



Şekil 2. Fundus Görüntüleri: a) Normal görüntü b) Hafif DR etiketli görüntü c) Orta DR etiketli görüntü d) Ciddi DR etiketli görüntü e) Proliferatif DR etiketli görüntü.

Görme bozukluğunun geri dönüşü olmadığı düşünüldüğünde ve erkenden tedavi edilmesi için diyabetik retinopatinin erkenden tespit edilmesi son derece önemlidir. DR'nin bu erken tespit edilmesi probleminin çözülmesi için ilk çalışmalarda bilgisayarlı görü ve makine öğrenmesine ait klasik yöntemler kullanılmıştır. Örneğin (Tymchenko vd., 2020; Zheng vd., 2012; Pratt vd., 2016; Li vd., 2017)'de renkli fundus görüntülerinde diyabetik retinopatinin seviye tespitine yönelik bilgisayarlı görmeye dayanan yaklaşımlar önerilmiştir. Son dönemlerde derin öğrenme yaklaşımları segmentasyon ve sınıflandırmada diğer algoritmalara göre daha iyi sonuçlar üretmektedir ve fundus görüntülerinde DR derecelendirilmesi için sık kullanılan bir yöntemdir. Diğer bir çalışmada önceden eğitilmiş Evrişimli Sinir Ağı(CNN) modelleri ve aktarmalı öğrenmeyi kullanarak en iyi sonuçların elde edilmesi amaçlanmıştır (Li vd., 2017). Başka bir çalışmada destek vektör makinesi (SVM) yaklaşımı DR sınıflandırması için olasılıksal bir sinir ağı modeli kullanılarak elde edilen sonuçlara bakılmıştır (Priya & Aruna, 2012). Diğer bir çalışmada (Li vd., 2019) DR'yi otomatik olarak derecelendirmek için CNN'le bütünleştirilen iki dikkat mekanizması (yani hastalığa özgü ve hastalığa bağlı modeller) önerdiler. (Bagherinezhad vd., 2018) önerdiği bir çalışmada da eğitim süreci sırasında temel gerçeklik etiketlerini yinelemeli olarak

güncellemek için bir etiket iyileştirmesi yapılmıştır. Liu vd. (2020)'de, DR derecelendirmesinde önemli bir iyileşme için sınıf korelasyonunu açık bir şekilde modellemek üzere, standart bir görüntü sınıflandırma ağından ve ekstra bir sınıf bağımlılık modülünden oluşan bir Grafik Artık Yeniden Sıralama Ağı (GREEN) önermiştir.

Bu çalışmada diyabetik retinopati tespiti için halka açık olan APTOS-2019 körlük veri seti kullanılmıştır (URL-2). Aktarmalı öğrenme yaklaşımı ve dikkat mekanizması ile tek bir fundus görüntüsünde DR aşama tespiti yapılmaya çalışılmıştır. İlk olarak çözünürlük, ışık, boyut, parlaklık gibi durumlardan kaynaklanan problemi çözmek için görüntülere ön işleme yapıldı. İkinci olarak sınıf dengesizliğinden kaynaklanan problemi çözmek için veri artırma işlemi uygulandı. Üçüncü olarak aktarmalı öğrenme metodu ile model eğitilmiştir. Son olarak da kategorisel dikkat bloğu eklenerek elde edilen sonuçların performansı artırdığı görülmüştür.

1.2. Literatür Çalışması

Doshi ve arkadaşları tarafından, açık veya manuel özellik çıkarımı olmadan hastalığın evresini teşhis etmede çok önemli olan özellikleri otomatik olarak öğrenen bir diyabetik retinopati teşhis modeli önerilmiştir (Doshi vd., 2016). Bu makalede görüntünün kontrastını pikseller arasında eşit bir şekilde artırmak için görüntülere histogram eşitleme tekniği uygulanmış ve evrimsel sinir ağının görüntüdeki doğal arka plan gürültüsünü öğrenmesini önlemek için, her görüntü Min-Max normalizasyonu kullanılarak normalleştirilmiştir. Giriş ve çıkış hacimlerinin uzamsal boyutunu korumak için evrimsel katmanlarda sıfır dolgu kullanılmıştır. Hastalığın teşhisinde yer alan özelliklerin karmaşıklığı göz önünde bulundurularak tasarlanan derin ağ, orijinal veri kümesine aşırı uyum sağlayabilirdi. Bunu önlemek için, veri kümesi kesme, bazı görüntü dönüşümleri kullanılarak görüntüler artırılmıştır. Kayıp fonksiyonunu en aza indirmek için modeller mini batch boyutunda Stokastik Gradyan İnişi ile Nesterov Momentum kullanılarak eğitilmiştir. Bütün yapılan işlemler sonucunda ikinci dereceden ağırlıklı Kappa hesaplanmıştır.

Li ve arkadaşları, hedef görevi tamamlamak için üç farklı yöntem kullanmışlardır (Li vd., 2017). İlk yöntem, önceden eğitilmiş farklı CNN modellerinin her birinin tüm ağ katmanlarına ince ayar yapmak, ikinci yöntem, önceden eğitilmiş bir CNN modeline katman bazında ince ayar yapmak ve üçüncü yöntem, fundus görüntülerinden özellikler çıkarmak için önceden eğitilmiş CNN modellerini kullanmak ve ardından bu özellikleri kullanarak

destek vektör makinelerini eğitmek. Özellikle, önceden eğitilmiş CNN modelleri, giriş görüntülerinden öznitelikler çıkaran öznitelik oluşturucular olarak kullanılmıştır. Çıkarılan bu öznitelikler, rastgele orman, lojistik regresyon gibi yeni bir sınıflandırıcıyı eğitmek için kullanılmıştır. Bu makalede, önceden eğitilmiş CNN modelleri hedef görev için öznitelik çıkarıcı olarak kullanılarak fundus görüntülerinin her biri önceden eğitilmiş CNN modelini beslenmiş ve iç katmanlardaki çıktılar, daha sonra bir destek vektör makinesi sınıflandırıcısını (alt sıra) eğitmek için kullanılmış ve umut verici sonuçlar elde edilmiştir.

Woo ve arkadaşları tarafından ileri beslemeli Evrişimsel sinir ağları için basit ama etkili bir dikkat mekanizması olan Evrişimsel Blok Dikkat Mekanizması (CBAM) önerilmiştir (Woo vd., 2018). Evrişim işlemleri kanallar arası ve uzamsal bilgileri bir araya getirerek bilgilendirici özellikler çıkardığından, modele bu iki temel boyut boyunca anlamlı özellikleri vurgulamak için, kanal ve uzamsal dikkat modülleri sırayla uygulanmıştır. Dikkat mekanizmasının etkinliği kapsamlı ablasyon çalışmalarıyla doğrulanmıştır. Çeşitli ağların performansının, hafif modül takılarak çoklu karşılaştırma ölçütlerinde (ImageNet-1K, MS COCO ve VOC 2007) büyük miktarda artırıldığı gösterilmiştir.

Tymchenko ve arkadaşları tarafından insan fundusunun tek bir fotoğrafı ile aşama tespiti yapmak için otomatik derin öğrenmeye dayalı bir yöntem önerilmiştir (Tymchenko vd., 2020). Ek olarak farklı etiketlemelere sahip verisetlerini kullanan transfer öğrenmeye yönelik çok aşamalı yaklaşımlar önerilmiştir. Sinir ağları, belirli bir görev (kafa) için bir öznitelik çıkarıcı ve daha küçük kod çözücüye sahip geleneksel derin CNN mimarisini kullanarak oluşturulmuştur. CNN omurgası ile çıkarılan özniteliklere dayalı olarak görevini çözmek için eğitilen üç kod çözücü kullanılmıştır. CNN'deki özniteliklere aşırı uyum sağlamaması ve görüntü içeriği ile meta özellikleri arasındaki korelasyonları azaltması için yüksek miktarda görüntü artırma işlemi dikkate alınmıştır. Eğitim aşamasında daha iyi performans elde etmek ve modelleri düzenli hale getirmek için bırakma gibi geleneksel yöntemler göz önüne alınmıştır. Deneysel sonuçlar, önerilen yöntemin kararsız metriklerde bile yüksek ve kararlı sonuçlar elde ettiği gösterilmiştir.

Hou ve arkadaşları tarafından DR sınıflandırması için yalnızca görüntü düzeyi denetimiyle lezyon öncelikleriyle ayırt edici öznitelikleri dikkate alan yeni bir ağ modeli önerilmiştir (Hou vd., 2023). Spesifik olarak, ikili DR tanımlama gibi yardımcı bir görev sunarak lezyon aktivasyon haritaları oluşturan bir lezyon dikkat mekanizması tasarlanmıştır. Lezyon aktivasyon haritaları, DR derecelendirme performansını artırmak için ağın en ilgili bölgelere odaklanmasına yardımcı olmaktadır. Ayrıca, DR tanımlama ve DR

derecelendirme görevlerini dinamik olarak dengelemek için özellikle uyarlanabilir bir ortak kayıp fonksiyonu tasarlanmıştır. Açık kaynaklı DR veri kümesi üzerinde elde edilen kapsamlı sonuçlar, önerilen lezyon farkındalıklı modelin üstünlüğünü göstermektedir. Üretilen lezyon aktivasyon haritalarının yorumlanabilirliği, segmentasyon maskeleriyle karşılaştırılarak da doğrulanmıştır.

1.3. Fundus Görüntüleme Teknikleri

Fundus görüntüleme, göz küresinin iç yüzeyindeki bileşenlerin (retina, optik disk makula vb.) görüntülenmesi işlemidir (Saine & Tyler, 2002). Teknik olarak fundus görüntüleme, göz küresinin 3 boyutlu iç yüzeyinin, ışık kullanılarak görüntüleme düzlemine yansıtılan 2 boyutlu bir nesne olarak temsil edildiği bir prosedürdür.

Görüntüler, özel bir düşük güçlü mikroskop ve buna bağlı bir kamera ile donatılmış bir fundus kamerasıyla elde edilir. Fundus kamera kullanmanın temeli, görüntüleme ışığının ve buna karşılık gelen retina yansımasının gözbebeği boyunca her iki yönde de geçebilmesidir. Böylece gözün içinin görüntüsü elde edilebilmektedir. Fundus kameraları tarafından çekilen görüntüler, merceğin optik kabul açısına bağlıdır. Normal görüş açısı 30°'dir, bu da görüntünün yaklaşık 2,5 kat büyütülmesiyle sonuçlanır. 45°-140° arasındaki daha geniş optik açılar için büyütme daha azdır (Saine & Tyler, 2002).

