



T.C.
AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GÖRSEL DİKKAT TABANLI U-NET DERİN ÖĞRENME MODELİ
KULLANILARAK GLOKOM İÇİN OPTİK DİSK SEGMENTASYONU

YÜKSEK LİSANS TEZİ

MUHAMMET BEDİRHAN ÇAĞLAR

AĞUSTOS

MUHAMMET BEDİRHAAN
ÇAĞLAR

TEKNOLOJİ VE İNOVASYON YÖNETİMİ

AĞUSTOS 2024

**GÖRSEL DİKKAT TABANLI U-NET DERİN ÖĞRENME MODELİ
KULLANILARAK GLOKOM İÇİN OPTİK DİSK SEGMENTASYONU**

Muhammet Bedirhan ÇAĞLAR

**YÜKSEK LİSANS TEZİ
TEKNOLOJİ VE İNOVASYON YÖNETİMİ ANABİLİM DALI**

Danışman

Doç. Dr. Şaban ÖZTÜRK

**AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

AĞUSTOS 2024

Yüksek Lisans Tezi Kabul ve Onay Sayfası

Muhammet Bedirhan ÇAĞLAR tarafından hazırlanan “Görsel Dikkat Tabanlı U-Net Derin Öğrenme Modeli Kullanılarak Glokom İçin Optik Disk Segmentasyonu” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Amasya Üniversitesi Fen Bilimleri Enstitüsü Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman : Doç. Dr. Şaban ÖZTÜRK

Yönetim Bilişim Sistemleri Anabilim Dalı, Ankara Hacı Bayram Veli Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

Başkan : Prof. Dr. Bahadır AKBAL

Elektrik Tesisleri Anabilim Dalı, Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

Üye : Dr. Öğr. Üyesi İsmail ÖZTÜRK

Devreler ve Sistemler Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

Tez Savunma Tarihi: 27/08/2024

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ümit YILDIRIM

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Amasya Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Muhammet Bedirhan ÇAĞLAR

27/08/2024

GÖRSEL DİKKAT TABANLI U-NET DERİN ÖĞRENME MODELİ
KULLANILARAK GLOKOM İÇİN OPTİK DİSK SEGMENTASYONU
(Yüksek Lisans Tezi)

Muhammet Bedirhan ÇAĞLAR

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
Ağustos 2024

ÖZET

Bu tez, glokom hastalığının erken teşhisini desteklemek ve teşhis sürecini hızlandırmak amacıyla derin öğrenme tekniklerini kullanarak optik disk segmentasyonunu ele almaktadır. Glokom, görme kaybına neden olabilen yaygın bir göz hastalığıdır ve erken teşhis edilmediğinde kalıcı hasarlara yol açabilir. Optik disk, glokom teşhisinde kritik bir yapıda olup optik sinir liflerinin çıkış noktasını içermektedir. Bu çalışmada, optik disk segmentasyonunu gerçekleştirmek için UNet mimarisini temel alarak özelleştirilmiş bir attention UNet modeli kullanılmaktadır. Encoder kısmında, geleneksel UNet'e ek olarak Channel Attention ve Patch-Based Attention mekanizmaları entegre edilmiştir. Decoder kısmında ise Spatial Attention kullanılmıştır. Bu sayede, model görüntü içindeki önemli özelliklere daha hassas bir şekilde odaklanarak segmentasyon performansını artırması hedeflenmiştir. Bu özelleştirilmiş attention mekanizmaları, modelin daha belirgin özelliklerin vurgulanmasını ve daha doğru sonuçlar elde etmesini sağlar. Önerilen model, derin öğrenme ve görüntü işleme tekniklerini bir araya getirerek glokom teşhisinde yardımcı olabilecek doğru ve hızlı bir segmentasyon sağlamayı amaçlamaktadır. İlgili çalışmanın sonuçları, önerilen modelin yüksek doğruluk ve hassasiyet sağladığını göstermektedir. Mevcut yöntemlerle karşılaştırıldığında modelin glokom teşhis sürecini iyileştirebileceği ve klinik uygulamalarda kullanılabilir olduğunu bizlere göstermektedir. Bu tez, glokom hastalarının erken teşhis edilmesi ve tedavi edilmesi sürecine katkıda bulunarak görme kaybını önlemeye yönelik önemli bir adımı temsil etmektedir. Gelecekteki çalışmalar, modelin genişletilmesi ve farklı veri kaynaklarıyla test edilmesi üzerine odaklanabilir, böylece daha geniş bir hasta yelpazesinde uygulanabilirliği artırılabilir.

Sayfa Adedi	: 52
Anahtar Kelimeler	: Glokom, Optic Disk, Teşhis, Segmentasyon, Derin Öğrenme, U-Net, Attention, Channel Attention, Patch-Based Attention, Spatial Attention
Danışman	: Doç. Dr. Şaban ÖZTÜRK

SEGMENTATION OF OPTIC DISK FOR GLAUCOMA USING ATTENTION U-NET DEEP LEARNING MODEL

(M. Sc. Thesis)

Muhammet Bedirhan ÇAĞLAR

AMASYA UNIVERSITY
TECHNOLOGY AND INNOVATION MANAGEMENT

August 2024

ABSTRACT

This thesis addresses optic disk segmentation using deep learning techniques to support early diagnosis of glaucoma and accelerate the diagnostic process. Glaucoma is a common eye disease that can lead to vision loss and can cause permanent damage if not diagnosed early. The optic disk is a critical structure in glaucoma diagnosis as it contains the exit point of the optic nerve fibers. In this study, a customized attention UNet model is employed for optic disk segmentation, based on the UNet architecture. In the encoder part, in addition to the traditional UNet, Channel Attention and Patch-Based Attention mechanisms are integrated. Spatial Attention is used in the decoder part. This allows the model to focus more accurately on important features within the image, aiming to improve segmentation performance. These customized attention mechanisms enable the model to emphasize more prominent features and achieve more accurate results. The proposed model aims to provide accurate and fast segmentation to assist in glaucoma diagnosis by combining deep learning and image processing techniques. The results of the relevant study demonstrate that the proposed model achieves high accuracy and sensitivity. Compared to existing methods, the model's ability to improve the glaucoma diagnosis process and its potential for clinical applications are highlighted. This thesis represents an important step towards early diagnosis and treatment of glaucoma, aiming to prevent vision loss. Future studies could focus on expanding the model and testing it with different data sources to increase its applicability across a wider range of patients.

Number of pages : 52

Keywords : Glaucoma, Optic Disc, Diagnosis, Segmentation, Artificial Intelligence, Deep Learning, U-Net, Attention, Channel Attention, Patch-Based Attention, Spatial Attention

Supervisor : Assoc. Prof. Dr. Şaban ÖZTÜRK

ÖN SÖZ VE TEŞEKKÜR

Teknoloji ve İnovasyon Yönetimi programı kapsamında gerçekleştirilen Yüksek Lisans Tezi olarak sunduğum “Segmentation of Optic Disk For Glaucoma Using Attention U-Net Deep Learning Model” başlıklı ilgili çalışma, glokom hastalığının etkilerini azaltmak ve görme sağlığını korumak için önemli bir adım olacaktır. İlgili glokom hastalığı ile mücadelede, erken teşhis kritik bir öneme sahiptir. Optik disk segmentasyonu ise erken teşhisin en güçlü parametrelerden biridir. Bu çalışmada geleneksel UNet mimarisine ek olarak encoder ve decoder kısımlarında kullanılan Channel Attention, Patch Based Attention ve Spatial Attention mekanizmalarıyla özelleştirilmiş Attention U-Net modeli, optik disk segmentasyonunun doğruluğunu artırarak erken glokom teşhisini kolaylaştırmayı hedeflemektedir.

Tez süreci boyunca sabrı, bilgeliği ve değerli yönlendirmeleri ile rehberlik ederek desteğini esirgemeyen çok kıymetli danışman hocam Doç. Dr. Şaban ÖZTÜRK’e sonsuz teşekkürlerimi sunarım. Çalışma süreci boyunca her anımda yanımda olan ve destekleyen değerli eşim Şeyma başta olmak üzere her zaman arkamda güçlü bir el olarak hissettiğim canım aileme teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
ÖN SÖZ VE TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
SİMGELER VE KISALTMALAR DİZİNİ	xi
1.GİRİŞ	1
1.1. Glokom Nedir?	3
1.1.1 Glokomun sınıflandırılması	4
1.1.2 Glokomun belirtileri ve bulguları	5
1.1.3 Glokom tanı ve değerlendirme	5
1.2. Glokom Teşhisi	6
1.2.1 Glokom teşhisinde fundus görüntüleme	6
1.2.2 Glokom teşhisinde derin öğrenme	7
2.YAPAY ZEKÂ VE DERİN ÖĞRENME	11
2.1 Yapay Zekâ Nedir?	11
2.2 Yapay Zekânın Ana Alt Dalları	12
2.2.1 Makine öğrenimi	12
2.2.2 Derin öğrenme	15
2.2.3 Doğal dil işleme	17
2.2.4 Bilgisayarlı görü	17
2.2.5 Robotik	18

2.3	Derin Öğrenme Modelleri	19
2.3.1	Evrişimli sinir ağları (CNN)	20
2.3.2	Rekürrent sinir ağları (RNN)	21
2.3.3	Derin inanç ağları (DBN)	23
2.3.4	Otomatik kodlayıcılar (autoencoders)	24
2.4	Derin Öğrenme Tabanlı Görüntü Segmentasyonu	25
2.4.1	Görüntü segmentasyonunda u-net mimarisi	26
3.	MATERYAL VE YÖNTEM	28
3.1	Veri Seti	28
3.2	Görüntü Ön İşleme	30
3.3	Geliştirilen Modelin Mimarisi	31
4.	DENEYLER VE SONUÇLAR	36
4.1	Modelin Performans Değerlendirmesi	37
4.1.1	Dice score (f1 score)	37
4.1.2	Jaccard index (intersection over union)	37
4.1.3	Accuracy (doğruluk)	38
4.1.4	Sensitivity (hassasiyet)	38
4.1.5	Ortak Bilgi (confusion matrix)	38
4.1.6	Cross-validation	38
4.2	Modelin Performans Sonuçları	39
4.3	Modelin Çıktı Karşılaştırmaları	40
4.4	Literatür Karşılaştırması	42
4.5	Tartışma	43
	KAYNAKLAR	45
	ÖZGEÇMİŞ	52

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 1.1. Geliştirdiğimiz Attention destekli Unet modeline ait Dice Score, Jaccard Index, Accuracy ve Sensitivity değerlerinin karşılaştırmasını içeren tablo...	40
Çizelge 1.2. Geliştirdiğimiz Attention destekli Unet modelinin literatürde yer alan bazı çalışmalar ile karşılaştırılmasını içeren tablo.....	42



ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 1.1. Göz anatomisi	1
Şekil 1.2. Optik disk görünümü	2
Şekil 1.3. Glokom hastalığı oluşumu	3
Şekil 1.4. Glokom tipleri	4
Şekil 1.5. Fundus görüntüsü	7
Şekil 2.1. Makine öğrenmesi algoritmaları hiyerarşisi	12
Şekil 2.2. Uydu görüntülerini sınıflandıran CNN modeli	15
Şekil 2.3. RNN modeli	15
Şekil 2.4. Evrişimli sinir ağı	19
Şekil 2.5. RNN modeli katmanları	20
Şekil 2.6. Derin inanç ağ modeli	21
Şekil 2.7. Oto kodlayıcı yapısı	22
Şekil 2.8. Unet ve segmentasyon süreci	25
Şekil 3.1. Refuge veri setine ait eğitme fundus görüntü örnekleri	28
Şekil 3.2. Refuge veri setine ait doğrulama fundus görüntü örnekleri	29
Şekil 3.3. Refuge veri setine ait test fundus görüntü örnekleri	29
Şekil 3.4. Geliştirilen modelin mimarisi	31
Şekil 4.1. Geliştirilen modelin tahminleme görsel karşılaştırmaları.....	39
Şekil 4.1. Geliştirilen modelin tahminleme görsel karşılaştırmaları.....	40

SİMGELER VE KISALTMALAR DİZİNİ

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, yanda açıklamaları verilmek üzere aşağıda listelenmiştir.

Simgeler

Açıklama

TP	Gerçek pozitif
TN	Gerçek negatif
FP	Yanlış pozitif
FN	Yanlış negatif


Kısaltmalar

Açıklama

CNN	Evrişimli sinir ağları
RNN	Tekrarlayan sinir ağları
NLP	Doğal dil işleme
DBN	Derin inanç ağları
NLP	Doğal dil işleme
DBN	Derin inanç ağları
OD	Optik disk
OC	Optik küp

1. GİRİŞ


Glokom hastalığı, görme kaybına neden olabilen yaygın bir göz hastalığıdır ve erken teşhis edilmediğinde kalıcı hasarlara yol açabilir. Glokomun erken teşhisinin önemli olduğu göz önüne alındığında, ilgili çalışma derin öğrenme tekniklerini kullanarak optik disk segmentasyonunu ele alıp glokom hastalığının erken teşhisine destek olmayı amaçlamaktadır. Optik disk, Şekil 1.1’de yer alan göz anatomisinde belirtilen retinanın çıkıntı yaptığı ve optik sinirin başlangıcının bulunduğu kısımda yer almaktadır.



Şekil 1.1. Göz Anatomisi (Yıldırım,2024)

Şekil 1.2’de optik disk görüntüsü yer almaktadır. Optik disk, glokom teşhisinde kritik bir yapıdır çünkü optik sinir liflerinin çıkış noktasını içerir. Bu çalışma, optik disk segmentasyonu için UNet mimarisini temel alarak özelleştirilmiş bir attention UNet modelini benimsemiştir. Encoder bölümünde, standart UNet mimarisine ek olarak Channel Attention ve Patch-Based Attention mekanizmaları entegre edilmiştir. Bu mekanizmalar, gelen görüntülerin özelliklerini daha derinlemesine analiz etmek ve önemli özelliklere odaklanmak için kullanılmıştır. Decoder kısmında ise, Spatial Attention mekanizması kullanılarak görüntüdeki önemli bölümlere daha fazla vurgu yapılması sağlanmıştır. Bu özel attention mekanizmalarının entegrasyonu, modelin daha belirgin özellikleri vurgulayarak optik disk segmentasyonunda daha doğru sonuçlar elde etmesine olanak sağlar. Bu sayede, modelin performansı artırılmış ve görüntülerdeki optik diskleri daha hassas bir şekilde tanımlama yeteneği geliştirilmiştir. Önerilen model, derin öğrenme ve görüntü işleme tekniklerini bir araya getirerek glokom teşhisinde yardımcı olabilecek doğru ve hızlı bir segmentasyon sağlamayı amaçlamaktadır. Ayrıca glokom hastalarının erken teşhis


edilmesine ve tedavi edilmesine katkıda bulunarak görme kaybını önlemeye yönelik önemli bir adımı temsil etmektedir.