Fundus görüntülemesinde temel olarak oftalmoskop, fundus kamera, fundus floressein anjiyografi (FFA), indosiyanin yeşili anjiyografi (ICG), tarayıcı lazer oftalmoskop (SLO), optik koherans tomografi (OCT) kullanılmaktadır (URL-3, 2024).

1.3.1. Oftalmoskop

İlk defa 1850 yılında Hermann Von Helmholtz tarafından direk oftalmoskopun kullanıma sunulması ile klinisyenler, yaşayan bireylerde retinayı görebilme imkanına kavuşmuştur. Direk oftalmoskop kullanımından 2 yıl sonra ise daha geniş görüş açısına sahip ve derinlik hissi sağlayan indirekt oftalmoskop geliştirilerek periferik retina değerlendirilebilmiştir (Çıtırık & Teke, 2016) (Şekil 3'te görüldüğü gibi).




Şekil 3. Welch Allyn®PanOptic™ Plus Ophthalmoscope (oftalmoskop) cihazı (URL-4, 2024).

1.3.2. Fundus Kamera


Optik tasarımı indirekt oftalmoskoba dayandırılan fundus kamera, bağlı bir kamera ile özelleştirilmiş düşük güce sahip bir mikroskoptur. Normal görüş açısı 30° 'lik bir açı kabul edilir ve bu da gerçek boyuttan 2,5 kat daha büyük bir film görüntüsünün elde edilmesini sağlar. Dar açıya sahip bir fundus kamera, 20° ya da bu derecenin altında bir görüş açısına sahipken geniş açıya sahip fundus kameranın görüş açısı 45° ile 200° arasında değişmektedir. Farklı görüntü açılarına sahip olunması daha az retinal büyüme sağlamaktadır. Fundus kamerasında görüntülere yedi bölge birleştirilmesi tekniği uygulanarak geleneksel fundus görüntüleme yönteminde 30° - 45° görüntüleme alanı 75° 'ye çıkarılır. Retinadaki görüntü alanı, geniş açılı fundus görüntüleme metotları kullanılarak 200° 'ye de çıkartılabilir (Çıtırık & Teke, 2016) (Şekil 4'te görüldüğü gibi).



Şekil 4. Fundus kamera görüntüsü (Çıtırık & Teke, 2016).



(a)



Şekil 5. Portatif fundus kamerası çekilen fundus görüntülerinin akıllı cihazda birleştirilmesi: a) Portatif fundus kamerası, b-e) Fundus görüntüleri ve f) Birleştirilmiş sonuç görüntüsü (Hu vd., 2022).

1.3.3. Fundus Floresein Anjiyografi


Yaklaşık 50 yıl önce tanımı yapılan ve kullanılmaya başlanan fundus flöresein anjiyografi (FFA) normal dönemlerde ve patolojik durumlarda retina ve koroidin incelenmesine olanak sağlayan bir görüntüleme metodudur. Modern görüntüleme teknikleri geliştirilmiş olmasına rağmen FFA teknolojisi hala retina patolojileri tanılarında kullanılmaya devam edilen bir yöntemdir. (Kalaycı, 2017). Flöresein anjiyografi (FA), 1960'lı yılların başından itibaren retinal, koroidal ve optik disk tanılarında kullanılmakla birlikte özellikle diyabetik retinopatinin başlangıcında bulunan mikro anevrizmaları gösteren, makula ödemi, maküler perfüzyonu, yeni damar oluşumları gibi retina damar patolojilerini ve sızıntıları göstermesi nedeniyle altın standart şeklinde benimsenmiş görüntüleme metodudur (Novotny & Alvis, 1961; Durlu & Kavadarlı, 2018).

Anjiyografide kullanılan Sodyum (Na) floresein boyası bir hidrokarbon olup petrolün yan ürünlerinden sentezlenerek elde edilen kimyasal boyalardan biridir. FFA, Na floresein floresans yayma özelliğine dayanan bir metottur. Floresans, bir molekülün belirli bir ışıktaki aktifleşip yükseltgenmesi ve foton yayarak tekrar indirgenmesi esnasında ışık yaymasıdır. Floresein ön kol veninden enjekte edilir ve periferik kanda %80'i proteine, çoğunluğu da albümine bağlanır. Bağlı olan bu molekül flöresans özelliğine sahip değildir. Retina damarları floresein molekülüne geçirgen olmayıp koryokapillaris tabakası floreseine geçirgendir. Normal şartlarda optik diskte koryokapillaris tabakasında olan sızıntı sebebiyle geç dönemde boyanma olur ve hiper flöresans görülür, fakat disk sınırlarından sızıntı yoktur. Retina damarlarında diyabet gibi bir patolojik durum olduğu zaman ya da retina pigment epitelinde patoloji olduğunda, normal durumda sızdırmayan bu bariyerlerin bozulması sonucu flöresein sızıntısı görülür (Kalaycı, 2017).

1.3.4. İndosiyanin Yeşili Anjiyografi

Göz hastalıklarının teşhis ve tedavisinde kullanılan görüntüleme yöntemlerinden biri olan indosiyanin yeşili anjiyografi (ICG), ilk olarak 1970'lerde kullanılmıştır. 1975 yılında Amerikan İlaç ve Gıda komitesi (FDA) tarafından onaylanan ICG yaygın olarak 2000'li yıllardan sonra uygulanmıştır. İndosiyanin yeşili, yakın kızılötesi ışığa hassas bir boya olmakla birlikte koroid damarlarının açık bir şekilde görüntülenmesini sağlar. ICG optik koherans tomografi ve fundus floresein anjiyografiye göre daha üstün bir görüntüleme yöntemi olmakla beraber yüksek maliyetli ve girişimsel olma gibi dezavantajları vardır.

İndosiyanin yeşili anjiyografi, koryoretinal hastalıkların patofizyolojisini anlamakta ve tedaviyi takip etme sürecinde kilit bir rol oynamaktadır. ICG'nin genellikle hafif ve orta ciddiyette yan etkileri olup nadir durumlarda ciddi yan etkilerle karşılaşılabilir. Farklı görüntüleme cihazları kullanılarak indosiyanin yeşili anjiyografi uygulanabilir. ICG'de yaygın olarak dijital fundus kamerası ve tarayıcı lazer oftalmoskobu gibi cihazlar kullanılır. Dijital fundus kamera sisteminde beyaz ışıktan yararlanılırken tarayıcı lazer oftalmoskop sisteminde lazer ışığı fundus üstünde hareket ettirilerek görüntü elde edilir. İndosiyanin yeşili anjiyografi, retinal ve koroidal hastalıkları takip etmek için kullanılan önemli yöntemlerden biridir (Yıldız, 2021).




Şekil 6. ICG'de koroid neovaskülarizasyonlarına ait plak görünümü: a) Erken dönem ICG'de koroid neovaskülarizasyonuna ait plak görünümü b) Geç dönem ICG'de koroid neovaskülarizasyonlarına ait plak görünümü (Afrashi, 2016).

1.3.5. Tarayıcı (Scanner) Lazer Oftalmoskopu

Temel çalışma prensibi tarayıcı lazer mikroskopu ile aynı olan tarayıcı lazer oftalmoskopu (SLO) 1980 yılında Webb, Pomerantzeff ve Hughes tarafından icat edildi. SLO, çeşitli retinal görüntüleme tekniklerinin hedefi, hücresel ve doku seviyesinde morfolojik değişikliklerin görsel hale getirilmesidir. Tarayıcı lazer oftalmoskop (SLO) fundusun epeyce paralel dar lazer ışını ile taranarak geri yayılan ışık yoğunluğunun ölçülmesi işlemine dayanmaktadır. Yaklaşık 1 mm çapa sahip monokromatik ve düşük enerjili ışık (670 nm, diod lazer) demeti retina iletilerek retinada ortalama 10 mikron çapında bir noktasal alan aydınlatılarak ve retina yüzeyinin tamamı taranarak odaklanılmış

noktadan yansıyan ya da emilime uğrayan ışığın detektör vasıtasıyla kaydedilmesiyle zaman içinde görüntü meydana getirilir. Her pikselin yoğunluğu ışığa duyarlı tek bir detektör kullanımı ile kaydedilerek her pikselin konumu tarama aynalarından elde edilen çıktılarla kodlanır ve bu bilgiler nihai görüntüyü elde etmek amacıyla bilgisayar yardımı ile bir araya getirilir (Yılmaz, 2017).

Klinik kullanımlarda en popüler olan SLO cihazı Heidelberg retina tomografisi (HRT) (Heidelberg Engineering, Heidelberg, Almanya) optik sinir başındaki topografik değişiklikleri 670 nm diod lazer ile görüntülemek ve yinelenabilir şekilde analiz etmek için kullanılır. Günümüzde geliştirilen yüksek hızlı anjiolardan biri olan Heidelberg retina anjiyografisi (HRA) senkron olarak FFA ve ICG için tasarlanmış konfokal lazer tarama sistemi şeklinde HRT'nin uyarlanmış halidir (Yılmaz, 2017).




Şekil 7. Heidelberg retina anjiyografisi fundus görüntüleri: a) Heidelberg retina anjiyografisi ile alınan kızıl ötesi fundus görüntüsü b) Heidelberg retina anjiyografisi ile otofloresans fundus görüntüsü (Yılmaz, 2017).

1.3.6. Optik Koherans Tomografi

Optik Koherens Tomografiyi (OCT), ilk olarak Huang ve arkadaşları tarafından Massachusetts Teknoloji enstitüsünde geliştirmiş ve 1991'de yayınlayarak bildirimini yapmıştır. OCT; makulanın sanal optik biyopsisini sağlaması nedeniyle retinal hastalıkların tanısında, tedavisinde ve takibinde kullanılan en kullanışlı görüntüleme testidir (Çıtırık, İlhan & Teke). Aynı zamanda optik koherens tomografi, biyolojik dokularda yüksek çözünürlüklü, gerçek zamanlı kesitlere erişen, girişimsel olmayan ve temassız bir

görüntüleme metodudur. Retinanın morfometrik ve kantitatif ölçümlerini vererek retina dışında başka dokuların görüntülenmesinde de yararlanılmaktadır. OCT, yüksek çözünürlüğü nedeniyle dokuya bozmadan, in vivo kesitsel görüntülerin alınmasını sağlamaktadır (Özdemir & Ekinci, 2018).