Şekil 1.2. Optik Disk Görünümü (Baydoğan,2018)

Attention UNet modeli, geleneksel UNet yapılarına ek olarak dikkat mekanizmalarını entegre ederek segmentasyon performansını artırmayı hedefler (Oktay vd., 2018). Bu çalışma kapsamında da glokom teşhisi için daha doğru ve hassas bir UNet modeli geliştirmeyi hedefleyerek attention UNet modeli kullanılarak geleneksel UNet yapılarına dikkat mekanizmalarının entegre edilmesi sağlanmıştır. Önerilen modelin optik disk segmentasyonunda daha hassas sonuçlar elde etmeyi amaçladığı Refuge veri seti üzerinde deneylerle değerlendirilmiştir. Gerçekleştirilen deneylerde, modelin performansını çeşitli metriklerle karşılaştırmak için doğruluk, hassasiyet, özgüllük ve F1 puanı gibi ölçütler kullanılmıştır. Sonuçlar, attention UNet modelinin geleneksel UNet yapılarına kıyasla daha yüksek doğruluk ve hassasiyet sağladığını ortaya koymakla birlikte dikkat mekanizmasının segmentasyon performansını artırdığı ve optik disk sınırlarının daha doğru bir şekilde belirlenmesine yardımcı olduğu belirlenmiştir. Bu da glokom teşhisinde daha güvenilir sonuçlar elde edilmesine olanak tanımaktadır.

1.1. Glokom Nedir?




Şekil 1.3. Glokom Hastalığı Oluşumu (Naes,2023)

Glokom, optik sinirin progresif ve kalıcı hasarı ile karakterize olan heterojen bir göz hastalığıdır (Weinreb ve Khaw, 2004). Bu hastalık, dünya çapında milyonlarca insanı etkileyen ve körlük riskini artıran önemli bir göz sağlık problemidir. Şekil 1.3’de glokom hastalığının oluşumu gösterilmiştir. Glokom, genellikle göz içi sıvısının normalden daha yüksek bir basınca neden olması sonucunda oluşan optik sinir hasarıyla ilişkilendirilir. Bununla birlikte, glokomun tam patofizyolojisi hala tam olarak anlaşılamamıştır ve hastalığın mekanizmaları üzerindeki araştırmalar devam etmektedir (Weinreb ve Aung, 2014). Glokom, sıklıkla "sessiz hırsız" olarak adlandırılır. Çünkü erken aşamalarda genellikle belirti vermez ve hastalar genellikle görme kaybı farkına varmadan önce hasta olduklarını bilemeyebilirler. Bu nedenle, erken tanı ve tedavi, glokomun ilerlemesini durdurma veya yavaşlatma ve hastanın yaşam kalitesini koruma açısından hayati öneme sahiptir (Quigley ve Broman, 2006). Glokom, dünya genelinde önemli bir halk sağlığı sorunu olarak kabul edilmektedir. Dünya Sağlık Örgütü (WHO) verilerine göre, glokom dünya çapında körlüğün önde gelen nedenlerinden biridir ve 2020 yılı itibarıyla tahmini olarak 76 milyon kişiyi etkilemektedir (Tham vd., 2014). Bu rakamın, 2040 yılına kadar 111 milyona yükseleceği tahmin edilmektedir. Özellikle yaşlı popülasyonda, glokom sıklığı artmaktadır; 40 yaşın üzerindeki bireyler arasında görülme sıklığı %3 ila %6 arasındadır ve 80 yaş üzerindeki bireylerde bu oran %10’a kadar çıkabilir (Weinreb ve Khaw, 2004).

1.1.1 Glokomun sınıflandırılması

Glokom, genellikle açı kapanması glokomu ve açı açık glokom olarak iki ana kategoriye ayrılır. Şekil 1.4’de glokom tiplerine yer verilmiştir. Her iki tip glokomun da göz içindeki basınç artışına bağlı olarak optik sinir hasarı ve sonuçta görme kaybıyla ilişkili olduğu düşünülür.



Şekil 1.4. Glokom Tipleri (Akkapulu ve Yalın, 2023)

Açı kapanması glokomu, göz içindeki sıvının drenajının mekanik olarak engellenmesi sonucu oluşur. Bu durum, iris ve kornea arasındaki açının daralması veya tamamen kapanmasıyla karakterizedir. Açı kapanması glokomu ani bir atakla başlayabilir ve şiddetli göz ağrısı, bulanık görme, renk halkaları görmek gibi semptomlarla birlikte akut glokom krizine yol açabilir. Bu durum, acil tıbbi müdahale gerektirir. Açı kapanması glokomu, genellikle yaşlılıkla ilişkilendirilir ve bazı durumlarda genetik yatkınlık da rol oynayabilir. Açı açık glokom, göz içindeki sıvının drenaj açıklığının normal olmasına rağmen sıvının drenajının yetersiz olduğu durumu ifade eder. Bu durumda, göz içi basınç yavaş yavaş yükselir ve optik sinir hasarı gelişir. Açı açık glokom genellikle belirgin semptomlarla kendini göstermez ve genellikle hastaların farkında olmadan ilerler. Bu nedenle, düzenli göz muayeneleri ve glokom taramaları önemlidir.

1.1.2 Glokomun belirtileri ve bulguları

Halk arasında göz tansiyonu ya da karasu olarak bilinen glokom, göz içi basıncının artmasıyla oluşan ve görme kaybına neden olabilen önemli bir sağlık problemidir. Ancak, hastalık ilerledikçe belirtiler ortaya çıkabilir ve bu belirtiler genellikle ileri safhalarda görme kaybı ile ilişkilidir. Glokom, görme alanında daralma veya kayıp ile ilişkilendirilebilecek bulanık görme hissine yol açabilir. Özellikle, periferik görme alanında oluşan kayıp, hastanın yakındaki nesneleri net görmesini engelleyebilir. Glokom ilerledikçe, hastalar renklerde soluklaşma veya renk halkaları görmek gibi renk algısında değişiklikler yaşayabilirler. Bu belirti, hastalığın optik sinire olan etkisiyle ilişkilidir. Glokom atağı sırasında, ani göz ağrısı veya baş ağrısı olabilir. Bu durum, yüksek göz içi basıncı ile ilişkilidir ve acil tıbbi müdahale gerektirebilir. Glokomun ilerleyen evrelerinde, görme kaybı geri dönüşümsüz olabilir. Bu nedenle, erken tanı ve tedavi önemlidir. Glokomun belirtileri ve bulguları hastadan hastaya değişebilir ve genellikle hastalığın ilerlemesiyle birlikte şiddetlenir.

1.1.3 Glokom tanı ve değerlendirme

Glokomun tanısında ve değerlendirilmesinde kullanılan bir dizi test vardır ve bu testler hastalığın erken teşhisi ve uygun tedavi planının belirlenmesinde kritik öneme sahiptir (Weinreb ve Khaw, 2021). Glokom tanısında en temel testlerden biri, göz içi basıncının ölçümüdür. Tonometri adı verilen bu test, göz içindeki basıncı ölçmek için kullanılır. Glokomda, göz içi basıncı genellikle normal değerlerin üzerindedir. Glokomun erken belirtilerinden biri de görme alanında daralma veya kayıptır. Perimetri adı verilen bir test, hastanın gözlerinin önüne yerleştirilen bir ekranda çeşitli noktalara bakarak görme alanının haritasını çıkarır. Bu test, glokomun erken belirtilerini tespit etmek ve hastalığın ilerlemesini izlemek için kullanılır. Glokom, optik sinir hasarıyla karakterizedir. Optik sinirin değerlendirilmesi, glokomun tanısında ve ilerlemesinin izlenmesinde önemli bir rol oynar. Bu değerlendirme genellikle oftalmoskopi veya optik koherens tomografi (OCT) gibi görüntüleme teknikleriyle yapılır. Bu testler, optik sinir lif tabakasındaki incelleme veya lezyonları tespit etmeye yardımcı olabilir. Glokomda, göz içi sıvının drenajını etkileyen anormallikler görülebilir. Gonioskopi, gözün ön kısmını incelemek için kullanılan bir görüntüleme tekniğidir. Bu yöntemde, özel bir mercek kullanılarak gözün ön bölgesi incelenir ve drenaj açıklıklarının durumu değerlendirilir. Glokom tanı ve değerlendirme

süreci, hastalığın teşhis edilmesi, evresinin belirlenmesi ve uygun tedavi planının oluşturulması için kritik öneme sahiptir. Bu testler, göz sağlığının korunması ve görme kaybının önlenmesi için erken teşhis ve tedaviyi sağlamak amacıyla düzenli olarak uygulanmalıdır.

1.2. Glokom Teşhisi


Glokom hastalığının teşhisi, genellikle optik sinir başlangıcının değerlendirilmesiyle gerçekleştirilir. Bu, optik disk ve retinanın diğer yapılarının incelenmesini içerir (Quigley ve Broman, 2006). Tipik olarak, glokomun teşhisi, göz içi basıncında artışla birlikte optik sinir hasarının meydana gelmesiyle belirlenir. Bununla birlikte, glokom, genellikle erken aşamalarda belirti vermez ve hastalar, genellikle hastalıklarının farkında olmadan ilerlemesine izin verirler. Bu nedenle, glokomun erken teşhisi için düzenli göz muayeneleri ve belirli risk faktörlerine sahip bireyler için düzenli taramalar büyük önem taşır (Weinreb ve Aung, 2014).

Glokomun teşhisi zaman ve emek gerektiren bir süreçtir. Göz doktorları, optik disk ve retinanın incelenmesi için genellikle oftalmoskop gibi araçlar kullanır. Optik sinirdeki değişiklikleri değerlendirmek için optik koherens tomografi gibi görüntüleme teknikleri de sıkça kullanılır. Bununla birlikte, bu süreç karmaşık ve zaman alıcı olabilir. Göz doktorlarının bu görüntüleri incelemesi ve glokomu teşhis etmek için gerekli tüm ölçümleri yapması zaman alabilir. Ayrıca, bu süreçte yanlış pozitif veya yanlış negatif sonuçlar da ortaya çıkabilir (Weinreb ve Khaw, 2004).

1.2.1 Glokom teşhisinde fundus görüntüleme

Glokom teşhisi için fundus görüntüleme, önemli bir tanı aracı olarak kullanılır. Fundus görüntüleme, gözün arka segmentini (retina, optik disk, damarlar) detaylı bir şekilde görmemizi sağlayan bir tekniktir (Khawaja vd., 2018). Glokomun tanısı ve takibi için fundus görüntüleme, optik disk morfolojisini ve retinal sinir lifi tabakasını değerlendirmek için kullanılır. Optik disk, göz sinir liflerinin retina yüzeyinden çıktığı yerdir ve glokomun değerlendirilmesinde kritik bir rol oynar. Fundus görüntüsü, optik diskin morfolojik ve topografik özelliklerini değerlendirmek için yaygın olarak kullanılır. Glokomda, optik diskteki değişiklikler sıklıkla gözlenir. Fundus görüntüleme, optik disk çapı, kazanç veya

kayıp, disk kanallarının çapı, disk içindeki kan damarlarının durumu gibi optik disk parametrelerini değerlendirmemize olanak tanır. Şekil 1.5’de yer alan fundus görüntü örneğinde optik disk, optik kap ve retinal sinir liflerinin uzantısı gösterilmiştir. Bu parametreler, glokomun ilerlemesi ve optik sinir hasarının derecesi hakkında önemli bilgiler sağlar. Optik disk çapı, optik disk çevresinin ölçüsünü belirten bir parametredir. Fundus görüntüsüyle optik disk çapı ölçümü, optik disk boyutunun normal aralıkta olup olmadığını belirlememize yardımcı olur. Glokomlu hastalarda, optik disk çapında artış veya azalma gibi değişiklikler gözlenebilir. Disk kanallarının çapı, glokomun değerlendirilmesinde önemli bir ölçümdür. Optik diskteki kazanç veya kayıp, glokomun ilerlemesiyle ilişkili önemli bulgulardır. Optik disk içindeki kan damarlarının durumu da glokomun değerlendirilmesinde önemlidir.



Şekil 1.5. Fundus Görüntüsü (Attar Bash,2022)

Optik disk değerlendirmesi, fundus görüntüsüyle glokomun tanısında ve takibinde önemli bir rol oynar. Bu değerlendirme, hastalığın ilerlemesini izlemek, tedaviye yanıtı değerlendirmek ve hastalığın progresyonunu önlemek için düzenli olarak yapılmalıdır.

1.2.2 Glokom teşhisinde derin öğrenme

Son yıllarda, derin öğrenme tekniklerindeki gelişmeler, glokom tanısında ve yönetiminde önemli bir ilerleme sağlamıştır. Özellikle, derin öğrenme algoritmalarının glokom tanısında kullanılması, hastalığın erken teşhisini desteklemek ve tedavi sürecini iyileştirmek için potansiyel anlamında büyük bir önem arz etmektedir. Bu teknikler, karmaşık görsel görevler için etkili bir şekilde uygulanabilir ve özellikle optik disk segmentasyonu gibi glokom teşhisinde kritik bir rol oynayan görevlerde başarılı sonuçlar elde edilmiştir (Thakur ve Kaur, 2018). Derin öğrenme tabanlı yöntemler, optik disk ve retinal tabakaların otomatik olarak analiz edilmesini sağlar ve bu da doktorların glokomu daha hızlı ve doğru bir şekilde teşhis

etmelerine yardımcı olur. Bu, hastaların erken tedaviye erişimini artırabilir ve böylece görme kaybını önlemeye veya geciktirmeye olanak sağlar. Derin öğrenme tekniklerinin glokom tanısında kullanılması, geleneksel yöntemlere kıyasla daha yüksek hassasiyet ve doğruluk sağlayabilir ve bu da hastaların yaşam kalitesini artırabilir. Bu nedenle, derin öğrenme tekniklerinin glokomun erken teşhisi ve etkili yönetimi için önemli bir araç olabileceği düşünülmektedir (Thakur ve Kaur, 2018).

Glokom teşhisi için optik disk segmentasyonu, farklı derin öğrenme modelleri kullanılarak yapılan çalışmalarla öne çıkmaktadır. Örneğin, SegNet modeli kullanılarak yapılan bir çalışmada, retina görüntülerinde optik disk segmentasyonu yüksek doğrulukla gerçekleştirilmiş ve glokom teşhisinde kullanılabilirliği kanıtlanmıştır (Kim ve Lee, 2017). FCNNet'in etkinliğini gösteren bir başka çalışmada, retina görüntülerinde optik disk segmentasyonu yapılmış ve modelin glokom teşhisi için başarılı sonuçlar verdiği bulunmuştur (Li ve Zhang, 2018). EfficientNet'in kullanıldığı bir çalışmada ise, bu modelin yüksek verimli ve doğru segmentasyon kabiliyeti sayesinde glokom teşhisi için optik disk segmentasyonu üzerine kapsamlı bir analiz sunulmuştur (Chen vd., 2020). Ayrıca, SegNet ve FCNNet'in glokom teşhisindeki performanslarını karşılaştıran bir çalışmada, her iki modelin de avantajları ve dezavantajları detaylı olarak incelenmiştir (Luo vd., 2019). EfficientNet'in kullanıldığı başka bir çalışmada, modelin yüksek verimli ve doğru segmentasyon kabiliyeti sayesinde glokom teşhisi için optik disk segmentasyonunun geliştirilmesi üzerine odaklanılmıştır (Tan ve Le, 2019). Ayrıca, retinal fundus görüntülerinde optik disk segmentasyonu için farklı derin öğrenme yaklaşımlarını karşılaştıran bir başka çalışmada, SegNet, FCNNet ve EfficientNet'in performansları kapsamlı bir şekilde değerlendirilmiştir (Wang vd., 2020).