OCT, DR'nin bazı erken dönem bulgularının teşhis edilmesinde tek başına yeterli olmamakla beraber renkli fundus fotoğrafı ve fundus floresin anjiyografiyle (FFA) ile değerlendirildiği zaman tanı ve takipte faydalı bilgiler bulmaktadır.




Şekil 8. Diyabetik retinopatili hastada okla belirtilen yüzeyel hiperreflektif çizgi nokta kanama alanını göstermektedir: a) Fundus görüntüsü ve b) OCT görüntüsü (Özdemir & Ekinci, 2018).

1.4. Evrişimsel Sinir Ağı ve Modelleri


Evrişimli sinir ağları, görüntü tanıma ve işlemede sık sık kullanılan bir yapay sinir ağı modelidir. Evrişimli sinir ağları görüntü sınıflandırmada kullanılan en verimli derin öğrenme modelleridir (Jmour vd., 2018). Bu modeller sayesinde sabit olan özellikler hiyerarşik bir şekilde ve otomatik olarak öğrenilir (Ergin, T., 2018). Bu mimariler, önce düşük düzeyli öznitelikleri belirlenir ve daha sonra daha kompleks kalıplarını öğrenmek için bu öznitelikleri tanımayı ve birleştirmeyi öğrenirler. Farklı seviyelerdeki bu öznitelikler ağın farklı katmanlarından gelir ve her katman belli sayıda nörona sahiptir ve bu nöronlar genişlik, yükseklik ve derinlik olmak üzere üç boyuttan oluşur (Şekil 9'da görüldüğü gibi). Böylece örneğin, iki boyutlu gri görüntüler temsil etmek için bir öznitelik haritası elde edilmiş olur.

Evrişimli sinir ağları, evrişim, havuzlama ve tam bağlantı katmanı olmak üzere genelde 3 farklı katmandan oluşur. Evrişim katmanı, evrişimli sinir ağının ana yapı taşı olup resmin özniteliklerinin algılanmasını sağlar. Bu katman, görüntüdeki yüksek ve düşük düzeyli özniteliklerin çıkarılması için görüntüye bazı filtreler uygular. Evrişim işleminde filtre görüntü üzerinde gezdirilerek basit matris çarpımı uygulanır, girdi görüntüsüne ait öznitelikler belirlenir. Genel olarak, daha fazla filtre kullanımıyla daha çok özellik belirlenir böylece bir evrişimli sinir ağında birden fazla evrişim katmanı bulunur (URL-5, 2024).




Şekil 9. Evrişimli sinir ağı modeli: Öznitelik öğrenme, sınıflandırma öğrenme ve sınıflandırma.

Evrişim işleminde, ilk olarak iki boyutlu veri üzerine x ve y eksenine göre simetriği alınan filtre uygulanır. Filtre görüntü üzerinde adım uzunluğuna bağlı ilişkili bir şekilde gezdirilirken her adımda çakışan değerler eleman eleman çarpılarak elde edilen tüm değerlerin toplamı çıkış matrisinin ilgili elemanına kaydedilmektedir. Filtrenin simetriği alınmadan yapılan işleme ise korelasyon (cross-correlation) denilmektedir. Evrişimli sinir ağlarında genelde korelasyon işlemi dikkate alınmaktadır. Giriş verisinin (örneğin bir görüntü işareti) tek kanallı olduğu durumlarda bu işlem basitçe yapılabilir. Fakat giriş verisi farklı formatlarda ve farklı kanal sayısına sahip olabilmektedir. Çıkış işaretinin kanal sayısı ile uygulanan filtre sayısı birbirlerine eşit olmaktadır. Giriş görüntüsünde kullanılan filtre, esasen geri yayılımla güncellenen ağırlıklar matrisidir. Çıkış matrisine, skaler bir b (bias) değeri eklendikten sonra aktivasyon fonksiyonu uygulanır. Sobel, Prewitt, Gabor gibi geleneksel metotlarda, görüntü, filtre ile evrişim işlemine tabii tutularak oluşturulan çıkış, görüntünün kenar bilgilerini gösterir (Kızrak & Bolat, 2018). Kenarlar çoğunlukla evrişimli bir ağ modelinin ilk katmanında hesaplanmaktadır (Gonzalez & Woods, 1977).



Şekil 10. Evrişim işlemi ve adım kaydırma (Kızrak & Bolat, 2018).


Havuzlama katmanları, evrişim katmanından gelen özellik haritalarından gelen temel bilgileri muhafaza ederek öznelilik haritalarının boyutlarının azalmasını sağlamaktadır. Bu işlem modelin parametre sayısını indirgemekte ve böylece yapılacak işlemin hesaplama maliyeti de azaltılmaktadır. Şekil 11’de, örnek bir havuzlama işlemi gösterilmektedir (Özçelik & Altan, 2021).



Şekil 11. Havuzlama işlemi (Özçelik & Altan, 2021)

Tam bağlantılı katman, geleneksel modellerdeki tam bağlantılı yapay sinir ağı modeline benzerdir. İlk aşamanın çıktısı (tekrarlı olarak konvolüsyon ve havuzlama içerir) tam bağlı katmana beslenir ve nokta çarpımı ağırlık vektörü ve girdi vektörü nihai çıktıyı elde etmek için hesaplanır. Toplu mod öğrenme veya çevrimdışı algoritma olarak da bilinen gradyan inişi, maliyeti tüm bir eğitim veri kümesi üzerinden tahmin ederek kayıp fonksiyonunun değerini azaltır ve model parametrelerini yalnızca bir epoktan sonra günceller; burada bir epok veri kümesinin tamamını işlemeye karşılık gelir. Bu yöntem,

küresel minimumu verir, ancak eğitim veri kümesinin boyutu büyükse ağı eğitmek için gereken süre önemli ölçüde artar. Kayıp fonksiyonunun değerini azaltmaya yönelik bu yaklaşım, yerini stokastik gradyan inişine bırakmıştır (Indolia vd., 2018).




Şekil 12. Tam bağlantı katmanı (Amidi, 2019).

1.4.1. ResNet-50

Residual Neural Network'ün kısaltması olan ResNet'in Türkçe anlamı artık ağlar olup, 2015 yılında daha derin olan ağların eğitimini kolaylaştırmak amacıyla tanıtılan belirli bir sinir ağı türüdür. Referans verilmeyen fonksiyonları öğrenmek yerine, katman girişlerine referansla artık fonksiyonları öğrenerek modelin katmanları açıkça yeniden formüle edilmiştir. Bu artık ağların optimize edilmesinin daha kolay olduğunu ve önemli ölçüde artan derinlikten doğruluk elde edebildiğini gösteren kapsamlı ampirik kanıtlar sunulmuştur. ImageNet veri setinde, 152 katmana kadar derinliğe sahip artık ağları değerlendirilmiştir. Bu artık ağların bir topluluğu dikkate alınarak, ImageNet test setinde %3,57 hata elde edilmiştir (He vd., 2016).

Resnet modeli evrimsel sinir ağlarındaki performans düşümü sorununu çözmeyi amaçlamaktadır. Performans düşümü sorunu, Resnet'in makalesinde şu şekilde ifade edilmektedir (URL-6, 2024): “Derin ağlar yakınsamaya başladığı zaman, bozulma sorunu ortaya çıkar ve ağ derinliği arttıkça, verimliliği doymuş seviyeye ulaşır, fakat sonrasında hızlı bir düşüş eğilimi gösterir.”

Resnet bu sorunu çözmek için katmanlar arasına kısayol bağlantıları ekleyerek ağ derinleştikçe ortaya çıkan bozulmayı önler. Bu kısayollar, bir veya daha fazla katmanı




Şekil 14. ResNet mimarisine ait 3 katmanlı darboğaz bloğu görüntüsü (He vd., 2016).

1.4.2. MobileNet

Google tarafından 2017 yılında önerilen mobilenet mimarisi derin öğrenme çalışmalarında sıkça kullanılan bir evrişimli sinir ağı modelidir. Mobil ve gömülü sistemlerde kullanılmak amacıyla geliştirilen MobileNet, diğer modellere göre daha az parametreye sahip olmasına karşın, başarılı sonuçlara erişme kapasitesine sahiptir. Derinlemesine ayrılabilir evrişimsel katmanlar kullanılan bu ağ, evrişimsel katmalarda iki boyutlu filtre, iki ayrı evrişim filtresi şeklinde görüntü üzerine uygulanmaktadır (Çetiner, 2022; Demir, 2022). MobileNet modelinin üç farklı mimari türü bulunmaktadır. Bunlar, MobileNetV1, MobileNetV2 ve MobileNetV3'tür.

MobileNetV3, NetAdapt algoritması ile tamamlanan donanıma duyarlı ağ mimarisi aramasının (NAS) bir kombinasyonu aracılığıyla, akıllı cihazlara uyarlanmıştır ve daha sonra yeni mimari geliştirme yollarıyla optimize edilmiştir. Otomatik arama algoritmalarıyla model tasarımının genel durumunun nasıl iyileştirilebileceği araştırılmıştır. Bu süreç aracılığıyla piyasaya sürülmek üzere iki yeni MobileNet modeli oluşturulmuştur: Yüksek ve düşük kaynak kullanım durumlarını hedefleyen MobileNetV3-Large ve MobileNetV3 Small (Şekil 15'te görüldüğü gibi). Bu modeller daha sonradan nesne algılama ve anlamsal bölümlendirme görevlerine de uygulanmıştır. Mobil sınıflandırma ve segmentasyon işlemleri bazı kabul edilebilir sonuçlara ulaşılmıştır. MobileNetV3-Large modeliyle ImageNet sınıflandırmasında %3,2 oranında iyileştirme yapılmıştır.



Şekil 16. Model boyutu ve ImageNet doğruluğu görüntüsü (Tan & Le, 2019).

Şekil 16, EfficientNet'lerin diğer ConvNet'lerden önemli ölçüde daha iyi performans gösterdiği ImageNet performansını özetlemektedir. Özellikle, EfficientNet-B7 mimarisi ImageNet sınıflandırma probleminde 66M parametre hesaplama yükü ile %84.4'lük doğruluğa ulaşmıştır.

Tablo 2. EfficientNetB0 Ağı (Tan & Le, 2019)


Aşama i	Operatör F_i	Çözümleme $H_i \times W_i$	#Kanallar C_i	#Katmanlar L_i
1	Conv3X3	224 X 224	32	1
2	MBConv1, k3x3	112 X 112	16	1
3	MBConv6, k3x3	112 X 112	24	2
4	MBConv6, k5x5	56 X 56	40	2
5	MBConv6, k3x3	28 X 28	80	3
6	MBConv6, k5x5	14 X 14	112	3
7	MBConv6, k5x5	14 X 14	192	4
8	MBConv6, k3x3	7 X 7	320	1
9	Cov1x1& Pooling & FC	7 X 7	1280	1

Tablo 2, EfficientNet-B0 mimarisini göstermektedir. Ana yapı taşı, mobil ters çevrilmiş darboğaz MBConv'dur ve buna sıkıştırma ve uyarma optimizasyonuna da eklenir. MBConv'da, bloklar önce kanalları genişleten, sonra bunları sıkıştıran bir katmandan oluşur. Böylece daha az kanala sahip katmanlar atlamalı bir şekilde bağlanmaktadır.

1.5. Transfer (Aktarmalı) Öğrenme

Geleneksel bir makine öğrenmesi paradigması olan transfer öğrenme, yapay sinir ağları ile çözülmesi gereken problemlerde yaygın olarak kullanılmaktadır. Bir yapay sinir ağını sıfırdan eğitmek başlıca 2 nedenden dolayı zordur. İlk neden bir yapay sinir ağına maliyet yüzeyi konveksiyonel değildir. Bu nedenle mantıksal bir yakınsama için iyi bir başlangıç genişliği seti gerektirir. İkinci neden sinir ağlarının eğitimi için mevcut özgül veriler yetersizdir ve çözmeyi amaçladığı problem, bir sinir ağı çözümlemesi gerektirecek kadar karmaşıktır (Pattanayak, 2019).

Yukarıda belirtilen her iki sorun da transfer öğrenme ile çözülür. ImageNet veya CIFAR gibi çok sayıda etiketlenmiş veri setleri üzerinde önceden eğitilmiş modeller, kapsamı daha az veri seti üzerinden eğitimi başlatmak için iyi bir başlangıç ağırlığına sahip olacaktır ve böylece bu ağırlıklar eldeki verilere göre ince ayarlanabilecektir. Diğer bir ifadeyle, daha az miktarda veri üzerinde karmaşık bir model eğitmekten kaçınmak için önceden eğitilmiş yapay sinir ağlarından karmaşık özellikler çıkarıp daha sonra nispeten daha basit bir modeli eğitmek için bu özellikler kullanılabilir (Şekil 17'de görüldüğü gibi).



Şekil 17. Evrişimli sinir ağı modelinde transfer öğrenme: a) Hedef veri kümesi küçük ve kaynak veri kümesine benzer (öznitelik öğrenme bloğunu dondurma), b) Hedef veri kümesi büyük ve kaynak veri kümesine benzer (öznitelik öğrenme bloğunun %60-80 arasını dondurma), c) Hedef veri kümesi küçük ve kaynak veri kümesinden çok farklı (öznitelik öğrenme bloğunun %30-50 arasını dondurma) ve d) Hedef veri kümesi büyük ve kaynak veri kümesinden çok farklı (derin sinir ağı yeniden eğitime) (Elgendy, 2020).


Transfer öğrenme araştırmalarının ana motivasyonu; insan öğrenmesinden gelmektedir. İnsanlar, önceden öğrendiği bilgiyi, yeni problemleri çözmek için daha hızlı ve verimli bir şekilde kullanırlar. Kaynak ve hedef derin öğrenme tekniklerinde sıkça kullanılan iki kavramdır. Basit bir şekilde açıklamak gerekirse transfer öğrenme işlemi kaynak çıktısındaki ağırlıkların hedef girdisine aktarılmasıdır (Türkdamar vd., 2023).

1.6. Dikkat Mekanizması

Dikkat mekanizması, Bahdanau ve arkadaşları (Bahdanau, Cho & Bengio) tarafından doğal dil işleme (NLP) için kodlayıcı-kod çözücü tabanlı yapay sinirsel makine çeviri sistemi olarak sunuldu. Sonraki yıllarda, dikkat mekanizmaları, çoğu bilgisayarlı görü görevinde ince ayrıntılı özelliklerin belirlenmesinde yardımcı olmakla beraber görüntü sınıflandırılması, anlamsal bölümlendirme ve nesne lokalizasyonu gibi işlemlerde yaygın olarak kullanılmaktadır (He vd., 2020).

Dikkat mekanizması, aynı zamanda derin sinir ağlarında ağdaki belirli önemli özelliklere odaklanırken diğerlerini görmezden gelme işlemine denir (Bakınız Şekil 18). Dikkat mekanizması, son yıllarda derin öğrenme araştırmalarında kullanılan en önemli atılımlardan biridir. Özellikle üzerinde çalışılan bir diğer konu da görsel dikkattir. Örneğin, Zhou ve diğerleri (Zhou vd., 2018) CNN'lerin derinliğini ve giriş görüntüsünün

çözünürlüğünü kademeli bir şekilde artıran çok hücreli bir mimari önermiştir. Bu yaklaşım eğitim süresini azaltmış ve sınıflandırma performansını artırmıştır. Tarama performansını daha da artırmak amacıyla fundus görüntülerinde DR taraması için dikkat mekanizmasını kullandılar. Bilgisayarla görü yaklaşımlarında, kanal dikkati, uzamsal dikkat, zamansal dikkat ve dal dikkati gibi farklı dikkat mekanizmaları vardır.



Şekil 18. Evrişimli sinir ağı modelinde dikkat mekanizması kullanma: a) Özgün fundus görüntüsü ve b) Dikkat mekanizmasıyla elde edilen sonuç görüntüsü (Li vd., 2019).

1.6.1. Kategorik Dikkat Bloğu

Kategorik dikkat bloğu, 2020 yılında He ve arkadaşları (He vd., 2020) tarafından L sınıflı ince ayrıntılı DR sınıflandırma görevini geliştirmek için fundus görüntülerinden ayırt edici bölgeleri öğrenmek üzere tasarlanmıştır. $F_{CAB-IN} \in R^{H \times W \times R'}$ gelen bir özellik haritası iç $F' \in R^{H \times W \times kL}$ özellik haritalarını üretmek için, ilk önce onu 1×1 evrişimli katmanla beslenir; burada k , her sınıf için ayırt edici bölgeleri tespit etmek için gereken kanal sayısıdır. Bir sınıftaki tüm k , özellik haritalarını farklı ayırt edici bölgeleri öğrenmeye zorlamak için, eğitim sırasında özelliklerin yarısı rastgele kaldırılır ve değerlerini sıfıra ayarlanır ve ardından her özellik haritasındaki özelliklerin yarısını koruyan $F'' \in R^{H \times W \times k}$ 'yi alabilir. Çıkarım sırasında bırakma işlemini kaldırılır ve k özellik haritalarındaki tüm özellikler tahmin için kullanılır. Ardından, $S = \{S_1, S_2, \dots, S_L\}$ puanlarını aşağıdaki formüle göre her sınıf için hesaplanır:

$$S_i = \frac{1}{k} \sum_{j=1}^k GMP(f''_{i,j}), i \in \{1, 2, \dots, L\}, \quad (1)$$

GMP, diğer bir ifadeyle global maksimum havuzlama ve $f''_{i,j}, F''$ 'den i 'inci sınıf j 'inci özellik haritasını temsil eder. S_i , her sınıf için özellik haritalarının önemini ölçer. CAB'nin global dikkat bloğuyla uyumlu olması gerektiğini unutmamalıdır. Böylece DR sınıflandırması, iki tamamlayıcı blok türü birleştirilerek daha iyi temsil edilebilir. S , doğrudan kategori dikkati olarak kullanılmaz ve her sınıf için özellik haritasını elde etmek amacıyla F'' 'ye kategori bazında kanallar arası ortalama havuzlama işlemi uygulanır:

$$F'_{i-avg} = \frac{1}{k} \sum_{j=1}^k f'_{i,j}, i \in \{1, 2, \dots, L\}, \quad (2)$$

Burada $f'_{i,j}$, F'' 'den i 'inci sınıf için j 'inci özellik haritasını temsil eder ve $F'_{i-avg} \in R^{H \times W \times 1}$, i 'inci sınıf için anlamsal özellik haritasını belirtir. Daha sonra, $ATT_{CAB} \in R^{H \times W \times 1}$ kategorisindeki dikkat şu şekilde elde edilir:

$$ATT_{CAB} = \frac{1}{L} \sum_{i=1}^L S_i F'_{i-avg} \quad (3)$$


ATT_{CAB} , DR derecelendirmesi için bilgilendirici olan ayırt edici bölgeleri vurgular. Son olarak, F_{CAB-IN} özellik haritaları, ATT_{CAB} kategorisinin dikkatine göre, $F_{CAB-OUT}$ özellik haritalarına dönüştürülebilir:

$$F_{CAB-OUT} = F_{CAB-IN} \otimes ATT_{CAB} \quad (4)$$

Burada $\otimes$ eleman bazında çarpmayı belirtir ve $F_{CAB-OUT}$, DR derecelendirmesi için F_{CAB-IN} 'deki ayırt edici bölgeleri geliştiren CAB'nin çıktı özellik haritalarıdır.

1.6.2. Global Dikkat Bloğu

Global dikkat bloğu (GAB), kanal dikkati ve uzamsal dikkatten oluşur ve tek dallı yapıyı benimser (Woo vd., 2018). Kanal dikkati için, her bir özellik kanalının önemini belirten ve daha az bilgilendirici kanalları bastıran kanal bazında dikkat ağırlıklarını öğrenerek bir özellik seçici görevi görür. Uzamsal dikkat için, kanal dikkatinin tamamlayıcısı olan uzamsal dikkat ağırlıklarının öğrenilmesi yoluyla her uzamsal konumun önemine işaret eder. Örneğin, kanal dikkati görüntü sınıflandırılması için iyi bir seçenекken uzamsal dikkat, semantik segmentasyon ve nesne tespiti gibi yoğun tahmin görevleri için çok uygundur. Şekil 19’da global dikkat bloğuna ait yapı verilmektedir.