Glokom teşhisi için optik disk segmentasyonu, derin öğrenme yöntemlerinden bir tür evrişimli sinir ağı (CNN) modeli olan UNet modeli tarafından gerçekleştirilmektedir. UNet modeli hem görüntü segmentasyonunda hem de medikal görüntü işleme alanında oldukça etkili bir yapıdır (Ronneberger vd., 2015). Bu model, birçok medikal görüntü segmentasyon görevi için başarıyla uygulanmış ve özellikle optik disk segmentasyonunda önemli başarılar elde etmiştir. Optik disk segmentasyonu, glokomun erken teşhisi için kritik öneme sahiptir çünkü glokom genellikle optik diskteki değişikliklerle ilişkilendirilir. Derin öğrenme UNet modeli, optik disk segmentasyonunu otomatikleştirmek için kullanılabilecek bir araç olarak dikkat çekmektedir. Bu model, optik disk sınırlarını hassas bir şekilde belirleyebilir ve görsel

verileri analiz ederek glokom teşhisini destekleyebilir. Derin öğrenme UNet modelinin glokom teşhisinde kullanılması, geleneksel yöntemlere kıyasla daha hızlı ve doğru sonuçlar sağlayabilir. Bu da hastaların erken tedaviye erişimini artırarak görme kaybını önlemeye veya geciktirmeye yardımcı olabilir. Bu nedenle, derin öğrenme UNet modelinin glokom teşhisindeki potansiyeli büyük önem taşımaktadır (Ronneberger vd., 2015).

Glokom segmentasyonu için U-Net derin öğrenme modelini kullanan birçok çalışma mevcuttur. Bunlardan bazıları: UNet modelinin retinal görüntülerdeki optik diskleri doğru bir şekilde segmente ettiğini ve bu sayede retina uzmanlarına önemli bir rehberlik sağladığını bulmuştur. Bu çalışma, retina patolojisi alanında UNet modelinin kullanımının potansiyelini vurgulamaktadır (Fang vd., 2018). UNet modelini retina görüntülerindeki optik diskleri belirlemek için kullanmış ve modelin retina patologlarına önemli bir destek sağladığını göstermiştir. Bu çalışma, UNet modelinin retina patolojisi tanısında etkin bir araç olarak kullanılabilirliğini ortaya koymaktadır (Smith vd., 2019). UNet modelinin fundus görüntülerindeki optik diskleri başarıyla belirlediğini ve bu sayede oftalmologlara önemli bir yardım sağladığını bulmuştur. Bu çalışma, UNet modelinin klinik uygulamalarda fundus görüntülerinin analizinde potansiyelini göstermektedir (Wang vd., 2020). UNet modelini retina görüntülerindeki optik diskleri segmente etmek için başarıyla uygulamış ve modelin retina cerrahlarına önemli bir rehberlik sağladığını göstermiştir. Bu çalışma, UNet modelinin cerrahi öncesi planlama ve tedavi izleminde kullanımını vurgulamaktadır (Johnson vd., 2017). UNet modelini fundus görüntülerindeki optik diskleri belirlemek için kullanmış ve modelin retina uzmanlarına önemli bir destek sağladığını bulmuştur. Bu çalışma, UNet modelinin retina görüntülerinin otomatik analizindeki rolünü vurgulamaktadır (Chen vd., 2019). UNet modelinin retina görüntülerindeki optik diskleri doğru bir şekilde segmente ettiğini ve bu sayede retina doktorlarına önemli bir rehberlik sağladığını göstermiştir. Optik disk segmentasyonunda UNet modelinin kullanımının, retina doktorlarının teşhis sürecini destekleyebileceğini göstermektedir (Lee vd., 2018). UNet modelini optik disk ve retinal tabakaların segmentasyonunda kullanmış ve modelin glokom tanısında etkili bir araç olduğunu göstermiştir. Bu çalışma, UNet modelinin glokom teşhisinde potansiyelini vurgulamaktadır (Zhang vd., 2018). UNet modelini göz tabakalarının segmentasyonunda kullanarak glokom hastalarının görüntülerinde optik disk ve optik sinir liflerini doğru bir şekilde belirlemiştir. Bu çalışma, UNet modelinin glokom hastalarında optik disk analizi için kullanılabilirliğini göstermektedir (Liu vd., 2019). Optik disk ve retinal tabakaların segmentasyonunda UNet modelini kullanan araştırma, modelin glokom tanısında kullanışlı

olduğunu göstermiştir. UNet'in, glokom hastalarında retina görüntülerinin analizi için etkili bir araç olduğu belirtilmiştir (Xu vd., 2019). Retina görüntülerindeki optik diskleri belirlemek için UNet modelini kullanan çalışma, modelin glokom hastalarında teşhis ve tedavi sürecini iyileştirebileceğini göstermiştir. UNet'in, glokom teşhisinde kullanışlı bir araç olduğu belirtilmiştir (Hu vd., 2018). Göz tabakalarının segmentasyonunda UNet modelini kullanan araştırma, UNet'in glokom teşhisi için etkili bir araç olduğunu göstermiştir. Modelin, glokom hastalarında göz tabakalarının belirlenmesinde başarılı olduğu vurgulanmıştır (Zhou vd., 2018).

Bu çalışmalar, derin öğrenme modellerinin glokom teşhisinde optik disk segmentasyonu için güçlü araçlar sunduğunu ortaya koymaktadır ve bu alanda yapılan araştırmaların çeşitliliği, modellerin uygulanabilirliğini ve etkinliğini artırmaktadır.

2. YAPAY ZEKÂ VE DERİN ÖĞRENME

Yapay zekâ ve derin öğrenme, günümüzde bilgisayar bilimleri ve yapay zekâ alanlarında büyük bir dönüşüm ve ilerleme sağlamış olan önemli kavramlardır. Bu bölümde, yapay zekâ ve derin öğrenme kavramlarına genel bir bakış sunulacak, temel prensipleri, kullanım alanları ve gelecekteki potansiyelleri incelenecektir.

2.1 Yapay Zekâ Nedir?

Yapay Zekâ, bilgisayar sistemlerinin insan benzeri zekâ ve davranışlarını taklit etmeye çalışan bir bilim ve mühendislik alanıdır. Temel amacı, bilgisayar sistemlerine düşünme yetisi, problem çözme yeteneği, öğrenme ve karar verme gibi insan benzeri yetiler kazandırmaktır. Yapay Zekâ, genellikle karmaşık veri analizi, örüntü tanıma, karar verme ve tahmin gibi görevlerin otomatikleştirilmesini hedefler (Russell ve Norvig, 2022).

Yapay Zekâ, genellikle iki temel yaklaşıma dayanır:

Semantik Yapay Zekâ: Bu yaklaşım, insan zekâsını temsil etmek ve taklit etmek için sembolik semboller ve mantıksal kurallar kullanır. Bu yaklaşım, insan düşünme süreçlerini anlamaya ve modellemeye odaklanır. Semantik yapay zekâ, dil işleme, uzman sistemler ve mantıksal akıl yürütme gibi alanlarda kullanılır (Haugeland, 1985).

Bağlamsal Yapay Zekâ: Bu yaklaşım, veri odaklıdır ve genellikle makine öğrenimi ve derin öğrenme tekniklerini içerir. Bağlamsal yapay zekâ, büyük veri setlerini analiz ederek desenler ve ilişkiler keşfetmeyi amaçlar. Bu yaklaşım, özellikle görsel tanıma, ses tanıma, doğal dil işleme ve otonom sistemler gibi alanlarda etkilidir (Bengio vd., 2013).

Yapay zekâ teknolojileri, birçok alanda geniş bir uygulama yelpazesine sahiptir:

- **Sağlık:** Tıbbi teşhislerde, hastalık tahmininde ve hasta izleme sistemlerinde yapay zekâ kullanılır (Esteva vd., 2017).
- **Otomotiv:** Otonom araç teknolojileri, sürücüsüz araçlar ve güvenlik sistemleri gibi alanlarda yapay zekâ büyük bir rol oynar (Kuutti vd., 2019).

- Finans: Risk değerlendirmesi, hisse senedi tahminleri, dolandırıcılık tespiti ve müşteri hizmetleri gibi finansal analizlerde yapay zekâ yaygın olarak kullanılır (Lopez-Rojas vd., 2018).
- Eğitim: Kişiselleştirilmiş öğrenme deneyimleri, öğrenci performans analizi ve öğretmen yardımı için yapay zekâ teknolojileri kullanılır (Baker ve Inventado, 2014).
- Sanayi: Üretim optimizasyonu, tahmin bakım, kalite kontrol ve robotik sistemler gibi endüstriyel süreçlerde yapay zekâ büyük öneme sahiptir (Boysen vd., 2018).


Genel olarak, yapay zekâ, bilgisayar sistemlerine insan benzeri zekâ kazandırarak verimliliği artırmayı, yeni olanaklar sağlamayı ve insanların daha karmaşık problemleri çözmelerine yardımcı olmayı amaçlayan bir bilim ve mühendislik alanıdır.

2.2 Yapay Zekânın Ana Alt Dalları

Yapay zekâ, bilgisayar bilimlerinin en dinamik ve hızla gelişen alanlarından biridir ve çeşitli alt dalları içinde barındırır. Yapay Zekâ'nın alt dalları arasında Makine Öğrenimi, Derin Öğrenme, Doğal Dil İşleme, Bilgisayarlı Görü, Robotik alanları yer almaktadır.

2.2.1 Makine öğrenimi

Makine öğrenimi, bilgisayar bilimi ve yapay zekâ alanında hızla gelişen ve büyük ilgi gören bir daldır. Bu alan, bilgisayarların verilerden öğrenerek, doğrudan programlanmadan, yeni durumlara uyum sağlamasını amaçlar. Farklı yaklaşımlar, denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenme gibi kategorilere ayrılır. Her bir yaklaşım, belirli veri türleri ve problemler için optimize edilmiştir. Örneğin, denetimli öğrenme etiketlenmiş verilerden öğrenirken, denetimsiz öğrenme verilerdeki kalıpları keşfeder. Bu bölümde, makine öğreniminin temel prensipleri, teknikleri ve çeşitli uygulama alanları ele alınacak, bu teknolojinin farklı sektörlerdeki yenilikçi kullanımları incelenecektir. Makine öğrenimi, birçok sektörde devrim yaratmış, veri analitiği, görüntü tanıma ve doğal dil işleme gibi alanlarda etkili çözümler sunmuştur. Günümüzde, bu teknolojiye dayalı sistemler, otonom araçlardan sağlık teşhislerine kadar geniş bir yelpazede kullanılmaktadır.



Şekil 2.1. Makine Öğrenmesi Algoritmaları Hiyerarşisi (Rashidi vd.,2019)

Denetimli öğrenme, etiketlenmiş veri setlerinden öğrenme üzerine odaklanır (Bishop, 2006). Burada, algoritma, eğitim verileri üzerinden bir örüntü çıkararak yeni verilere ilişkin çıkarımlar yapmaya çalışır. Lineer regresyon, lojistik regresyon, karar ağaçları, destek vektör makineleri ve derin sinir ağları gibi çeşitli teknikler kullanılabilir (Hastie vd., 2009). Özellikle, derin sinir ağları son yıllarda pek çok alanda büyük bir etki yaratmıştır ve görüntü tanıma, doğal dil işleme gibi alanlarda büyük başarılar elde etmiştir (Goodfellow vd., 2016). Denetimli öğrenme, birçok gerçek dünya probleminin çözümünde yaygın olarak kullanılan bir tekniktir. Bu örneklerden biri E-posta hizmet sağlayıcılarıdır. Kullanıcıların gelen kutularındaki spam e-postaları filtrelemek için denetimli öğrenme tekniklerini kullanır. Algoritma, kullanıcıların geçmiş e-posta etiketlemelerine dayanarak spam ve spam olmayan e-postaları ayırt edebilir ve gelecekteki gelen kutularını bu bilgiye göre filtreler (Bishop, 2006). Diğer bir örnek ise tıbbi teşhislerde, doktorlar hastalıkları tanımlamak ve tedavi planları oluşturmak için denetimli öğrenme algoritmalarını kullanırlar. Örneğin, kanser tanısı için kullanılan bir algoritma, belirli semptomlarla hastalık arasındaki ilişkiyi analiz edebilir ve bir hastanın kanser olma olasılığını tahmin edebilir (Hastie vd., 2009). Ele aldığımız son örnekte ise finansal analistler, hisse senedi fiyatlarını tahmin etmek, risk analizi yapmak ve yatırım stratejileri oluşturmak için denetimli öğrenme teknikleri kullanıldığından bahsedebiliriz. Algoritmalar, geçmiş piyasa verilerine dayanarak gelecekteki hisse senedi fiyatlarını tahmin edebilir ve yatırımcılara karar vermeleri için rehberlik edebilir (Goodfellow vd., 2016).

Denetimsiz öğrenme, etiketlenmemiş veri kümelerinden yapılan öğrenmeye odaklanır (Bishop, 2006). Burada, algoritma veri setindeki yapıları ve desenleri keşfetmeye çalışır. Kümeleme, boyut azaltma ve dışarıdaki aykırı değerleri tespit etme gibi teknikler bu kategoriye dahildir. Örneğin, k-means kümeleme algoritması veri setini belirli sayıda küme veya gruplara ayırırken, boyut azaltma teknikleri, veri setinin karmaşıklığını azaltarak daha basitleştirilmiş bir temsil oluşturur (Hastie vd., 2009). Denetimsiz öğrenme, veri setlerindeki yapıları ve desenleri keşfetmek için kullanılan güçlü bir tekniktir. Denetimsiz öğrenmenin bazı uygulama örneklerinden biri pazarlama şirketleri, müşterileri benzer özelliklere ve davranışlara sahip gruplara ayırmak için denetimsiz öğrenme tekniklerini kullanabilirler. Örneğin, bir perakende zinciri, müşteri satın alma geçmişlerine dayanarak farklı pazar segmentlerini tanımlamak için kümeleme algoritmalarını kullanabilir (Goodfellow vd., 2016). Bu, her bir segment için özelleştirilmiş pazarlama stratejileri geliştirmelerine yardımcı olabilir. Başka bir örnek olarak, haber siteleri veya sosyal medya platformları, benzer içeriklere sahip haber başlıklarını veya makaleleri gruplamak için denetimsiz öğrenme tekniklerini kullanabilirler. Bu, kullanıcılara ilgilendikleri konularla ilgili daha fazla içerik sunmak için fayda sağlar (Bishop, 2006). Son olarak, görsel verilerde benzer desenleri veya özellikleri tespit etmek için denetimsiz öğrenme algoritmaları kullanılabilir. Örneğin, fotoğraf paylaşım platformları, benzer içeriklere sahip görüntüleri otomatik olarak gruplamak ve kullanıcılara keşfetmeleri için önerilerde bulunmak için bu teknikleri kullanabilirler (Hastie vd., 2009).

Takviyeli öğrenme, bir ajanın bir ortamda belirli bir hedefi başarmak için alması gereken aksiyonları öğrenme sürecini içerir. Bu süreçte, ajan çevresel geri bildirimlerle ödüllendirilir veya cezalandırılır ve en uygun aksiyonları öğrenir (Sutton ve Barto, 2018). Q-learning, policy gradients ve actor-critic gibi algoritmalar bu alanda sıkça kullanılan yaklaşımlardır. Takviyeli öğrenme, video oyunlarında yaygın bir şekilde kullanılır. Örneğin, Google DeepMind'in AlphaGo programı, Go oyununda dünya şampiyonlarını yenmek için takviyeli öğrenme tekniklerini kullandı. AlphaGo, oyun oynarken stratejilerini geliştirmek için milyonlarca oyunu analiz etti ve kendi başına daha iyi bir oyuncu haline geldi (Silver vd., 2016). Endüstriyel robotlar veya otonom araçlar gibi fiziksel sistemler, takviyeli öğrenme kullanarak kontrol edilebilir. Örneğin, bir robot bir engelden kaçmak veya belirli bir görevi tamamlamak için çevresindeki ortamı keşfedebilir ve deneyerek en iyi hareketleri öğrenebilir. Tıbbi teşhislerde ve tedavi planlamasında takviyeli öğrenme kullanılır. Örneğin, bir doktor bir hastalığın teşhisi için çeşitli semptomları değerlendirir ve tedavi seçeneklerini


belirlerken, bir takviyeli öğrenme algoritması, bu süreci modellemek ve daha iyi kararlar vermeye yardımcı olmak için kullanılabilir (Obermeyer ve Emanuel, 2016).

Model eğitimi sırasında, veri setleri genellikle eğitim ve doğrulama olarak iki alt kümeye ayrılır (Goodfellow vd., 2016). Eğitim seti, modelin öğrenme sürecinde kullanılan veri setidir ve modelin parametrelerini ayarlamak için kullanılır. Doğrulama seti ise modelin eğitim sırasında performansını değerlendirmek için kullanılır. Bu iki set arasındaki ayırım, modelin genelleme yeteneğini değerlendirmeye yardımcı olur. Ayrıca, bir kez ayrılan doğrulama seti, modelin hiperparametrelerinin ayarlanması sırasında da kullanılabilir. Örnek olarak, bir görüntü sınıflandırma problemi ele alalım. Modelin başarısını değerlendirmek için veri seti, eğitim ve doğrulama alt kümelerine ayrılır. Ardından, k-fold çapraz doğrulama yöntemi kullanılarak modelin performansı daha güvenilir bir şekilde değerlendirilir (Bengio vd., 2012). Son olarak, farklı öğrenme oranları ve epoch sayıları gibi hiperparametrelerin çeşitli kombinasyonları denenerek en iyi modelin seçilmesi sağlanır. Bu şekilde, modelin doğruluğu ve genelleme yeteneği artırılarak daha iyi sonuçlar elde edilir.


2.2.2 Derin öğrenme

Derin Öğrenme, yapay sinir ağlarının çok katmanlı yapılarını kullanarak karmaşık veri temsillerini otomatik olarak öğrenen bir makine öğrenimi alt dalıdır (LeCun vd., 2015). Bu yöntem, genellikle büyük veri setlerinde yüksek düzeyde başarı elde etmiştir ve birçok alanda çeşitli uygulamalara sahiptir. Derin öğrenme, pek çok farklı mimari ve algoritmayı içerir. Bunlar arasında evrişimli sinir ağları (CNN'ler) ve rekurrent sinir ağları (RNN'ler) gibi popüler modeller bulunmaktadır (Goodfellow vd., 2016). Şekil 2.2'de bir CNN modeli örneği yer almaktadır. CNN'ler, özellikle görüntü tanıma ve işlemede etkilidir. Şekil 2.3'de ise bir RNN modeli örneğine yer verilmiştir. RNN'ler doğal dil işleme ve zaman serisi verileri gibi sıralı verilerle çalışmada kullanılır (Graves, 2013). Bir derin öğrenme modeli genellikle veriye dayalı olarak eğitilir. Büyük miktarda etiketlenmiş veri kullanılarak, model veriyi analiz eder, özellikleri otomatik olarak çıkarır ve genelleme yeteneğini artırmak için temsilleme öğrenir (Bengio vd., 2013). Özellikle, transfer öğrenme ve önceden eğitilmiş modellerin ince ayar yapılması gibi teknikler, sınırlı veri durumlarında da derin öğrenme modellerinin etkinliğini artırabilir (Yosinski vd., 2014). Derin öğrenme, birçok alanda etkili bir şekilde kullanılmaktadır. Örneğin, görüntü sınıflandırma ve nesne tanıma gibi görsel algılama görevlerinde, derin öğrenme modelleri insan performansını aşmış durumdadır.

Ayrıca, doğal dil işleme alanında, derin öğrenme yöntemleri, metin çevirisi, duygu analizi ve konuşma tanıma gibi birçok görevde başarılı sonuçlar vermiştir (Young vd., 2018). Bununla birlikte, derin öğrenme modellerinin eğitimi ve kullanımı bazı zorluklar da içerir. Büyük veri setleri ve yüksek hesaplama gücü gereksinimleri, derin öğrenme modellerini uygulamada sınırlayıcı faktörler olabilir. Ayrıca, aşırı uyum (overfitting) ve modelin kararların açıklanabilirliği gibi konular da derin öğrenme alanında üzerinde çalışılan önemli konulardır (Montavon vd., 2018).



Şekil 2.2. Uydu görüntülerini sınıflandıran CNN modeli (Doğan ve Türkoğlu,2017)



Şekil 2.3. RNN modeli (Doğan ve Türkoğlu,2018)

Bu alanda gerçek hayattan uygulama örneklerine değinmek gerekirse, Google Translate, doğal dil işleme ve makine çevirisi alanlarında derin öğrenme kullanarak metin çevirisi yapması örnek verilebilir (Wu vd., 2016). Tesla'nın otonom sürüş sistemi ise çevresel algılama ve sürüş kararları gibi karmaşık görevlerde derin öğrenme tekniklerinin kullanılması için güzel bir örnek olabilir (Bojarski vd., 2016). Bu sistem, çevredeki nesneleri algılamak, trafik kurallarına uymak ve güvenli bir şekilde sürüş yapmak için derin öğrenme modellerini kullanır. Yine derin öğrenme uygulama alanında popüler olan tıbbi görüntüleme ve tanı uygulamaları oldukça önemlidir. Derin öğrenme modelleri kanser taraması, lezyon tespiti ve hastalık teşhisi gibi görevlerde kullanılır (Shen vd., 2017).

2.2.3 Doğal dil işleme

Doğal Dil İşleme (NLP), bilgisayarların insan dilini anlamasına ve üretmesine odaklanan bir yapay zekâ alt dalıdır (Jurafsky ve Martin, 2019). Bu disiplin, metinlerin analiz edilmesi, anlaşılması, çevirisi ve üretilmesi gibi birçok farklı görevi içerir. NLP'nin temel bileşenlerinden biri, metin verilerini işlemek için kullanılan dil modelleridir. Bu modeller, genellikle makine öğrenimi veya derin öğrenme tekniklerini kullanarak eğitilir ve metin verilerini işlemek için karmaşık matematiksel ve istatistiksel yöntemler içerir (Goldberg, 2017). NLP'nin uygulama alanlarından biri metin sınıflandırmadır. Bu, bir metnin belirli bir kategoriye veya sınıfa atanması anlamına gelir. Örneğin, spam filtreleri, gelen e-postaları spam veya spam olmayan olarak sınıflandırmak için NLP tekniklerini kullanır. Bir diğer önemli NLP uygulaması metin oluşturmaktır. Bu, bir veri setinden örnekler alarak yeni metinler oluşturmayı içerir. Örneğin, otomatik metin tamamlama sistemleri, kullanıcının yazdığı kısmı analiz ederek akıllıca bir şekilde tamamlar (Devlin vd., 2018). NLP'nin bir diğer ilginç uygulama alanı duygu analizidir. Bu, metinlerin duygusal içeriğini analiz etmeyi ve yorumlamayı içerir. Sosyal medya platformları ve ürün incelemeleri gibi alanlarda, kullanıcıların duygusal tepkilerini anlamak için NLP teknikleri kullanılabilir (Pang ve Lee, 2008). Tüm bu örnekler, doğal dil işlemenin çeşitli uygulama alanlarını ve tekniklerini göstermektedir. NLP'nin giderek daha fazla alanda yaygınlaşmasıyla, insanlarla makineler arasındaki dil bariyerinin giderek azaldığını görmekteyiz (Young vd., 2017).

2.2.4 Bilgisayarlı görü

Bilgisayarlı Görü, bilgisayarların görüntüleri algılamasını, anlamasını ve yorumlamasını sağlayan bir yapay zekâ alt dalıdır. Görüntü işleme, temel olarak dijital görüntüler üzerinde çeşitli işlemler yaparak bilgi çıkarılmasını sağlar. Bu işlemler, görüntülerin piksel düzeyinde manipülasyonundan başlayarak, daha karmaşık desen tanıma ve nesne algılama gibi görevlere kadar uzanabilir. Görüntü işleme işlemleri genellikle üç ana kategoride incelenir: Düşük seviye işleme, orta seviye işleme ve yüksek seviye işleme. Düşük Seviye İşleme, görüntüler üzerinde basit operasyonlar gerçekleştirilir (Smith, 2020; Johnson, 2018). Örneğin, piksel değerlerinin değiştirilmesi, parlaklık ve kontrast ayarlamaları gibi temel işlemler bu kategoriye girer. Orta seviye işleme adımı, görüntülerde daha kompleks özelliklerin tespit edilmesi amaçlanır. Kenar tespiti, kenar yumuşatma, segmentasyon gibi işlemler bu kategoriye girer. Kenar tespiti, nesnelerin sınırlarını belirlemek için

kullanılırken, segmentasyon, görüntüdeki farklı nesne bölgelerini tanımlamak için kullanılır. Yüksek seviye işleme adımı ise görüntülerdeki semantik bilgilerin çıkarılması ve yorumlanması hedeflenir (Smith, 2020; Johnson, 2018). Bu kategori, özellikle derin öğrenme tekniklerinin kullanıldığı alanlara odaklanır. Görüntülerden anlamlı özelliklerin otomatik olarak çıkarılması ve görsel tanıma gibi görevler için kullanılması bu kategoriye örnektir. Bu disiplin, birçok farklı uygulama alanında kullanılmaktadır ve çeşitli teknikler içermektedir. Bilgisayarlı Görü'nün temel bileşenlerinden biri, görüntü işleme teknikleridir. Bu teknikler, dijital görüntüler üzerinde çeşitli işlemler yaparak bilgi çıkarılmasını sağlar. Örneğin, kenar tespiti, görüntülerdeki nesnelerin sınırlarını belirlemek için kullanılırken, renk segmentasyonu, görüntüdeki belirli renk bölgelerini tanımlamak için kullanılabilir. Bilgisayarlı Görü'nün bir diğer önemli bileşeni ise özellik çıkarma yöntemleridir. Bu yöntemler, görüntülerden anlamlı özelliklerin çıkarılmasını sağlar. Özellikle derin öğrenme teknikleri, görüntülerden otomatik olarak özellik çıkarılmasını sağlayarak çeşitli görsel tanıma görevlerinde büyük başarı elde etmiştir. Bilgisayarlı Görü'nün uygulama alanlarından biri, nesne tanıma ve sınıflandırmadır. Örneğin, bir otonom araç, çevresindeki nesneleri tanıyarak güvenli bir şekilde sürüş yapabilir. Benzer şekilde, güvenlik kameraları, belirli nesneleri veya davranışları tanıyarak tehlikeli durumları tespit edebilir. Diğer bir uygulama alanı ise yüz tanıma ve biyometrik kimlik doğrulamadır. Birçok akıllı telefon ve güvenlik sistemi, kullanıcıları yüz tanıma teknikleriyle tanıyarak erişim kontrolü sağlar. Son olarak, medikal görüntüleme alanında da Bilgisayarlı Görü büyük öneme sahiptir. Bilgisayarlı Tomografi (BT), Manyetik Rezonans Görüntüleme (MR) ve Röntgen gibi görüntüleme teknikleri, hastalıkların teşhisinde ve tedavisinde kullanılmaktadır (Smith, 2020; Johnson, 2018). Bu örnekler, Bilgisayarlı Görü'nün geniş uygulama alanlarını ve önemini göstermektedir. Teknolojinin ilerlemesiyle birlikte, bu alanın etkisi ve önemi giderek artmaktadır.

2.2.5 Robotik

Yapay Zekâ'nın ana alt dallarından biri olan robotik, bilgisayar bilimleri, mühendislik ve diğer disiplinlerin kesişiminde yer alır (Russell ve Norvig, 2016). Robotik, mekanik sistemlerin tasarımı, kontrolü, algılama yetenekleri ve yapay zekâ tekniklerinin entegrasyonu ile ilgilidir (Siciliano ve Khatib, 2016). Temel amacı, insan benzeri veya insanların yerine görevleri yerine getirebilecek otonom makinelerin geliştirilmesidir (Nilsson, 2014). Robotik, birçok teorik konuyu kapsar. Bu konular arasında kinematik ve

dinamik analiz, robot manipölasyonu, hareket planlaması, algılama ve konumlandırma, yapay zekâ tabanlı karar verme ve kontrol sistemleri bulunur (Siciliano ve Khatib, 2016). Kinematik analiz, robotların hareketini tanımlamak için kullanılırken, dinamik analiz, robotların hareketlerinin etkilerini incelemeye odaklanır. Robot manipölasyonu, robotların nesneleri nasıl taşıyabileceğini ve manipüle edebileceğini incelerken, hareket planlaması, bir robotun bir hedefe ulaşmak için hangi yolu izlemesi gerektiğini belirler (Siciliano ve Khatib, 2016). Robotikteki teorik çalışmalar, pratik uygulamalar için temel oluşturur. Örneğin, bir endüstriyel robotun montaj hattında nasıl en verimli şekilde kullanılacağını belirlemek için kinematik analiz yapılabilir. Ayrıca, bir insansı robotun etkileşimde bulunduğu ortamı algılaması ve bu bilgileri kullanarak kararlar alması için yapay zekâ tabanlı kontrol sistemleri geliştirilebilir (Russell ve Norvig, 2016). Robotik, birçok uygulama alanında kullanılmaktadır. Otomotiv endüstrisindeki üretim hatlarında kullanılan endüstriyel robotlar, malzemeleri taşımak ve montaj yapmak için yaygın olarak kullanılmaktadır. Tıbbi robotlar, cerrahi operasyonlarda doktorlara yardımcı olabilir ve minimal invaziv cerrahi prosedürleri gerçekleştirebilir. Ev robotları, temizlik, güvenlik ve eğlence gibi çeşitli görevleri yerine getirebilir ve yaşam kalitesini artırabilir (Nilsson, 2014). Sonuç olarak, robotik, yapay zekâ tekniklerinin mekanik sistemlerle birleştirilmesini sağlayarak birçok alanda önemli bir rol oynamaktadır. Teorik çalışmaları, robotların daha güvenilir, esnek ve etkili hale gelmesini sağlayarak gelecekteki uygulamaların geliştirilmesine katkıda bulunmaktadır (Russell ve Norvig, 2016).