Şekil 19. Global dikkat bloğunun yapısı (He vd., 2020).

1.7. Çalışmada Kullanılan Metrikler

Bu çalışmada kullanılan modellerin başarımlarını değerlendirmesinde ikinci dereceden karesel ağırlıklı Cohen Kappa skoru ve doğruluk metriği kullanılmıştır.

Kappa skoru, iki derecelendirme arasındaki anlaşmayı ölçen bir yöntemdir. İkinci dereceden ağırlıklı Kappa skoru, insan değerlendirici tarafından atanan puanlar ile tahmin edilen puanlar karşılaştırılarak hesaplanır. Bu ölçü, değerlendiriciler arasında tam görüş ayrılığı -1 ile değerlendiriciler arasında tam görüş birliği 1 arasında değişir. Karesel ağırlıklı Kappa ($\mathcal{K}$) aşağıdaki gibi tanımlanmıştır.

$$\mathcal{K} = 1 - \frac{\sum_{i=1}^k \sum_{j=1}^k W_{ij} O_{ij}}{\sum_{i=1}^k \sum_{j=1}^k W_{ij} E_{ij}}, \quad (5)$$

Burada k kategorilerin sayısıdır, O_{ij} ve E_{ij} sırasıyla gözlemlenen ve beklenen matrislerdeki öğelerdir. Karesel ağırlıklı Kappa için ifadedeki ağırlık W_{ij} aşağıdaki şekilde hesaplanır.

$$W_{ij} = \frac{(i-j)^2}{(k-1)^2}, \quad (6)$$

Cohen Kappa skoru, özellikleri nedeniyle araştırmacıların bu oranı dikkatle yorumlaması gerekmektedir. Örneğin, aynı anlaşma yüzdesine sahip ve farklı derecelendirme oranlarına sahip iki değerlendirici çifti ele alırsak, bunun Kappa oranını büyük ölçüde etkileyeceğini bilmeliyiz. Diğer bir sorun ise kod sayısı: Kod sayısı arttıkça Kappa da artıyor. Yukarda bahsedilen bu durumların tümü Kappa'yı analiz edilmesi gereken bir değişken oran haline getirir. Kappa oranını kullanmamızın ana nedeni, doğrulama etiketlerine ve test veri kümesine erişimimizin olmamasıdır.

Doğruluk, ikili bir sınıflandırma durumunda, modelin performansını değerlendirmek için gerekli olan ana metriklerden biri olmakla birlikte modelin doğru tahmin ettiği örnek sayısının veri kümesinde bulunan tüm örnek sayısına oranıdır (URL-8, 2024). Bu metriğin başarımlı ölçütünün hesaplanması için Tablo 3'teki karışıklık matrisinin kullanılmaktadır.

Tablo 3. Karışıklık Matrisi

		Tahmin Edilen Sınıf	
		Pozitif	Negatif
Doğrusınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (7)$$

Doğru Pozitif (DP), doğru tahmin edilen örnek sayısı iken; DN doğru biçimde reddedilen örneklerin sayısıdır. Yanlış pozitif (YP), sonucun gerçekte negatif iken yanlışlıkla pozitif tahminin yapılmasıdır; yanlış negatif (YN), sonucun gerçekte pozitif iken yanlışlıkla negatif biçimde tahmin edilmesidir.

Kesinlik, bir sınıflandırma modelinin pozitif olarak tahmin ettiği örneklerin gerçekte ne kadarının pozitif olduğunu ölçen metriktir. Kesinlik metriği aşağıdaki gibi hesaplanır.

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (8)$$

Geri Çağırma, doğru şekilde sınıflandırılmış pozitiflerin toplam gerçek pozitiflere bölünmesi ile hesaplanan metriktir (Memiş, Enginoğlu & Erkan, 2019).

$$\text{Geri Çağırma} = \frac{DP}{DP+YN} \quad (9)$$


F1 skoru, kesinlik ve geri çağırma metriklerinin harmonik ortalaması alınarak bulunur (Memiş, Enginoğlu & Erkan, 2019).

$$\text{F1 skoru} = \frac{2(\text{Kesinlik} * \text{Geri Çağırma})}{\text{Kesinlik} + \text{Geri Çağırma}} = \frac{2DP}{2DP+YP+YN} \quad (10)$$

2. YAPILAN ÇALIŞMALAR

2.1. Görüntü Ön İşleme

Görüntülerde ışık ve boyut farklılığı, çözünürlük, kırpma türü, yakınlaştırma düzeyi gibi özelliklerin neden olduğu sorunları çözmek amacıyla birtakım görüntü ön işleme adımları uygulanmıştır. Ön işlemede görüntü kırpma işlemi ile yeniden boyutlandırma işlemi yapılmıştır. Ayrıca ön işleme de görüntü verilerini basitleştirmek ve bazı algoritmalarda hesaplama gereksinimini azaltabilmek için görüntü gri tonlamaya dönüştürülmüştür. Yeniden boyutlandırma işlemi ile makine öğrenimi algoritmalarının düzgün çalışması için görüntüler tekdüze bir boyuta yeniden boyutlandırılmıştır. Bu işlem için OpenCv kütüphanesine ait *resize* fonksiyonu kullanılmıştır. Daha sonra göz şeklinden dolayı da dairesel kırpma uygulanmıştır. Süzgeçleme yaklaşımı (URL-9, 2024) ile Gauss yumuşatma filtresi kullanılarak yapılan keskinleştirme işleminin ardından dairesel kırpma işlemleri uygulanarak giriş görüntülerinde iyileştirmeler yapılmıştır. Bu iyileştirmeler sayesinde hastalığa ait bazı lezyonlar daha belirgin görülmektedir. Yapılan işlem basamaklarına ait örnek çıktılar Şekil 20’de belirtilmektedir. Şekil 20.a’da ön işleme yapılmamış bir fundus görüntüsü verilmiştir. Şekil 20.b’de ise, kan damarları netleştirilerek ilgili görüntünün dairesel biçimde kırpılmış haline yer verilmiştir.




Şekil 20. Fundus görüntülerinde ön işlemler: a) giriş görüntüsü ve b) keskinleştirilmiş ve dairesel biçimde kırpılmış görüntü.

2.2. Veri oğaltma

Veri oğaltma (artırma), orijinal veri setlerini herhangi bir deęiřime maruz bırakmadan veri setlerinde bulunan görüntü vb. verilerin sayısının oğaltılması işlemidir. Burada eřitli görüntü işleme teknikleri kullanılarak veriler artırılmaktadır. Bu teknikler; çevirme, döndürme, kırpma, kaydırma ve renk tonu deęiřtirmedir (Kürşad & KOCER, 2022) (Şekil 21’de görüldüğü gibi).


CNN modelleri üzerinde eğitim yapılırken artırılmış bu veri kümesi göz önünde bulundurulmuştur. Veri artırma, sadece örnek sayısını artırmakla kalmayıp aynı zamanda derin öğrenme modeli için görünmeyen verilerin örneğini artırdığı için verilerde eřitlilięi de beraberinde getirmiş olur. Veri kümesindeki sınıf sayılarını eşit şekilde dengelemek ve artırılmış veri kümesi üzerinde gerekli tahmin veya sınıflandırma vazifesini yerine getirmek için veri kümesinin herhangi bir sınıfına veya veri kümesinin tamamına eřitli veri artırma teknikleri uygulanabilir (Chandola vd., 2021).

Bu tarz işlemler, genellikle veri kümesindeki dengesizlik sorununu özmek ve veri miktarının kısıtlı olduğı durumlarda aşırı uydurmayı önlemek için kullanılmaktadır.




Şekil 21. Fundus görüntüsü oğaltma örnekleri: a) Özgün görüntü, b) Yatay çevrilmiş görüntü ve c) Kırpılmış görüntü.

Örneğin Şekil 22 ve Şekil 23 eğitim veri kümesinde yer alan her bir sınıfa ait toplam fundus görüntü sayısını vermektedir. 0,1, 2, 3, 4 etiketli sınıflara ait sırasıyla 1805 ,370, 999, 193,295 adet görüntü vardır. Şekiller incelendiğinde veri kümesinin dengesiz olduğı görülmektedir. Bu nedenle, veri oğaltma işlemi kaçınılmaz hale gelmektedir. Fakat bu tez alışmasında veri oğaltma işlemi modelin eğiminde aşırı uydurma sorununu gidermek için gerçekleştirilmiştir.



Şekil 22. APTOS-2019 eğitim veri kümesinde her bir sınıfa ait fundus görüntülerinin sayısını gösteren çubuk grafiği.



Şekil 23. APTOS-2019 eğitim veri kümesinde her bir sınıfa ait fundus görüntülerinin sayısını gösteren pasta dilimi grafiği.

2.3. CNN Modelleri

Fundus görüntülerinde doğru bir sınıflandırma yapabilmek için her bir görüntünün uygun bir derin öğrenme modeli içerisinde değerlendirilmesi gerekmektedir. Son zamanlarda literatürde CNN tabanlı ve görü dönüştürücü tabanlı birçok modelin geliştirildiği bilinmektedir. Görüntü sınıflandırma işlemlerinde CNN tabanlı modellerin, görü dönüştürücü tabanlı modellere nazaran genel anlamda daha fazla tercih edildiği görülmektedir. Bunun nedeni, görü dönüştürücü tabanlı modellerin küresel öznitelik bilgilerine dikkat etmesine ve daha iyi performans göstermelerine rağmen, eğitim aşamasında veri setlerinin daha büyük olmasına ihtiyaç duyarlar. Ancak bu tür

dönüştürücülerin dezavantajı çok fazla parametre sayısına sahip olmasıdır. Öte yandan CNN ve görü dönüştürücülerini literatürde birlikte kullanan biçimlendirici modeller de geliştirilmiştir. Ayrıca literatürde, CNN modellerindeki parametre sayısının azaltılması ve bu modellerin performansında artışın görülmesi için pek çok araştırmanın yapıldığı bilinmektedir. Bu durumda modellerin hem genişlemesine hem de derinlemesine optimize edilmesi gerekli olmaktadır. Diğer yandan modelin en iyi biçimde eğitilmesi için gradyan yok olması veya patlaması gibi problemlerin de ortadan kaldırılması gerekmektedir. Bu sebepten dolayı bazı modellerde katmanlar arasında artık bağlantılar olarak da bilinen atlamalı bağlantı yaklaşımları literatüre kazandırılmıştır. Bu yaklaşımların geliştirilmesinde, geleneksel görüntü işlemedeki toplamsal gürültülerin modellemesi yöntemi dikkate alınmıştır. Sayısal türev alma işleminde sıfır değerli sonuçların elde edilmesini önlenmek için burada CNN modelindeki bir bloğun girdisi çıktısına aktarılmaktadır.