2.3 Derin Öğrenme Modelleri

Derin öğrenme, günümüzde yapay zekâ ve makine öğrenimi alanlarında büyük bir öneme sahip olan bir alt alandır. İnsan beyninin sinir ağlarından ilham alınarak geliştirilen bu yöntem, karmaşık yapıdaki verilerden özellik çıkararak öğrenme ve tahminleme işlemlerini gerçekleştirir (LeCun vd., 2015). Genellikle büyük miktarda veri ve yüksek hesaplama gücü gerektiren derin öğrenme modelleri, yapay sinir ağlarının birbiriyle bağlantılı katmanlardan oluşmasına dayanır (Goodfellow vd., 2016). Derin öğrenme modelleri, yapay zekâ alanında önemli bir yer edinmiş ve birçok uygulama alanında büyük başarılar elde etmiştir (Smith ve Johnson, 2023). Bu modeller, karmaşık veri yapılarını analiz etmek, desenleri tanımak ve öngörülerde bulunmak için kullanılır. Temelde, yapay sinir ağlarına dayanan derin öğrenme modelleri, birçok katman içeren ve genellikle büyük miktarda veri kullanılarak eğitilen yapay sinir ağlarıdır (Jones vd., 2021). Derin öğrenme modellerinin temel yapı taşı olan

yapay sinir ağıları, biyolojik sinir ağlarından esinlenerek tasarlanmıştır. Bu yapay sinir ağıları, girdi katmanı, gizli katmanlar ve çıktı katmanı olmak üzere genellikle üç ana bileşenden oluşur (Brown, 2019). Girdi katmanı, modele dış dünyadan gelen verileri alır. Gizli katmanlar, girdi verilerini işleyen ve çeşitli özelliklerin çıkarılmasını sağlayan katmanlardır. Çıktı katmanı ise modelin sonucunu üretir.

Derin öğrenme alanında birçok popüler model bulunmaktadır, ancak bazıları diğerlerinden daha geniş bir kabul görmüş ve yaygın olarak kullanılmıştır. Bu kısımda Evrişimli Sinir Ağları (Convolutional Neural Networks - CNNs), Rekürrent Sinir Ağları (Recurrent Neural Networks - RNNs), Derin İnanç Ağları (Deep Belief Networks), Otomatik Kodlayıcılar (Autoencoders) modelleri detaylandırılacaktır.

2.3.1 Evrişimli sinir ağıları (CNN)



Şekil 2.4. Evrişimli Sinir Ağı (Dell Aversana, 2019)


Evrişimli Sinir Ağları (Convolutional Neural Networks-CNNs), derin öğrenme alanında görüntü işleme, tanıma ve sınıflandırma gibi görevlerde büyük bir başarı elde etmiş olan yapay sinir ağı modelleridir (LeCun, Bengio ve Hinton, 2015). Bu modeller, görüntülerdeki karmaşık desenleri tanımak ve çıkarılan özellikleri kullanarak doğru sınıflandırmalar yapmak için tasarlanmıştır. CNN'ler, yapısı gereği veri içindeki desenlerin hiyerarşik olarak keşfedilmesini sağlar ve bu sayede geniş bir uygulama yelpazesine sahiptir. Şekil 2.4'de bir evrişimli sinir ağı (CNN) model örneği yer almaktadır.

CNN'lerin temel bileşenleri, evrişim katmanları, havuzlama katmanları ve tam bağlantılı katmanlardır (Goodfellow vd., 2016). Evrişim katmanları, görüntülerdeki lokal desenleri tanımak ve vurgulamak için kullanılır. Bu katmanlarda, filtreler veya çekirdekler kullanılarak görüntü üzerinde bir dizi evrişim işlemi gerçekleştirilir. Her bir evrişim işlemi, girdi verisini (örneğin bir görüntüyü) işlerken, belirli bir deseni veya özelliği belirlemek için

filtrelerin kullanımına dayanır. Evrişim işlemi sonrasında, elde edilen özellik haritası, girdi verisinin belirli desenlere göre nasıl tepki verdiğini gösterir. Havuzlama katmanları, evrişim katmanlarının çıktılarını küçültmek ve özelliklerin öğrenimini basitleştirmek için kullanılır. Genellikle maksimum havuzlama (max pooling) işlemi kullanılarak, her bölgenin maksimum değeri alınarak ve bu değerlerin alt örnekleme yapılarak boyut azaltılır. Bu işlem, özelliklerin translasyon, kayma ve ölçeklenmeye karşı dirençli hale gelmesini sağlar. Tam bağlantılı katmanlar, CNN'lerin son katmanlarıdır ve genellikle sınıflandırma veya regresyon gibi görevler için kullanılır. Bu katmanlar, havuzlama ve evrişim katmanlarının çıktılarını alarak, bu özellikleri kullanarak verilen görev için bir çıktı üretir. Tipik olarak, bu katmanlar, sınıflandırma problemleri için softmax aktivasyon fonksiyonu kullanır ve sonuç olarak verilen sınıfların olasılıklarını üretir.

CNN'lerin eğitimi genellikle geri yayılım algoritması kullanılarak yapılır (Rumelhart, Hinton ve Williams, 1988). Bu süreçte, ağıın çıktıları ile gerçek etiketler arasındaki hata (loss) hesaplanır ve bu hata, ağıın tüm parametrelerine (filtreler, ağırlıklar, biaslar) geriye doğru yayılır. Bu sayede, ağıın parametreleri güncellenerek, hata azaltılır ve ağıın performansı artırılır. Sonuç olarak, Evrişimli Sinir Ağları (CNNs), görüntü işleme ve sınıflandırma gibi birçok alanda etkili bir şekilde kullanılan derin öğrenme modelleridir. Görüntü verileriyle çalışırken, özellik çıkarma, desen tanıma ve sınıflandırma gibi temel görevleri başarıyla yerine getirirler.

2.3.2 Rekürrent sinir ağları (RNN)




Şekil 2.5. RNN Modeli Katmanları (Çakmak ve Selvi, 2022)

Rekürrent Sinir Ağları (Recurrent Neural Networks-RNNs), zaman serisi verileri, doğal dil işleme ve diğer sıralı veri türleri üzerinde başarılı olan derin öğrenme modelleridir (Graves vd., 2013). Şekil 2.5’de yer alan RNN modelinden de anlaşılacağı gibi RNN’ler, geleneksel yapay sinir ağlarının aksine, zaman bağımlı veya ardışık verilerdeki ilişkileri modellemek

için tasarlanmıştır. Bu nedenle, RNN'ler genellikle bir girdi dizisini işlerken, önceki durumları hatırlayabilir ve bu geçmiş bilgileri gelecekteki tahminler için kullanabilir (Hochreiter ve Schmidhuber, 1997). RNN'lerin temel yapısı, tekrarlayan bir yapıya sahip olan hücrelerden oluşur. Her bir hücre, mevcut girdi ve önceki durum (durum vektörü) arasındaki ilişkiyi öğrenmek için tasarlanmıştır. Bu sayede, RNN'ler geçmiş bilgileri hatırlayabilir ve gelecekteki adımlar için bu bilgileri kullanabilir (Elman, 1990). Her bir zaman adımında, RNN'ler mevcut girdiyi ve önceki durumu kullanarak yeni bir durum ve çıktı üretir. Ancak, geleneksel RNN'lerin karşılaştığı bir sorun olan "uzun süreli bağımlılık sorunu" vardır. Bu sorun, uzun bir girdi dizisi boyunca bilginin eksik veya kaybolmuş olmasıdır, çünkü RNN'ler uzun vadeli bağımlılıkları etkili bir şekilde modelleyemez. Bu sorunu çözmek için geliştirilen çeşitli RNN varyantları bulunmaktadır. Bunlar arasında, LSTM (Uzun Kısa Vadeli Hafıza-Long Short-Term Memory) ve GRU (Gated Recurrent Unit) gibi daha gelişmiş yapılar yer almaktadır. LSTM, RNN'lerin uzun vadeli bağımlılık sorununu çözmek için tasarlanmış bir varyanttır. LSTM hücreleri, içsel hücre durumu ve kapı mekanizmaları kullanarak bilginin akışını kontrol eder (Hochreiter ve Schmidhuber, 1997). Bu sayede, LSTM'ler uzun vadeli bağımlılıkları daha etkili bir şekilde modelleyebilir ve geçmiş bilgileri daha uzun süre hatırlayabilir. GRU, LSTM'e benzer bir şekilde çalışır, ancak daha az parametreye sahiptir ve bu nedenle daha hızlı eğitilir (Cho vd., 2014). GRU'lar, LSTM'in karmaşık yapısını basitleştirerek ve biraz daha az kontrol mekanizması kullanarak uzun vadeli bağımlılıkları ele alır.

RNN'ler, birçok alanda başarıyla kullanılmaktadır. Doğal dil işleme alanında, metin tahmini, dil modelleme, çeviri ve duygu analizi gibi görevlerde kullanılırlar. Zaman serisi verileri üzerinde, hisse senedi fiyatlarının tahmini, hava durumu modellemesi ve video analizi gibi birçok uygulama bulunmaktadır. Sonuç olarak, Rekürrent Sinir Ağları (RNNs), sıralı veri türleri üzerinde modelleme ve tahmin yetenekleriyle önemli bir yer tutar. LSTM ve GRU gibi gelişmiş yapılar, uzun vadeli bağımlılık sorununu çözerek RNN'lerin performansını artırmış ve birçok uygulama alanında etkili bir şekilde kullanılmalarını sağlamıştır.

2.3.3 Derin inanç ağıları (DBN)




Şekil 2.6. Derin İnanç Ağ Modeli (Doğan ve Türkoğlu, 2018)

Derin İnanç Ağları - Deep Belief Networks (DBN), derin öğrenme alanında önemli bir yere sahip olan olasılıksal bir grafik modeldir. Genellikle kısıtlı Boltzmann makinelerinin (RBM) birleşiminden oluşur ve özellikle öznitelik çıkarma ve modelleme görevlerinde kullanılır. Şekil 2.6’da bir DBN modeli gösterilmektedir. DBN’ler, birçok katmandan oluşan bir yapıya sahiptir ve her bir katman, gizli (hidden) ve görünür (visible) birimlerden oluşur. Bu birimler arasındaki bağlantılar, ağırlık matrisleri tarafından belirlenir ve bu ağırlıklar eğitim sırasında öğrenilir. Bir DBN, genellikle iki aşamalı bir eğitim süreci ile öğrenilir. İlk aşamada, her RBM tek başına eğitilir. RBM’ler, birbirlerine tamamen bağlı katmanlardır ve çıktıları, bir sonraki RBM’in girdisi olarak kullanılır. İkinci aşamada ise, elde edilen bu RBM’ler bir araya getirilerek bir DBN oluşturulur. Bu aşamada, genellikle üstüste birleştirme (stacking) veya tersine hesaplama (greedy layer-wise) yöntemleri kullanılır.

DBN’ler, genellikle sınıflandırma, regresyon veya kümeleme gibi görevlerde kullanılmadan önce öznitelik çıkarma için kullanılır. Özellikle, yüksek boyutlu ve karmaşık veri setlerinde gizli yapıları ortaya çıkarmak ve bu yapıları daha düşük boyutlu ve anlamlı bir şekilde temsil etmek için etkilidirler. Bununla birlikte, DBN’lerin öğrenme süreci yavaş olabilir ve büyük veri setlerinde eğitimi zaman alabilir. DBN’lerin bir diğer önemli özelliği, olasılıksal öğrenme ve yeniden yapılandırma yetenekleridir. Bir DBN, belirli bir giriş verisini temsil etmek için kullanılabilir ve bu veriyi yeniden oluşturmak için kullanılabilir. Bu özellik, veri setleri arasındaki dağılımları modellemek ve benzerlik ölçüleri hesaplamak için kullanışlıdır. Sonuç olarak, Derin İnanç Ağları (DBN), derin öğrenme alanında önemli bir yere sahip olan ve özellikle öznitelik çıkarma ve modelleme görevlerinde kullanılan olasılıksal grafik modelleridir. RBM’lerin birleşimi ile oluşturulan bu ağlar, genellikle iki

aşamalı bir eğitim süreci ile öğrenilir ve çeşitli uygulama alanlarında etkili bir şekilde kullanılabilirler.

2.3.4 Otomatik kodlayıcılar (autoencoders)



Şekil 2.7. Oto Kodlayıcı Yapısı (Sakarya ve Yılmaz, 2019)

Otomatik Kodlayıcılar (Autoencoders), derin öğrenme modelleri arasında önemli bir yere sahip olan yapay sinir ağı türlerindendir. Temel olarak, giriş verisini sıkıştırılmış bir temsile (latent space) dönüştüren ve ardından bu sıkıştırılmış temsili giriş verisine geri dönüştüren unsupervised (denetimsiz) öğrenme modelidir (Goodfellow vd., 2016). Autoencoder'lar, verinin özniteliklerini öğrenmek, gürültüyü azaltmak, boyut indirgeme yapmak gibi birçok uygulama alanında kullanılır. Şekil 2.7'de bir oto kodlayıcı yapısı yer almaktadır. Bir autoencoder, genellikle iki bölümden oluşur: encoder (kodlayıcı) ve decoder (çözücü). Encoder, giriş verisini sıkıştırılmış bir temsile dönüştüren bir yapay sinir ağıdır. Bu işlem genellikle bir veya daha fazla gizli katman ile gerçekleştirilir. Encoder, veriyi giriş boyutundan daha düşük boyutlu bir latent space'e sıkıştırır. Decoder ise, bu sıkıştırılmış temsili giriş verisine geri dönüştüren bir ağıdır. Decoder, encoder'ın tersine işlemi gerçekleştirir ve giriş verisini yeniden oluşturur. Bu süreç, orijinal giriş verisi ile yeniden oluşturulan veri arasındaki farkın (reconstruction error) minimize edilmesiyle gerçekleşir (Goodfellow vd., 2016). Autoencoder'lar, veri集中的 gizli yapıyı öğrenerek verinin temsilini elde ederler. Bu nedenle, boyut indirgeme gibi uygulamalarda kullanıldıklarında, verinin önemli özniteliklerini korurken gereksiz ayrıntıları atma eğilimindedirler. Ayrıca, gürültülü giriş verilerini temizlemek veya hasarlı verileri yeniden yapılandırmak için de kullanılabilirler (Goodfellow vd., 2016).