Çıktı Görüntüsünün yumuşatılması için gürültü azaltma işlemlerinde görüntü alçak geçiren bir süzgeçten geçirilir ve yumuşatılmış görüntüye sayısal türev alma işlemi uygulandığında sıfır değerli sonuçların ortaya çıktığı görülecektir. Benzer şekilde bir CNN bloğunda da bu tür sorunlar oluşmaktadır. Bu çalışmada bu çeşit problemleri gidererek fundus görüntülerinin sınıflandırılması amacıyla atlamalı bağlantı yaklaşımını hesaba katan ResNet50 modeli (He vd., 2016) kullanılmıştır. Üstelik son dönemlerde birçok CNN modelinde görüntü sınıflandırmasını iyileştirmek için dikkat modüllerinin de kullanıldığı görülmektedir. Uzamsal tabanlı dikkat modülleri uzamsal ilişkileri kullanarak gerekli özniteliklerin nerede olduğu hakkında bilgi verirken kanal tabanlı dikkat mekanizmasında, öznitelik çıkarımı göz önünde bulundurulduğunda, girdi görüntüsünde neyin anlamlı olduğu hakkında bilgi vermektedir. Örneğin bu çalışmada kanal tabanlı bir dikkat mekanizması içeren EfficientNet-B0 ve MobileNetV3-Large modellerinden (Tan & Le, 2019; Howard vd., 2019) yararlanılmıştır.

Beş Diyabetik Retinopati sınıfının, renk ve doku bakımından birbirine çok benzemesi ve fundus görüntülerindeki bazı lezyonların çok küçük boyutlu olması nedeniyle sınıflandırma görevi sırasında bunları karıştırmak kolaydır, bu yüzden sınıflandırma işlemi de zorlaşmaktadır. Bu çalışmada, bu tür problemleri çözmek amacıyla hem fundus görüntülerinde ayrıntılı lezyon bilgilerini muhafaza eden hem de gereksiz bilgileri (benzer renk ve doku) bastırarak global öznitelikleri öğrenebilen global dikkat bloğu kullanılmıştır. Bununla birlikte, normal olmayan fundus görüntüleri, bütün görüntülerin sadece küçük bir bölümünü oluşturduğu için, farklı evreler arasındaki DR veri dağılımı çok fazla dengesizlik

oluřturmaktadır. Öznitelik haritalarının her kanalının belli bir öznitelik modelini örneklendirmesi; farklı DR evrelerinde farklı davranıřlar sergilemesini, dolayısıyla farklı kategorilerin ayırımından yararlanmasını saęlamaktadır. Bu tarz problemleri çözmek için ise kolay ama etkili olan bir kategorisel dikkat bloęu, kullanıldıęı sınıfa ait öznitelikleri öęrenebilmekte ve her DR evresi için belli miktarda öznitelik kanalını kullanabilmektedir. Dolayısıyla bu çalıřmamızda kullanıldıęımız bu dikkat mekanizması sayesinde aynı sınıfa özgü tüm öznitelik kanalları ayırt edici olduęundan fazla sayıdaki öznitelik kanalı azaltılmıř olmaktadır (He vd., 2020).




3. DENEYSEL ÇALIŞMALAR, BULGULAR VE İRDELEME

Şekil 23'te gösterildiği gibi, çalışmamızda kullandığımız APTOS-2019 veri setine ait eğitim görüntü sayısı 3662 iken test görüntü sayısı 1928'dir. Veri setinde yer alan test ve eğitim görüntülerinin sınıflara göre dağılım oranları benzerdir. Ek olarak eğitim veri setinin %20'lik kısmı doğrulama işlemi için kullanılmıştır. CNN modellemelerinde aktarmalı öğrenme yaklaşımı dikkate alınmıştır. Eğitim ve doğrulama işlemlerinde grup büyüklüğü 8 iken test için grup büyüklüğü 1 olarak belirlenmiştir. Bu uygulamada açık kaynak kodlu bir makine öğrenimi kütüphanesi olan Keras'tan yararlanılmıştır. Uygulamalar için Google Colab ortamı kullanılmıştır. Tüm modellerde öznitelik belirleme işleminde yer alan eğitim adımındaki döngü sayısı 40 olarak belirlenmiştir. Modelde Adam optimizasyon yaklaşımı kullanılarak değişken öğrenme oranı başlangıç değeri 0.005 olarak seçilmiştir. Çalışmada yer alan diğer hiper parametreler orijinal çalışmalarda kabul edildiği şekliyle kullanılmıştır. (He vd., 2020).


Resnet50, MobileNetV3-Large ve EfficientNetB0 modellerine ayrıca kategorisel dikkat mekanizması, yani CABNET modülü (He vd., 2020) eklenmiştir. CABNET modülünde DR kategorisi için özellik kanallarının sayısı olan k hiper parametresi 5 olarak ayarlanıyor. Bu parametrenin etkisi bir çalışmada analiz edilmiş, k değeri arttıkça CABNet'in DR sınıflandırma performansının arttığını ve k değeri 5 olarak ayarlandığında en iyi derecelendirme sonuçlarını elde ettiğini gösterilmiştir. Ancak k değeri daha da artırıldığında modelin sınıflandırma performansı düştüğü görülmüştür. Bunun başlıca nedeni CABNet'teki aşırı uyum ve öznitelik fazlalığıdır. CABNET modülünden sonra ise aşırı uydurmayı önlemek için modellerin çıkışına aşağıda verilen kod bloğu eklenmiştir.

```
x = Dropout(0.5)(x)
x = Dense(512, activation='relu')(x)
x = Dropout(0.5)(x)
```



Şekil 24. APTOS-2019 eğitim veri kümesindeki eğitim ve test görüntülerinin oranlarını gösteren pasta dilimi grafiği

Bu çalışmada kullanılan CNN modeli Şekil 25’te gösterilmektedir.



Şekil 25. Bu tezde kullanılan Evrişimsel Sinir Ağı Modeli.

Modellerin sınıflandırma performanslarını ölçmek için doğruluk, Kappa, kesinlik, geri çağırma, F1 Skoru değerlerine ait ölçülebilir sonuçlar Tablo 4 ve 5’te verilmiştir. Tablo 4’te modellerin CABNet modülü eklenmeden önceki sonuçları yer almaktadır. Eklenen CABNet modülünde kanal dikkat bloğunun daha fazla özneliliğin öğrenilmesini sağladığı ve daha az önemli öznelilikleri bastırdığı görülmektedir. Ayrıca uzamsal dikkat bloğunun eklenmesi ile de bu özneliliklerin önem derecesinin elde edildiği sonucuna ulaşılmıştır. Bununla birlikte kategori bazında sınıfa özgü dikkat bloğuyla daha etkili öznelilik haritaları oluşturulmaktadır. Tablo 5’te modellere CABNet modülü eklendikten sonraki sonuçlar bulunmaktadır. Aşağıdaki tablolardan test veri kümesi için elde edilen nicelik sonuçları incelendiğinde, modellere eklenen CABNet modülü ile performansların iyileştirildiği net bir şekilde görülmektedir.

Tablo 4. Orijinal CNN Modellerinde kullanılan Test Veri Kümesi için elde edilen nicelik sonuçları


Model	Kappa	Doğruluk	Kesinlik	Geri Çağırma	F1 Skoru
ResNet50	0.853	0.795	0.830	0.795	0.808
MobileNetV3-Large	0.885	0.827	0.843	0.827	0.832
EfficientNet-B0	0.888	0.821	0.837	0.821	0.827

Tablo 5. Dikkat Mekanizması eklentili CNN Modellerine ait test veri kümesinin nicelik sonuçları


Model + Modül + Dropout	Kappa	Doğruluk	Kesinlik	Geri Çağırma	F1 Skoru
ResNet50	0.881	0.809	0.838	0.809	0.819
MobileNetV3-Large	0.891	0.840	0.848	0.840	0.843
EfficientNet-B0	0.899	0.832	0.845	0.832	0.837

Aşağıdaki şekillerde kullanılan modellere ait doğruluk ve kayıp değerlerinin grafikleri verilmiştir.

Şekil 26.a-b’de ResNet50 modeline ait grafiksel sonuçlar gösterilmiştir. Burada sonuç grafiklerinden modelin aşırı uydurma işlemini önlemek için modelin eğitimde erken durdurma işlevi de göz önüne alınabilir. Diğer taraftan doğrulama veri setine ait elde edilen grafiklerde döngünün başlangıç aşamasında biraz dalgalanma sorunu ortaya çıkmaktadır. Bu sorun öğrenme oranının biraz fazla değere setlenmesinden kaynaklanmaktadır. Daha sonraki epok değerlerinde bu sorunun ortadan kalktığı verilen grafiklerden gözlemlenmektedir.



(a)



(b)


Şekil 26. ResNet50 modeline ait eğitim veri seti için elde edilen grafikler: a) Doğruluk grafiği ve b) Kayıp fonksiyonu grafiği.

Şekil 27.a-b’de ResNet50 modeline CABNet modülünün ve bırakma katmanlarının eklenmesi duruma ait grafiksel sonuçlar verilmiştir. Burada sonuçlardan da görülebileceği gibi, doğrulama veri setine ait elde edilen grafiklerde döngünün başlangıç aşamasında biraz dalgalanma sorunu oluşmaktadır. Bu sorun öğrenme oranının biraz fazla değere ayarlanmasından ortaya çıkmaktadır. Daha sonraki döngü değerlerinde bu sorunun ortadan kalktığı verilen grafiklerden anlaşılabılır.

Benzer şekilde, EfficientB0, EfficientB0 + CABNet + Dropout, MobileNetV3Large ve MobileNetV3Large + CABNet + Dropout modellerine ait grafiksel sonuçlar sırasıyla Şekil 28.a-b, Şekil 29.a-b, Şekil 30.a-b ve Şekil 31.a-b’de verilmiştir. Bu sonuçlardan da görülebileceği gibi özgün modeller modifiye edilerek daha iyi performanslar elde edilmiştir.




(a)




(b)

Şekil 27. ResNet50 + CABNet + Dropout modeline ait eğitim veri seti için elde edilen grafikler: a) Doğruluk grafiği ve b) Kayıp fonksiyonu grafiği.




(a)



(b)



Şekil 28. EfficientB0 modeline ait eğitim veri seti için elde edilen grafikler: a) Doğruluk grafiği ve b) Kayıp fonksiyonu grafiği.




(a)

Şekil 29. EfficientB0 + CABNet + Dropout modeline ait eğitim veri seti için elde edilen grafikler: a) Doğruluk grafiği ve b) Kayıp fonksiyonu grafiği.

Şekil 29' un devamı



(a)




(b)

Şekil 30. MobileNetV3Large modeline ait eğitim veri seti için elde edilen grafikler: a) Doğruluk grafiği ve b) Kayıp fonksiyonu grafiği.




(a)



(b)

Şekil 31. MobileNetV3Large + CABNet + Dropout ait eğitim veri seti için elde edilen grafikler: a) Doğruluk grafiği ve b) Kayıp fonksiyonu grafiği.


Şekil 32, Şekil 33, Şekil 34, Şekil 35, Şekil 36 ve Şekil 37’de ise, sırasıyla ResNet50, ResNet50 + CABNet + Dropout, EfficientB0, EfficientB0 + CABNet + Dropout, MobileNetV3Large ve MobileNetV3Large + CABNet + Dropout modellerine ait diyabetik retinopatinin seviyelerinin kestirimi için hata matris değerleri verilmiştir. Şekillerden de görülebileceği gibi, diyabet hastası olmayan, diğer bir ifadeyle ilk seviyenin kestirim değeri oldukça yüksektir. İkinci sırada ise, orta düzeyde diyabetik retinopati hastalığı olanların kestirimi en iyidir. Bu sıralamayı genelde hafif düzeyde diyabetik retinopati hastalığı olanlar, ciddi düzeyde diyabetik retinopati hastalığı olanlar ve körlük düzeyinde diyabetik retinopati hastalığı olanlar izlemektedir.




Şekil 32. ResNet50 modeline ait diyabetik retinopatinin seviyelerinin kestirimi için elde edilen hata matrisi.



Şekil 33. ResNet50 + CABNet + Dropout modeline ait diyabetik retinopatinin seviyelerinin kestirimi için elde edilen hata matrisi.




Şekil 34. EfficientB0 modeline ait diyabetik retinopatinin seviyelerinin kestirimi için elde edilen hata matrisi.




Şekil 35. EfficientB0 + CABNet + Dropout modeline ait diyabetik retinopatinin seviyelerinin kestirimi için elde edilen hata matrisi.

Şekil 34 ve Şekil 35 hata matrisleri karşılaştırıldığında 2 etiketli Moderate sınıfındaki doğru tahmin sayısı 154'ten 162'ye çıkmış böylece iyileşme görülmüştür. 3 etiketli Severe sınıfında da ufak miktarda bir iyileşme görülmektedir. 2 modelin hata matrisinde de sınıflar en çok 2 etiketli Moderate sınıfı ile karıştırılmaktadır. 3 etiketli Severe sınıfı ile 4 etiketli Proliferative sınıfı arasındaki karışıklığın azalması için DR'nin ileriki aşamalarında bu iki sınıfa ait daha fazla örnek eklenirse model daha hassas sınıflandırma yapabilir.



Şekil 36. MobileNetV3Large modeline ait diyabetik retinopatinin seviyelerinin kestirimi için elde edilen hata matrisi.



Şekil 37. MobileNetV3Large + CABNet + Dropout modeline ait diyabetik retinopatinin seviyelerinin kestirimi için elde edilen hata matrisi.

4. SONUÇLAR VE TARTIŞMA

Fundus görüntülerinde diyabetik retinopati tanılarının evrelerinin sınıflandırılmak için CNN modelleri kullanılmaktadır. Bu çalışmada, diyabetik retinopati tanı evrelerini sınıflandırabilmek için mevcut literatürde yer alan “ResNet50, EfficientNetB0 ve MobileNetV3” modelleri modifiye edilmiş ve modifiye edilmiş modelin görüntüleme performansında iyileşme sağlayıp sağlamadığı araştırılmıştır. Çalışma sonuçları, bilinen modellere dikkat mekanizması eklendiğinde performans açısından iyileştirme sağlandığını göstermektedir. Fundus görüntülerinde kabul edilebilir bir sınıflandırma yapabilmek için her bir sınıfta yer alan görüntü sayısının hemen hemen eşit olması gerekmektedir. Fakat, tıbbi görüntü kümelerinin çoğu dengesiz bir dağılıma sahiptir. Veri kümelerindeki dengesizlikten kaynaklanabilecek problemleri giderebilmek için, klasik veri çoğaltma yaklaşımı yerine, bu tezde modellerin sonuna literatürde var olan bir dikkat modülü eklenmiştir. Fakat modellerin eğitimi aşamasında, aşırı uydurmayı önlemek için, kullanılan veri setinde ayrıca yapay olarak veri çoğaltma işlemi gerçekleştirilmiştir.

Çalışmada göz önüne alınan dikkat mekanizması, elde edilen nicel sonuçlardan da görülebileceği gibi performans açısından iyileştirme gerçekleştirmektedir. Fakat bu tür modüller özgün modellere eklenerek parametre sayısını da artırmaktadır. Bu bağlamda eğer geliştirilen model, mobil tabanlı cihazlarda kullanılacaksa, MobileNet modelleri gibi hafif ağırlıklı derin ağ mimarilerinin göz önüne alınması gerekmektedir.

5. ÖNERİLER

Bu tez çalışmasında evrişimli sinir ağları dikkate alınarak fundus görüntülerindeki diyabetik retinopatinin seviyelerinin kestirimi için bir çalışma yapılmıştır. Bu tez çalışmasında her bir sınıfa ait veri setindeki fundus görüntülerinin dengesizliğine bağlı ortaya çıkabilecek sorunları gidermek için bir dikkat mekanizması göz önüne alınmıştır. Diğer taraftan literatürde son zamanlarda yapay görüntü üretme dahil veri çoğaltma işlemleriyle de veri dengesizliği giderilmeye çalışılmıştır. Geliştirilen bu yaklaşımlar dikkate alınarak, fundus görüntülerindeki sınıflandırma başarımlarını artırmaya yönelik ileride bazı araştırmalar yapılması planlanmaktadır. Ayrıca, hafif ağırlıklı bir CNN modeli kullanılarak fundus görüntülerinin sınıflandırılmasına yönelik çalışmalara devam edilecektir. Diğer taraftan literatürde son zamanlarda görü dönüştürücü yaklaşımlarıyla ve hem metin hem de görüntü bilgisini dikkate alan yöntemlerle sınıflandırma performansı açısından daha iyi sonuçlar elde edilebilmektedir. Evrişimli sinir ağlarıyla karşılaştırıldığında, görü dönüştürücülerin avantajı global öznitelik bilgisini yakalayabilmesidir. Fakat bu modeller hem daha fazla parametre içermekte hem de bu modellerin eğitimi daha uzun sürmektedir. Bu yüzden hem evrişimli sinir ağı hem de görü dönüştürücülerin yapısını içeren karma modeller geliştirilmiştir. Ayrıca bu modeller mobil cihazlara adapte edilebilmektedir. Bu bağlamda ileride görüntü sınıflandırma performanslarını artırmak için hafif ağırlıklı bu tür modellerin geliştirilmesine çalışılacaktır.

Görüntü yanında metin bilgisinin de kullanılması görüntü işlemenin yanına bir de doğal dil işleme eklenmiştir. Böylece modellerin performansı oldukça iyileştirilmiştir. Bu tür yaklaşımlarda büyük dil modelleri dikkate alınmaktadır. Fakat bu tür modellerin parametre sayısı oldukça fazladır ve eğitimleri de oldukça fazla zaman almaktadır. Bu yüzden son zamanlarda bu tür dezavantajları ortadan kaldırmak için küçük dil modelleri de geliştirilmeye başlanmıştır. Bu bağlamda ileriki çalışmalarda retina görüntülerinin işlenmesinde küçük dil modellerini dikkate alan çalışmalar da yapılacaktır.

6. KAYNAKLAR

- Afrashi, F. (2016). İndosiyanin Yeşili Anjiyografi. *Güncel Retina*,1(1), 28-31.
- Amidi, A. & Amidi, S. (2019 Nisan, 30). Evrişimli Sinir Ağları El Kitabı VIP. <https://github.com/afshinea/stanford-cs-230-deep-learning/blob/master/tr/cheatsheet-convolutional-neural-networks.pdf>.
- Amin, J.S. & Shanavas, M. (2024, Haziran 3). Fundus imaging techniques for fundus images.National Conference on COMPUTING AND COMMUNICATION TECHNOLOGIES-2016.
- Bagherinezhad, H., Horton, M., Rastegari, M., & Farhadi, A. Label refinery: Improving imagenet classification through label progression. *arXiv* 2018. *arXivpreprint arXiv:1805.02641*.
- Bahdanau, D., Cho, K., & Bengio, Y. (2014). Neural machine translation by jointly learning to align and translate. *arXivpreprint arXiv:1409.0473*.
- Balıkoğlu Yılmaz, M. (2017). Tarayıcı (Scanning) Lazer Oftalmoskop. *Güncel Retina*, 1(1), 18-21.
- Chandola, Y., Virmani, J., Bhadauria, H. S., & Kumar, P. (2021). *Deep learning for chest radiographs: Computer-aided classification*. Elsevier.
- Çetiner, H. (2022). MobileNetV2 ve MobileNetV3 Tabanlı Derin Öğrenme Yaklaşımları ile Cilt Kanserlerinin Sınıflandırılması
- Çıtırak M., İlhan Ç., Teke M.Y. (2017). Optik Koherens Tomografi. *Güncel Retina*, 1(1), 58-68.
- Çıtırak, M. & Teke, M.Y. (2016). Fundus Kamera ve Renkli Fundus Fotoğrafı, *Güncel Retina* 1(1), 7-9.
- Demir, F. B. (2022). *Akciğer bilgisayarlı tomografilerinden görüntü işleme ve derin öğrenme ile COVID-19 tespiti* (Doctoral dissertation, Bursa Uludag University (Turkey)).
- Doshi, D., Shenoy, A., Sidhpura, D., & Gharpure, P. (2016, December). Diabetic retinopathy detection using deep convolutional neural networks. In *2016 international conference on computing, analytics and security trends (CAST)* (pp. 261-266). IEEE.
- Durlu, Y.K. & Kavadarlı, I. (2018). Diyabetik Retinopati ve Diyabetik Maküla Ödeminde Flöresein Anjiyografi ve Optik Koherens Tomografi Anjiyografi Bulguları, *Güncel Retina*, 2(2), 130-137.
- Elgendy, M. (2020). *Deep learning for vision systems*. Simon and Schuster.