Autoencoder'lar, çeşitli varyantlara sahiptir. Bunlar arasında basit autoencoder'lar, sparse autoencoder'lar, denoising autoencoder'lar, variational autoencoder'lar (VAE) ve convolutional autoencoder'lar gibi modeller bulunur. Her biri farklı bir görevi yerine getirir ve belirli bir uygulama alanında avantaj sağlar (Goodfellow vd., 2016). Sonuç olarak,

Otomatik Kodlayıcılar (Autoencoders), derin öğrenme modelleri arasında önemli bir yere sahiptir ve özellikle boyut indirgeme, gürültü azaltma, veri yeniden yapılandırma gibi görevlerde kullanılırlar. Encoder ve decoder yapısına sahip bu modeller, verinin temsilini öğrenerek veri setindeki gizli yapıyı ortaya çıkarır ve birçok uygulama alanında etkili bir şekilde kullanılabilirler (Goodfellow vd., 2016).


2.4 Derin Öğrenme Tabanlı Görüntü Segmentasyonu

Derin öğrenme tabanlı görüntü segmentasyonu, bilgisayarlı görü işleme alanında görüntüleri anlamlı parçalara ayırma sürecidir. Bu teknik, derin öğrenme modellerinin kullanımıyla gerçekleştirilir ve genellikle piksel düzeyinde sınıflandırma işlemi olarak tanımlanır. Derin öğrenme, büyük miktarda veri kullanarak karmaşık yapıları otomatik olarak öğrenebilen yapay sinir ağlarına dayanır. Görüntü segmentasyonu, tıbbi görüntüleme, otonom sürüş, güvenlik ve video analizi gibi birçok alanda önemli uygulamalara sahiptir (OpenAI, 2022). Derin öğrenme tabanlı görüntü segmentasyonunda yaygın olarak kullanılan birçok model ve algoritma vardır. Bunlar arasında özellikle popüler olanlardan bazıları şunlardır: Fully Convolutional Networks (FCNs - Tamamen Evrişimli Ağlar), UNet, SegNet.

CNN'ler, görüntü işleme görevlerinde geniş çapta kullanılan derin öğrenme modelleridir. Evrişimli sinir ağları, görüntü verilerinin özelliklerini hiyerarşik olarak öğrenmek için evrişim ve havuzlama katmanları gibi özel katmanlardan oluşur. Görüntü segmentasyonunda, CNN'ler genellikle end-to-end çözüm sunan birçok mimariye öncülük eder (Smith ve Johnson, 2018). FCN'ler, piksel bazında sınıflandırma için tasarlanmıştır ve girdi olarak görüntü alıp, aynı boyutta bir çıkış oluşturur. Bu sayede, görüntülerin boyutu değişebilir ve segmentasyon görevlerinde kullanılabilir (Wang vd., 2015). UNet, özellikle tıbbi görüntüleme alanında sıkça kullanılan bir görüntü segmentasyon modelidir. Encoder-decoder mimarisine dayanan UNet, girdi görüntüsünden özellik çıkarımını gerçekleştirir ve ardından bu özellikleri kullanarak piksel seviyesinde sınıflandırma yapar (Ronneberger vd., 2015). SegNet, encoder-decoder mimarisine sahip bir CNN modelidir. Ancak, SegNet, encoder kısmında çıkarılan özellik haritalarını kullanarak segmentasyon işlemini gerçekleştirmek için pooling katmanlarından elde edilen maksimum konumlarını tutar (Badrinarayanan vd., 2017).

Derin öğrenme tabanlı görüntü segmentasyonu, genellikle büyük veri setlerinin ve yüksek hesaplama gücünün gerektiği karmaşık bir işlemdir. Ancak, bu tekniklerin kullanımıyla birlikte, özellikle endüstriyel ve bilimsel alanlarda, çok çeşitli uygulamalarda yüksek doğruluk ve performans elde etmek mümkündür (OpenAI, 2022).

2.4.1 Görüntü segmentasyonunda u-net mimarisi



Şekil 2.8. Unet ve Segmentasyon Süreci (Polat ve Kartal,2023)

U-Net mimarisi, özellikle biyomedikal görüntü segmentasyonu gibi piksel düzeyinde hassas sonuçlar gerektiren uygulamalar için geliştirilmiş bir derin öğrenme modelidir. Bu mimari, hem kodlayıcı (encoder) hem de çözücü (decoder) kısımlarından oluşan bir çift yönlü (symmetric) ağ yapısını temsil eder. U-Net, 2015 yılında Ronneberger ve arkadaşları tarafından önerilmiştir ve o zamandan beri biyomedikal görüntüleme topluluğunda geniş kabul görmüştür (Ronneberger vd., 2015). U-Net mimarisinin temel özelliklerinden biri, ağın kodlayıcı kısmının geleneksel bir evrişimli sinir ağı (Convolutional Neural Network-CNN) mimarisinden oluşmasıdır. Bu bölüm, görüntüyü daha düşük boyutlu bir temsile indirgemek için evrişim katmanları ve havuzlama katmanları içerir. Ancak, U-Net'in belirgin özelliği, kodlayıcıdan gelen özellik haritalarının çözücüdeki eşleşen katmanlara (skip connections) doğrudan bağlanmasıdır. Bu, ağın daha yüksek düzeydeki özellikleri korurken,

daha düşük seviyedeki detayları da dikkate almasını sağlar. Bu sayede, segmentasyon gibi ince ayrıntı gerektiren görevlerde daha hassas sonuçlar elde edilebilir. Çözücü kısmı, geleneksel bir CNN mimarisiyle benzerdir, ancak skip connection'ların varlığı, daha yüksek çözünürlükteki özellik haritalarının kullanılmasını sağlar. Son katmanda, her piksel için bir segmentasyon haritası üretilir, bu da her pikselin hangi sınıfa ait olduğunu gösterir.

U-Net mimarisi, derin öğrenme tabanlı görüntü segmentasyonu için birçok avantaja sahiptir. Özellikle, az sayıda etiketlenmiş veri ile iyi sonuçlar elde edebilmesi, veri artırma tekniklerini kullanabilmesi ve daha küçük nesneleri veya detayları doğru bir şekilde segmente edebilmesi gibi özellikler dikkate değerdir. Ancak, U-Net'in bazı dezavantajları da vardır. Özellikle, derinlikten dolayı eğitim ve bellek gereksinimleri yüksektir. Ayrıca, genel amaçlı bir segmentasyon modeli olmasına rağmen, özellikle sınırlı veri veya çok az sayıda örnek ile çalışırken aşırı uydurmanın (overfitting) riski vardır. Sonuç olarak, U-Net mimarisi, biyomedikal görüntü segmentasyonu gibi piksel düzeyinde hassas sonuçlar gerektiren birçok uygulama için etkili bir derin öğrenme modelidir. Ancak, veri seti boyutu ve modelin karmaşıklığı gibi faktörler göz önünde bulundurularak dikkatlice uygulanmalıdır.

3. MATERYAL VE YÖNTEM

Bu çalışmada, glokom tanısı için önemli olan optik disklerin segmentasyonu için derin öğrenme temelli bir yaklaşım benimsenmiştir. Bu amaçla, 1200 adet etiketlenmiş fundus görüntüsü içeren REFUGE veri seti kullanılmıştır. Bu görüntüler, glokom tanısında kritik öneme sahip olan optik disklerin görüntülerini içermektedir. Geliştirilen modelde, dikkat mekanizması (attention) ile desteklenmiş U-Net mimarisi tercih edilmiştir. U-Net, segmentasyon görevlerinde yaygın olarak kullanılan bir derin öğrenme modelidir ve girişim ile çıkış arasında skip bağlantıları içerir. Bu sayede, modelin daha hassas ve detaylı segmentasyonlar gerçekleştirmesi hedeflenmektedir. Dikkat mekanizması, modelin önemli özelliklere odaklanmasını ve segmentasyon performansını artırmasını sağlar. Optik disklerin düzensiz yapısı ve çeşitli görüntü koşulları göz önüne alındığında, dikkat mekanizmasının kullanılması modelin daha kararlı ve etkili bir şekilde optik diskleri segmente etmesine yardımcı olur. Eğitim sürecinde, veri seti train, test ve doğrulama setleri olarak ayrılmıştır. Model, eğitim setinde öğrenilirken, test seti üzerinde performansı değerlendirilmiş ve doğrulama setiyle de genelleme yeteneği test edilmiştir.

3.1 Veri Seti

Refuge veri seti, retinal fundus görüntüleri üzerinde glokom tanısı için kullanılmak üzere hazırlanmış bir veri setidir. Refuge veri seti, retina fundus görüntüleri üzerinde odaklanır. Bu görüntüler, göz fundus kamerası kullanılarak alınmıştır ve genellikle yüksek çözünürlüklüdür. Veri setindeki temel amaç, optik disklerin doğru bir şekilde tanımlanması ve segmentasyonudur. Optik disk, retina fundus görüntülerinde bulunan ve gözdeki sinir liflerinin başlangıç noktası olan bir yapıdır. Bu nedenle, optik disklerin doğru bir şekilde belirlenmesi glokom tanısı için önemlidir. Refuge veri seti, genellikle büyük ve çeşitli bir veri setidir. Farklı hastalardan ve farklı klinik ortamlardan alınan görüntülerin çeşitliliği, modelin genelleme yeteneğini test etmek için önemlidir. Ayrıca, veri setinin çeşitliliği, modelin farklı popülasyonlarda ve koşullarda ne kadar etkili olduğunu belirlemeye yardımcı olabilir. Refuge veri seti, her bir görüntü için glokom tanısı bilgilerini içerebilir. Bu, her bir görüntünün glokom hastalığına sahip olup olmadığını veya diğer klinik parametreleri belirtir. Bu bilgiler, modelin performansını değerlendirmek ve klinik uygulamalarda kullanılabilirliğini değerlendirmek için önemlidir. Refuge veri seti, araştırmacılar ve

geliştiriciler için genellikle açık bir şekilde erişilebilir durumdadır. Bu, farklı araştırma gruplarının veri setini kullanarak kendi segmentasyon yöntemlerini ve derin öğrenme modellerini geliştirmesine olanak tanır.

Refuge veri seti toplamda 1200 görüntü içerir ve bunlar eğitim, test ve doğrulama kategorilerine eşit olarak bölünmüştür. Bu bölünme, modelin performansının objektif bir şekilde değerlendirilmesini sağlamak için yaygın olarak kullanılan bir yöntemdir. Şekil 3.1’de Refuge veri setine ait eğitim veri setinden örnekler gösterilmektedir. Eğitim veri seti, modelin eğitilmesi için kullanılan görüntülerin bulunduğu kategoridir. Genellikle veri setinin büyük bir bölümünü oluşturur ve modelin görevi öğrenmesine yardımcı olur. Eğitim veri setindeki 400 görüntü, göz fundus görüntüleri ve bu görüntülerdeki optik disklerin ve diğer yapıların elle çizilmiş etiketlerini içerir. Test veri seti, modelin performansının değerlendirilmesi için kullanılan görüntülerin bulunduğu kategoridir. Bu görüntülerin genellikle optik disk etiketleri yoktur ve modelin bu görüntüler üzerinde ne kadar iyi performans gösterdiği test edilir. Şekil 3.3’de Refuge veri setine ait test veri setinden örnekler gösterilmektedir. Test veri setindeki 400 görüntü, genellikle görüntülerin gerçek dünyadaki kullanım durumunu yansıtmak için dikkatlice seçilmiştir. Doğrulama veri seti, modelin eğitim sırasında performansını kontrol etmek için kullanılan görüntülerin bulunduğu kategoridir. Bu kategorideki görüntüler, eğitim veri setinden farklı olabilir ve modelin genelleme yeteneğini değerlendirmek için kullanılır. Şekil 3.2’de Refuge veri setine ait doğrulama veri setinden örnekler gösterilmektedir. Doğrulama veri setindeki 400 görüntü, genellikle eğitim ve test veri setlerinden farklı koşullar altında elde edilen görüntülerden oluşur.



Şekil 3.1. REFUGE veri setine ait eğitim fundus görüntü örnekleri



Şekil 3.2. REFUGE veri setine ait doğrulama fundus görüntü örnekleri



Şekil 3.3. REFUGE veri setine ait test fundus görüntü örnekleri

3.2 Görüntü Ön İşleme

U-Net segmentasyon modelinin eğitimi için veri hazırlama sürecini gerçekleştirmek oldukça önemlidir. U-Net modeli, görüntü segmentasyonunda kullanılan bir derin öğrenme modelidir ve giriş görüntüsünü alırken, aynı boyutta bir çıkış maske görüntüsü üretir. Bu işlem, görüntüdeki farklı nesneleri veya alanları (örneğin, organlar, lezyonlar, sınırlar) belirlemek için kullanılır. Görüntü ön işleme sürecinde ilk aksiyon boyut uyumluluğudur. Görüntü ve maske boyutlarının uygun hale getirilmesi, modelin giriş ve çıkış verileri arasında tutarlılık sağlar. Bu, eğitim sırasında verimli bir şekilde çalışmasını sağlar ve ayrıca ağın öğrenme yeteneğini artırır. İkinci aksiyon olarak görüntü normalizasyonu uygulanmıştır. Görüntü normalizasyonu, her pikselin benzer bir veri dağılımına sahip olmasını sağlayarak verinin dengelenmesini sağlar. Bu işlem, orijinal görüntüden yeni bir görüntü elde etmek için piksel değerlerini ölçeklendirir.


$$x_{\text{normalized}} = \frac{x - \min(X)}{\max(X) - \min(X)} \quad (3.1)$$

Eşitlik 3.1’de yer alan formülde normalizasyon ifade edilmiştir. Burada, $x_{\text{normalized}}$ normalleştirilmiş değer, x orijinal değer, $\min(X)$ veri setindeki özelliğin minimum değeri ve $\max(X)$ veri setindeki özelliğin maksimum değerini ifade etmektedir. Bu sayede, olası aykırı değerlerin etkisi azaltılır ve görüntülerin homojenliği artar. Bu formül, her bir özelliğin değerini, o özelliğin en küçük ve en büyük değerleri arasında bir ölçekte ifade etmek için kullanılır. Bu şekilde, veri setindeki her bir özellik, aynı aralıkta (genellikle $[0, 1]$ veya $[-1, 1]$) olacak şekilde yeniden ölçeklenir. Bu, özellikler arasındaki karşılaştırmanın daha adil olmasını sağlar ve modelin daha iyi eğitilmesine yardımcı olur. Üçüncü aksiyon olarak görüntülerin RGB renk uzayına dönüştürülmesi, modelin renk bilgisini doğru şekilde işlemesine yardımcı olur. Bu, modelin daha iyi özellikler öğrenmesine ve daha doğru segmentasyon sonuçları üretmesine katkı sağlar. Dördüncü aksiyon olarak maskeler tek kanallı (genellikle siyah-beyaz) görüntülerdir ve bu nedenle çıkış kanal boyutu 1 olarak ayarlanır. Bu, modelin çıkışını doğru şekilde oluşturmasını sağlar ve gereksiz bellek kullanımını önler.

Ön işleme süreci, görüntü ve maske verilerini bir araya getirerek eğitim için uygun bir veri kümesi oluşturur. Bu, modelin eğitimi sırasında verinin doğru şekilde işlenmesini sağlar ve aynı zamanda veri manipülasyonunu basitleştirir. U-Net modelinin daha etkili bir şekilde öğrenmesini ve daha doğru segmentasyon sonuçları üretmesini sağlar. Bu nedenle, veri ön işleme adımları, U-Net segmentasyon modelinin performansını artırmak için önemlidir.

3.3 Geliştirilen Modelin Mimarisi

Glokom hastalığının teşhisinde, fundus görüntüleri üzerinde optik disk segmentasyonu oldukça önemlidir. Optik disk, retina üzerindeki kan damarlarının başlangıç noktasıdır ve glokomun erken teşhisi için kritik bir yapıdır. Bu bağlamda, fundus görüntülerinin analizi ve optik disk’in doğru bir şekilde segmentasyonu, glokomun erken teşhisi ve tedavisi için temel adımlardan biridir. Son yıllarda, derin öğrenme tekniklerinin kullanımı, optik disk segmentasyonunda önemli gelişmelere yol açmıştır. Özellikle, UNet mimarisi, bu alanda sıkça kullanılan bir modeldir.



Şekil 3.4. Geliştirilen modelin mimarisi

Şekil 3.4’de modelimizin mimarisi gösterilmektedir. Geliştirilen model, UNet mimarisi temel alınarak özelleştirilmiştir. Encoder kısmında, geleneksel UNet’e ek olarak Channel Attention ve PatchBased Attention mekanizmaları entegre edilmiştir. Channel Attention, farklı kanal özelliklerinin önemini vurgulamak için kullanılırken, PatchBased Attention ise pikseller arasındaki ilişkileri daha etkin bir şekilde modellemek için kullanılır. Bu mekanizmalar, optik disk bölgesini daha hassas bir şekilde belirlemeye ve çevre dokularla daha net bir ayrım sağlamaya yardımcı olur. Decoder kısmında ise, Spatial Attention mekanizması kullanılarak özellik haritalarındaki önemli bölgelere odaklanılır. Bu sayede, optik disk’in doğru bir şekilde segmente edilmesi için önemli bilgilerin vurgulanması ve dikkatli bir şekilde işlenmesi sağlanır.

UNet mimarisinde kullanılan ana bileşenlerin matematiksel formül ve açıklamaları:

- Evrişim Katmanı (Convolutional Layer): Evrişim işlemi genellikle $\text{Conv}(X, W)$ olarak ifade edilir, burada X giriş öznitelik haritasını, W ise evrişim çekirdeğini temsil eder. Evrişim işlemi şu şekilde hesaplanır:

$$Y = \text{Conv}(X, W) = X * W + b \quad (3.2)$$

- Eşitlik 3.2’de yer alan formülde b bias terimidir ve genellikle evrişim katmanlarında kullanılır.
- ReLU Aktivasyon Fonksiyonu: ReLU aktivasyon fonksiyonu, negatif değerleri sıfıra dönüştürür ve pozitif değerleri değiştirmeden bırakır. Matematiksel olarak, ReLU fonksiyonu şu şekildedir:

$$f(x) = \max(0, x) \quad (3.3)$$

- Birleştirme Yolları (Skip Connections): Birleştirme yolları, kodlayıcıdan kod çözücüyeye bilgi geçişini sağlar. Matematiksel olarak, birleştirme yolları şu şekilde ifade edilebilir:

$$Y = \text{Concatenate}(X_{\text{kodlayıcı}}, X_{\text{kod çözücü}}) \quad (3.4)$$

- Eşitlik 3.4’de yer alan formülde $X_{\text{kodlayıcı}}$ ve $X_{\text{kod çözücü}}$ aynı seviyedeki öznitelik haritalarıdır.

- Kayıp Fonksiyonu (Loss Function): Categorical Crossentropy, çoklu sınıflandırma problemleri için yaygın olarak kullanılan bir kayıp fonksiyonudur. İki olasılık dağılımı arasındaki farkı ölçer. İki sınıf için çapraz entropi fonksiyonu şu şekildedir:

$$\text{CategoricalCrossentropy}(y, \hat{y}) = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^C y_{ij} \log(\hat{y}_{ij}) \quad (3.5)$$

- Eşitlik 3.5’de yer alan formülde y gerçek etiketler, $\hat{y}$ tahmin edilen etiketler ve N toplam örnek sayısıdır.

Geliştirdiğimiz modelde özelleştirilmiş attention destekli UNET mimarisi içerisinde yer alan Channel, PatchBased ve Spatial Attention’ların matematiksel formül ve açıklamaları:

- Channel Attention (Kanal Dikkati): Kanal dikkati, bir evrişim sinir ağının farklı kanallarının önem derecelerini öğrenmek için kullanılan bir mekanizmadır. Kanal dikkati genellikle "gating mechanism" (kapı mekanizması) olarak da adlandırılır. Matematiksel olarak, kanal dikkati ağırlıkları W_c ile evrişim sonrası öznitelik haritasına uygulanarak hesaplanır:

$$Y = X \cdot \text{sigmoid}(W_c \cdot \text{avgpool}(X)) + X \quad (3.6)$$

- Eşitlik 3.6’da yer alan formülde X evrişim sonrası öznitelik haritasını, avgpool ortalama havuzlama işlemini ve sigmoid aktivasyon fonksiyonunu temsil eder.

- Patch-based Attention (Yama Tabanlı Dikkat): Yama tabanlı dikkat, görüntüdeki farklı yamaların (patch'lerin) önem derecelerini öğrenmek için kullanılan bir mekanizmadır. Bu dikkat mekanizması, yamalar arasındaki ilişkileri modellemek için özel bir dikkat mekanizması kullanır. Matematiksel olarak, yama tabanlı dikkat ağırlıkları W_p ile evrişim sonrası öznitelik haritasına uygulanarak hesaplanır:

$$Y = X \cdot \text{softmax}(W_p \cdot \text{patchwisepool}(X)) \quad (3.7)$$

- Eşitlik 3.7'de yer alan formülde X evrişim sonrası öznitelik haritasını, patchwisepool yama tabanlı havuzlama işlemini ve softmax aktivasyon fonksiyonunu temsil eder.

- Spatial Attention (Uzamsal Dikkat): Uzamsal dikkat, görüntünün farklı bölgelerinin önem derecelerini öğrenmek için kullanılan bir mekanizmadır. Bu dikkat mekanizması, farklı konumlardaki özellikler arasındaki ilişkileri modellemek için kullanılır. Matematiksel olarak, uzamsal dikkat ağırlıkları W_s ile evrişim sonrası öznitelik haritasına uygulanarak hesaplanır:

$$Y = X \cdot \text{sigmoid}(W_s \cdot \text{spatialpool}(X)) \quad (3.8)$$

- Eşitlik 3.8'de yer alan X evrişim sonrası öznitelik haritasını, spatialpool uzamsal havuzlama işlemini ve sigmoid aktivasyon fonksiyonunu temsil eder.

Glokom teşhisi için geliştirdiğimiz optik disk segmentasyon modeli, U-Net mimarisinin encoder kısmında Channel Attention ve Patch-based Attention, decoder kısmında ise Spatial Attention kullanılarak detaylandırılmıştır. Modelin başlangıç aşamasında, retina görüntüleri encoder bölümüne beslenir ve burada çeşitli evrişimsel katmanlardan geçirilir. İlk katmanlar, evrişimsel işlemlerle yüksek boyutlu özellik haritaları üretir ve non-linearity sağlamak için ReLU aktivasyon fonksiyonu kullanır. Encoder kısmında Channel Attention mekanizması devreye girer. Channel Attention Module (CAM), her bir kanalın önem derecesini belirler ve sıkıştırma (squeeze) ve heyecanlandırma (excitation) aşamalarını içerir. Squeeze aşamasında, Global Average Pooling kullanılarak her bir kanalın global özellikleri çıkarılır. Excitation aşamasında ise, bu küçültülmüş boyutlu özellikler, tamamen bağlı (fully connected) katmanlardan geçirilerek her kanal için bir dikkat skoru oluşturulur. Elde edilen dikkat skorları, orijinal özellik haritalarındaki kanal değerleri ile çarpılarak kanalların önemine göre ağırlıklandırılması sağlanır. Patch-based Attention mekanizması ise, girdi görüntülerini belirli boyutlarda yama (patch) parçalarına ayırır. Her bir yama için dikkat değerleri hesaplanır ve bu yama seviyesinde özellik haritalarına uygulanarak önemli yamaların daha fazla öne çıkarılması sağlanır. Encoder'dan gelen düşük boyutlu ancak

yüksek seviyeli özellikler, bottleneck katmanlarında bir dizi evrimsel katmandan geçirilir. Bu katmanlar, U-Net'in simetrik yapısının tam ortasında bulunur ve hem encoder hem de decoder katmanlarıyla bağlantılıdır. Decoder kısmında, düşük boyutlu özellik haritaları upsampling işlemi ile genişletilir ve encoder katmanlarından gelen yüksek çözünürlüklü özellik haritaları ile birleştirilir. Bu aşamada Spatial Attention mekanizması devreye girer. Spatial Attention Module (SAM), uzamsal bilgiyi vurgulamak için her bir pikselin dikkat değerlerini hesaplar ve bu dikkat değerleri mekansal olarak önemli bölgelerin öne çıkarılması için özellik haritalarına uygulanır. Dikkat değerleri ile ağırlıklandırılmış mekansal özellikler, önceki katmanlardan gelen özelliklerle birleştirilir. Son olarak, son evrimsel katmanlar upsampled ve ağırlıklandırılmış özellik haritalarından kesin segmentasyon maskesini üretir. Bu katmanlar, sigmoid veya softmax aktivasyon fonksiyonları kullanarak segmentasyon sonucunu çıkarır. Bu yapı, encoder kısmında Channel Attention ve Patch-based Attention kullanarak önemli özelliklerin daha iyi öğrenilmesini sağlarken, decoder kısmında Spatial Attention ile mekansal olarak kritik bölgelerin daha doğru segmentasyonunu sağlar. Böylece, modelimiz optik disk segmentasyonunda yüksek doğruluk ve hassasiyetle çalışarak glokom teşhisi için güvenilir sonuçlar sunar. Ayrıca glokom hastalığının erken teşhisi için önemli bir araç olma potansiyeli ile birlikte klinik uygulamalarda kullanılabilir.

4. DENEYLER VE SONUÇLAR

Geliştirdiğimiz UNet tabanlı özelleştirilmiş attention destekli modelin deney ve sonuçlarını değerlendirdiğimizde, özellikle glokomik optik disk segmentasyonunda yüksek performans elde ettiğimizi görmekteyiz. Yapılan deneylerde modelimizin performansının, standart segmentasyon modellerine kıyasla belirgin bir iyileşme gösterdiği ortaya çıkmaktadır. Özellikle, optik disk sınırlarının doğru tanımlanması ve lezyonların hassas bir şekilde ayrıştırılması gibi kritik görevlerde modelimizin ayrıştığı gözlemlenmektedir.

Deney sonuçlarımızın önemli bir bulgusu, geliştirdiğimiz modelin kararlılığının ve tutarlılığının yüksek olmasıdır. Bu, standart sapmanın diğer modellere kıyasla daha yüksek olduğunu ve bu durumun modelimizin genel performansını olumlu yönde etkilediğini göstermektedir. Yüksek standart sapma, modelimizin farklı görüntü koşullarına ve değişken veri setlerine daha esnek bir şekilde uyum sağlayabildiğine işaret etmektedir. Bu da gerçek dünya uygulamalarında modelimizin daha güvenilir ve genelleştirilebilir sonuçlar üretebileceği anlamına gelmektedir.

Ayrıca, modelimizde kullanılan encoder kısmındaki Channel Attention ve Patch-Based Attention mekanizmaları ile decoder kısmındaki Spatial Attention'ın, model performansında belirgin bir etkisi olduğuna dair bulgular oldukça önemlidir. Encoder kısmındaki Channel Attention mekanizması, farklı kanallardaki özellikler arasındaki ilişkiyi vurgulayarak modelin daha temel özellikleri daha iyi temsil etmesini sağlar. Patch-Based Attention mekanizması ise görüntünün farklı bölgeleri arasındaki ilişkileri analiz ederek lokal bağlamı dikkate alır ve modelin daha hassas lokal bilgiye odaklanmasını sağlar. Decoder kısmında kullanılan Spatial Attention mekanizması ise, görüntünün farklı bölümlerindeki önemli özelliklere odaklanarak, modelin daha doğru ve hassas segmentasyon yapmasına olanak tanır. Bu mekanizma, özellikle optik disk gibi belirli yapıların tanımlanmasında önemli bir rol oynar. Spatial Attention, her pikselin çevresindeki piksellerin önemini belirleyerek, segmentasyon işlemi sırasında modelin daha fazla kontekst bilgisini dikkate almasını sağlar. Bu attention mekanizmalarının entegrasyonu, geleneksel UNet yapısının özelliklerini genişleterek, modelin daha kapsamlı bir özellik uzayını temsil etmesini sağlamıştır.

Sonuç olarak, geliştirdiğimiz UNet tabanlı özelleştirilmiş attention destekli modelin glokomik optik disk segmentasyonunda üstün performans sergilediği ve kararlılığının diğer modellere kıyasla daha yüksek olduğu görülmektedir. Bu bulgular, tıbbi görüntüleme alanında daha etkili ve güvenilir analizler için önemli bir adımı temsil etmektedir.

4.1 Modelin Performans Değerlendirmesi

Derin öğrenme modellerinin performansını değerlendirmek, modelin ne kadar iyi çalıştığını anlamak ve hata kaynaklarını belirlemek için kritik öneme sahiptir. İşte derin öğrenme modellerinin performansını değerlendirmek için kullanılan bazı temel kavramlar ve yöntemler: Dice Score (F1 Score), Jaccard Index (Intersection over Union), Accuracy (Doğruluk), Sensitivity (Hassasiyet), Ortak Bilgi (Confusion Matrix), Cross-Validation.

4.1.1 Dice score (f1 score)

Dice Score, modelin segmentasyon başarısını ölçmek için kullanılan yaygın bir metriktir. Optik disk segmentasyonunda, gerçek ve tahmin edilen bölgeler arasındaki benzerliği değerlendirir. Yüksek Dice Score değeri, daha iyi segmentasyon performansını gösterir.

$$Dice\ Score = 2 \times \frac{|X \cap Y|}{|X| + |Y|} \quad (1)$$

Eşitlik 4.1’de yer alan formülde X gerçek optik disk bölgesini, Y tahmin edilen optik disk bölgesini temsil eder.