- Gonzalez, R. C., Woods, R. E. (1977). Digital Image Processing, Pearson Publication.
- He, A., Li, T., Li, N., Wang, K., & Fu, H. (2020). CABNet: Category attention block for imbalanced diabetic retinopathy grading. *IEEE Transactions on Medical Imaging*, 40(1), 143-153.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).
- Hou, J., Xiao, F., Xu, J., Feng, R., Zhang, Y., Zou, H., & Xue, W. (2023, June). Diabetic retinopathy grading with weakly-supervised lesion priors. In *ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 1-5). IEEE.
- Howard, A., Sandler, M., Chu, G., Chen, L. C., Chen, B., Tan, M., ... & Adam, H. (2019). Searching for mobilenetv3. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 1314-1324).
- Hu, R., Chalakkal, R. J., Linde, G., & Dhupia, J. S. (2022, July). Multi-image stitching for smartphone-based retinal fundus stitching. In *2022 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM)* (pp. 179-184). IEEE.
- Indolia, S., Goswami, A. K., Mishra, S. P., & Asopa, P. (2018). Conceptual understanding of convolutional neural network-a deep learning approach. *Procedia computer science*, 132, 679-688.
- Jmour, N., Zayen, S., & Abdelkrim, A. (2018, March). Convolutional neural Networks for image classification. In *2018 international conference on advanced systems and electric technologies (IC_ASET)* (pp. 397-402). IEEE.
- Kalaycı, D. (2017). Fundus Flöresein Anjiyografi, *Güncel Retina*, 1(1), 22-27.
- Kızrak, M. A., & Bolat, B. (2018). Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286.
- Kürşad, U. Ç. A. R., & KOCER, H. E. (2022). Measuring the Effect of Data Augmentation Methods for Improving the Success of Convolutional Neural Network. *Gazi Mühendislik Bilimleri Dergisi*, 8(3), 430-438.
- Liu, S., Gong, L., Ma, K., & Zheng, Y. (2020). GREEN: a graph residual re-ranking network for grading diabetic retinopathy. In *Medical Image Computing and Computer Assisted Intervention–MICCAI 2020: 23rd International Conference, Lima, Peru, October 4–8, 2020, Proceedings, Part V 23* (pp. 585-594). Springer International Publishing.
- Li, T., Gao, Y., Wang, K., Guo, S., Liu, H., & Kang, H. (2019). Diagnostic assessment of deep learning algorithms for diabetic retinopathy screening. *Information Sciences*, 501, 511-522.

- Li, X., Hu, X., Yu, L., Zhu, L., Fu, C. W., & Heng, P. A. (2019). CANet: cross-disease attention network for joint diabetic retinopathy and diabetic macular degeneration. *IEEE transactions on medical imaging*, 39(5), 1483-1493.
- Li, X., Pang, T., Xiong, B., Liu, W., Liang, P., & Wang, T. (2017, October). Convolutional neural Networks based transfer learning for diabetic retinopathy fundus image classification. In 2017 10th international congress on image and signal processing, biomedical engineering and informatics (CISP-BMEI) (pp. 1-11). IEEE.
- Memiş, S., Enginoğlu, S., & Erkan, U. (2019). A data classification method in machine learning based on normalised hamming pseudo-similarity of fuzzy parameterized fuzzy soft matrices. *Bilge International Journal of Science and Technology Research*, 3, 1-8.
- Novotny, H. R., & Alvis, D. L. (1961). A method of photographing fluorescence in circulating blood in the human retina. *Circulation*, 24(1), 82-86.
- Özçelik, Y. B., & Altan, A. (2021). Diyabetik retinopati teşhisi için fundus görüntülerinin derin öğrenme tabanlı sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (29), 156-167.
- Özdemir H., Ekinci C. (2018). Diyabetik Retinopati ve Diyabetik Maküla Ödeminde Optik Koherens Tomografi Bulguları. *Güncel Retina*, 2(2), 138-142.
- Pattanayak, S. (2019). *Intelligent Projects Using Python: 9 real-world AI projects leveraging machine learning and deep learning with Tensor Flow and Keras*. Packt Publishing Ltd.
- Pratt, H., Coenen, F., Broadbent, D. M., Harding, S. P., & Zheng, Y. (2016). Convolutional neural Networks for diabetic retinopathy. *Procedia computer science*, 90, 200-205.
- Priya, R., & Aruna, P. J. I. J. (2012). SVM and neural network based diagnosis of diabetic retinopathy. *International Journal of Computer Applications*, 41(1).
- Saine, P. J., & Tyler, M. E. (2002). *Ophthalmic photography: retinal photography, angiography, and electronic imaging* (Vol. 132). Boston: Butterworth-Heinemann.
- ŞAHİN, N., ALPASLAN, N., İLÇİN, M., & HANBAY, D. (2023). Evrimsel Sinir Ağı Mimarileri ve Öğrenim Aktarma ile Bitki Zararlısı Çekirge Türlerinin Sınıflandırması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 35(1), 321-331.
- Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning (pp. 6105-6114). PMLR.
- Türkdamar, M. U., Taşyürek, M., & Öztürk, C. (2023). Transfer öğrenmeli ve transfer öğrenmesiz derin ağlar ile inşaat alanında kask tespiti. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12(1), 39-51.
- Tymchenko, B., Marchenko, P., & Spodarets, D. (2020). Deep learning approach to diabetic retinopathy detection. arXiv preprint arXiv:2003.02261.

- URL-1.(2024,Şubat,05).Exeter-Eye-Diabetic-eye-diagram:
<https://www.exetereye.co.uk/eye-conditions/diabetic-retinopathy/exeter-eyediabetic-retinopathy-eye-diagram/> adresinden alınmıştır.
- URL-2. (2024,Eylül,24). APTOS 2019 Blindness Detection:
<https://www.kaggle.com/c/aptos2019-blindness-detection> adresinden alınmıştır.
- URL-3. (2024, Haziran, 5). Güncel Retina Görüntüleme Cihazları:
<https://ankararetina.com/bilgi-detayi/guncel-retina-goruntuleme-cihazlari/> adresinden alınmıştır.
- URL-4. (2024, Ağustos, 7). Welch Allyn PanOptic Pluss Ophthalmoscope:
<https://www.hillrom.com/en/products/panoptic-plus-ophthalmoscope/> adresinden alınmıştır.
- URL-5. (2024 Şubat, 15). Convolutional Neural Network (ConvNet ya da CNN) nedir, nasıl çalışır : <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad> adresinden alınmıştır.
- URL-6. (2024, Şubat, 26). Yapay Zeka Destekli Görüntü Tanıyan IOS uygulama Nasıl Geliştirilir?: <https://medium.com/nsistanbul/g%C3%B6r%C3%BCnt%C3%BCtan%C4%B1yan-mobil-uygulama-nas%C4%B1l-geli%C5%9Ftirilir-33760f7d827>adresinden alınmıştır.
- URL-7.(2024, Şubat, 26). DERİNE DAHA DERİNE: Evrişimli Sinir Ağları:
<https://ayyucekizrak.medium.com/deri%CC%87ne-daha-deri%CC%87ne-evri%C5%9Fimli-sinir-a%C4%9Flar%C4%B1-2813a2c8b2a9> adresinden alınmıştır.
- URL-8. (2024, Mayıs, 02). Makine Öğrenmesi İpuçları ve püf noktaları El Kitabı VIP:
<https://stanford.edu/~shervine/l/tr/teaching/cs-229/cheatsheet-machine-learning-tips-and-tricks>, adresinden alınmıştır.
- URL-9. (2024, Şubat, 02). How can I sharpen an image in OPENCV?:
<https://stackoverflow.com/questions/4993082/how-can-i-sharpen-an-image-in-opencv>,stackoverflow adresinden alınmıştır.
- Woo, S., Park, J., Lee, J. Y., & Kweon, I. S. (2018). Cbam: Convolutional block attention module. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 3-19).
- Yıldız, A. A. (2021). İndosiyanin Yeşili Anjiyografi. *Retinal Görüntüleme Yöntemleri* (pp. 107–130). Akademisyen Kitabevi.
- Zheng, Y., He, M., & Congdon, N. (2012). The world wide epidemic of diabetic retinopathy. *Indian journal of ophthalmology*, 60(5), 428.
- Zhou, K., Gu, Z., Liu, W., Luo, W., Cheng, J., Gao, S., & Liu, J. (2018, July). Multi-cell multi-task convolutional neural networks for diabetic retinopathy grading. In *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 2724-2727).

ÖZGEÇMİŞ

Kübra UÇAR, İlköğrenimini Aysın Rafet Ataç İlkokulunda bitirdikten sonra lise eğitimini Ali Fuat Kadirbeyoğlu Anadolu (AFKAL) Lisesinde tamamladı. 2011-2012 öğretim yılında Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümünde lisans eğitimine başladı ve bu bölümden mezun oldu. 2020-2021 yılı Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim dalında tezli yüksek lisans programına başladı. Gümüşhane Üniversitesi Yazılım Mühendisliği Bölümü'nde araştırma görevlisi olarak görev yapmaktadır. İyi derece İngilizce bilmektedir.

Uçar, K., Dizdaroğlu, B. (2024). İyileştirilmiş Derin Öğrenme Modelleriyle Fundus Görüntülerinde Diyabetik Retinopatinin Sınıflandırılması. 8. Uluslararası Göbeklitepe Bilimsel Çalışmalar Kongresi, Kongre Kitabı, s.289-298. Şanlıurfa, Türkiye.