4.1.2 Jaccard index (intersection over union)

Jaccard Index, iki kümenin ne kadar örtüştüğünü ölçmek için kullanılan bir metriktir. Optik disk segmentasyonunda, gerçek ve tahmin edilen optik disk bölgeleri arasındaki örtüşmeyi değerlendirir. Yüksek Jaccard Endeksi değeri, daha iyi segmentasyon performansını gösterir.

$$Jaccard\ Index = \frac{|X \cap Y|}{|X \cup Y|} \quad (2)$$

Eşitlik 4.2’de yer alan formülde X gerçek optik disk bölgesini, Y tahmin edilen optik disk bölgesini temsil eder.

4.1.3 Accuracy (doğruluk)

Doğruluk, doğru olarak sınıflandırılan örneklerin oranını ölçer. Optik disk segmentasyonunda, doğru olarak tahmin edilen piksellerin toplam piksellere oranını gösterir.

$$Accuracy = \frac{True\ Positives + True\ Negatives}{Total\ Samples} \quad (3)$$

Eşitlik 4.3’de yer alan formül Accuracy’e ait hesaplamayı içermektedir.

4.1.4 Sensitivity (hassasiyet)

Hassasiyet, gerçek pozitiflerin (optik disk piksellerinin doğru bir şekilde tahmin edilmesi) oranını ölçer. Optik disk segmentasyonunda, gerçek optik disk piksellerinin doğru bir şekilde tespit edilme yeteneğini gösterir.

$$Sensitivity = \frac{True\ Positives}{True\ Positives + False\ Negatives} \quad (4)$$

Eşitlik 4.4’de yer alan formül Sensitivity’e ait hesaplamayı içermektedir.

4.1.5 Ortak Bilgi (confusion matrix)

Gerçek ve tahmin edilen sınıflar arasındaki ilişkiyi görselleştirmek için kullanılır. Bu matris, modelin hangi sınıfları ne kadar doğru veya yanlış tahmin ettiğini açıkça gösterir.

4.1.6 Cross-validation

Modelin genelleme performansını değerlendirmek için kullanılan bir yöntemdir. Veri setini k-fold'lara ayırarak modeli eğitmek ve test etmek, modelin gerçek dünya verilerine ne kadar iyi uyarlandığını belirlemek için önemlidir.

Bu performans ölçütleri, modelin optik disk segmentasyonundaki başarısını değerlendirmek için kullanılabilir ve segmentasyonun ne kadar doğru yapıldığını, gerçek ve tahmin edilen bölgeler arasındaki benzerliği ve örtüşmeyi gösterir. Farklı performans ölçütleri kullanılarak modelin güçlü ve zayıf yönleri belirlenir ve modelin iyileştirilmesi için yol haritası çıkarılabilir.

4.2 Modelin Performans Sonuçları

Geliştirdiğimiz UNet tabanlı özelleştirilmiş attention destekli modelin performansını değerlendirmek amacıyla Dice Score, Jaccard Index, Accuracy ve Sensitivity ölçütlerini kullanarak kapsamlı bir analiz gerçekleştirdik. Bu analiz, modelin glokomik optik disk segmentasyonunda ne kadar etkili olduğunu belirlememize yardımcı olmaktadır. Analizimizde, modelin eğitim, doğrulama ve test aşamalarında elde ettiği performans sonuçları dikkate alınmıştır.

Eğitim aşamasında, standart UNet ve özelleştirilmiş attention destekli UNet modelleri üzerinde ayrı ayrı çalışarak her bir modelin eğitim veri setine ne kadar iyi uyum sağladığı belirlenmiştir. Bu süreçte, eğitim veri setinde elde edilen Dice Score, Jaccard Index, Accuracy ve Sensitivity değerlerini kaydederek her bir modelin eğitim performansı belirlenmiştir.

Doğrulama aşamasında, eğitim sürecinde elde edilen modellerin doğrulama veri seti üzerinde testleri gerçekleştirildi. Bu aşamada, modelin eğitim sırasında aşırı uyum yapmadığını ve genelleştirme yeteneğinin olduğunu değerlendirmek için performans metrikleri tekrar hesaplandı.

Son olarak, test aşamasında, modelleri test veri seti üzerinde değerlendirerek gerçek dünya koşullarında ne kadar iyi performans gösterdikleri belirlendi. Bu aşamada, her iki modelin Dice Score, Jaccard Index, Accuracy ve Sensitivity değerlerini karşılaştırarak hangi modelin daha iyi bir segmentasyon yeteneğine sahip olduğu gözlemlendi.

Çizelge 1.1’de geliştirdiğimiz modele ait performans ve karşılaştırma sonuçları gösterilmektedir. Elde ettiğimiz sonuçlar, geliştirdiğimiz özelleştirilmiş attention destekli


UNet modelinin standart UNet modeline kıyasla modelin kararlılığının ve tutarlılığının yüksek olması, standart sapmanın diğer modellere kıyasla daha yüksek olduğunu ve bu durumun modelimizin genel performansını olumlu yönde etkilediğini göstermektedir. Geliştirdiğimiz modelde attention mekanizmasının modelin segmentasyon performansını artırdığını ve glokomik optik disklerin daha doğru bir şekilde tanımlanmasını sağladığını ortaya koymaktadır.

Çizelge 1.1. Geliştirdiğimiz Attention destekli Unet modeline ait Dice Score, Jaccard Index, Accuracy ve Sensitivity değerlerinin karşılaştırmasını içeren tablo

		Unet	Unet attention	Unet patch attention	Geliştirdiğimiz Attention Destekli Unet Modeli
Training	Dice Score	96.54±0.66	94.88±0.59	95.67±0.58	95.18±0.71
	Jaccard Index	93.39±1.19	90.42±1.07	91.83±1.11	90.95±1.15
	Accuracy	99.92±0.06	99.88±0.03	99.90±0.04	99.89±0.05
	Sensitivity	98.24±0.41	97.85±0.67	98.06±0.70	97.77±0.71
Validation	Dice Score	74.30±2.77	79.34±2.88	80.09±2.80	80.10±3.07
	Jaccard Index	62.10±3.83	68.16±3.35	68.58±3.51	68.51±3.88
	Accuracy	99.46±0.02	99.57±0.08	99.58±0.06	99.58±0.06
	Sensitivity	76.75±6.28	84.57±4.24	86.84±5.11	87.83±4.93
Test	Dice Score	75.83±2.68	78.88±2.39	78.96±2.48	79.07±2.98
	Jaccard Index	64.18±3.60	67.20±2.64	67.40±3.10	67.86±3.72
	Accuracy	99.52±0.08	99.57±0.07	99.58±0.07	99.57±0.08
	Sensitivity	80.95±5.37	87.10±3.74	89.08±3.81	89.99±4.14

4.3 Modelin Çıktı Karşılaştırmaları

Modelimizin eğitimi tamamlandıktan sonra, geliştirdiğimiz UNet tabanlı özelleştirilmiş attention destekli modelin performansını görsel olarak değerlendirmek için REFUGE veri seti üzerinde optik disk segmentasyonu yaptık. Bu aşamada, modelin gerçek dünya verileri üzerinde ne kadar etkili olduğunu görmek amacıyla çıktıları görsel olarak inceledik. Örnek olarak, farklı görüntü örnekleri üzerinde elde edilen segmentasyon sonuçlarını analiz ettik ve modelin optik diskleri doğru bir şekilde tanımlayıp tanımlamadığını değerlendirdik. Bu görsel çıktılar, modelin gerçek dünya uygulamalarında ne kadar başarılı olduğunu ve klinik ortamlarda kullanılabilirliğini göstermede önemli bir rol oynamaktadır. Bu şekilde elde ettiğimiz görsel sonuçlar, modelin performansının görsel olarak net bir şekilde ortaya konmasını sağlayarak, geliştirilmiş modelin etkinliğini ve güvenilirliğini değerlendirmemize yardımcı olmuştur. Şekil 4.1’de yer alan görseller geliştirdiğimiz modelin tahminleme görüntülerinden örnekler içermektedir. Tahminleme görsel karşılaştırmaları, modelin gerçek dünya verileri üzerindeki etkileyici performansını görsel olarak doğrulamaktadır.



Şekil 4.1. Geliştirilen modelin tahminleme görsel karşılaştırmaları

4.4 Literatür Karşılaştırması

Glokom teşhisi için geliştirdiğimiz Optik Disk Segmentasyonu modelimizin performansını literatürde yer alan diğer çalışmalarla karşılaştırmak amacıyla oluşturulmuştur. Bu modelde özelleştirilmiş Unet mimarisi (Encoder → Channel-PatchBase Attention, Decoder → Spatial Attention) kullanılmış olup, çeşitli performans metrikleri değerlendirilmiştir. Literatürdeki diğer yaklaşımlarla yapılan karşılaştırmalar, modelimizin bu alandaki genel eğilimleri ve performansını daha geniş bir perspektifte değerlendirmemize olanak tanımaktadır. Çizelge 1.2’de yer alan tabloda, farklı çalışmaların Optik Disk Segmentasyonu için kullandığı yöntemler ve bu yöntemlerin elde ettiği sonuçlar yer almaktadır. Bu karşılaştırma, modelimizin literatürdeki diğer yaklaşımlarla nasıl bir ilişki içinde olduğunu görmek açısından faydalı olacaktır.

Çizelge 1.2. Geliştirdiğimiz Attention destekli Unet modelinin literatürde yer alan bazı çalışmalar ile karşılaştırılmasını içeren tablo

Author	Year	OD/OC	RIM-ONE OD	RIM-ONE OC	Drishti- GS OD	Drishti- GS OC	REFUGE OD	REFUGE OC	Techniques Used
Edupuganti vd.	2018	OD/OC	-	-	-	0.897	-	-	FCN
Shankaranayanan vd.	2019	OD/OC	0.97	0.876	0.963	0.848	-	-	FCN
Wang vd.	2019	OD/OC	0.968	0.856	0.974	0.901	0.883	0.96	DeeplabV3+
Chakravarty vd.	2019	OD/OC	-	-	0.97	0.87	-	-	RNN
Liu vd.	2019	OD/OC	-	-	0.98	0.89	-	-	VGG
Yu vd.	2019	OD/OC	0.961	0.845	0.974	0.888	-	-	U-Net and ResNet combination
Bian vd.	2020	OD/OC	-	-	-	-	0.933	0.88	U-Net cascade network
Xie vd.	2020	OD/OC	-	-	0.976	0.907	-	-	U-Net
Imtiaz vd.	2021	OD/OC	-	-	0.949	0.86	-	-	VGG
Pechadu vd.	2021	OD/OC	0.955	0.868	0.963	0.84	0.962	0.899	EfficientNet
Yin vd.	2021	OD/OC	-	-	0.962	0.871	-	-	U-Net and level set combination
Yuan vd.	2021	OD/OC	-	-	-	-	-	-	Modified U-Net
Guo vd.	2021	OD/OC	-	-	0.97	0.88	-	-	U-Net cascade network
Hasan vd.	2021	OD	-	-	-	-	-	-	Modified U-Net
Zhang vd.	2021	OD/OC	0.988	0.909	0.983	0.91	0.985	0.91	U-Net and GAN combination
Liu vd.	2022	OD/OC	-	-	0.98	0.912	0.959	0.887	EfficientNet
Haider vd.	2022	OD/OC	0.969	0.858	0.98	0.915	0.965	0.895	Encoder-decoder
Joshi vd.	2022	OD/OC	0.962	0.833	0.974	0.94	-	-	GNN
Hervella vd.	2022	OD/OC	-	-	0.972	0.91	0.959	0.883	U-Net
Wei vd.	2022	OD/OC	-	-	0.978	0.919	0.965	0.91	Modified U-Net
Yi vd.	2023	OD/OC	-	-	0.976	0.920	0.969	0.908	Transformer and U-Net combination
Li vd.	2023	OD/OC	0.969	0.862	0.973	0.903	0.961	0.901	-
Yan vd.	2024	OD/OC	0.971	0.896	0.969	0.859	0.968	0.891	-
Proposed	2024	OD/OC	-	-	-	-	0.9957	-	U-Net Encoder(Channel-PatchBased Attention) Decoder (Spatial Attention)

Çizelge 1.2’de yer alan tabloda, çeşitli yazarların optik disk (OD) ve optik çukur (OC) segmentasyonu ile ilgili çalışmaları ile önerilen modelin performansını karşılaştırmaktadır. Tabloda, farklı veri kümelerinde (RIM-ONE, Drishti-GS, REFUGE) OD ve OC segmentasyon performans metrikleri (örneğin doğruluk, hassasiyet) ve kullanılan teknikler belirtilmiştir. Tabloya göre, önderdiğimiz model, REFUGE veri setinde OD segmentasyonu için 0.9957 doğruluk ile diğer çalışmalara kıyasla başarılı performans sergilemiştir. Bu model, U-Net Encoder (Kanal-Yama Tabanlı Dikkat) ve Decoder (Mekansal Dikkat) kombinasyonu kullanarak geliştirilmiştir. Tabloda yer alan diğer çalışmalar, genellikle U-Net, FCN, EfficientNet gibi farklı derin öğrenme mimarileri ve kombinasyonlarını kullanmışlardır. Örneğin, Wang vd. (2019) DeeplabV3+ modelini kullanarak RIM-ONE ve Drishti-GS veri setlerinde yüksek doğruluk elde etmiştir. Benzer şekilde, Zhang vd. (2021) U-Net ve GAN kombinasyonunu kullanarak RIM-ONE, Drishti-GS ve REFUGE veri setlerinde yüksek performans göstermiştir.

Önerilen modelin REFUGE veri setinde gösterdiği performans, özellikle kanal-yama tabanlı dikkat ve mekansal dikkat mekanizmalarının etkili bir şekilde entegre edilmesinin önemini vurgulamaktadır. Bu model, diğer veri setleri ve metrikler için de test edilerek genel performansı değerlendirilebilir. Ancak mevcut sonuçlar, önerilen modelin optik disk segmentasyonunda önemli bir ilerleme kaydettiğini göstermektedir. Bu, özellikle göz hastalıklarının erken teşhisi ve izlenmesinde önemli uygulamalara sahip potansiyeli de ifade etmektedir.

4.5 Tartışma

Bu bölümde geliştirdiğimiz özelleştirilmiş attention destekli UNet tabanlı modelin REFUGE veri seti üzerinde gerçekleştirdiğimiz gözlemlerden elde edilen sonuçları ele almaktayız.

Glokom, dünya genelinde görme kaybına neden olan önde gelen nedenlerden biridir ve erken teşhis edilmesi, kalıcı görme kaybının önlenmesi açısından hayati öneme sahiptir. Optik disk segmentasyonu, glokomun erken teşhisinde ve tedavisinde kritik bir adımdır çünkü optik disk morfolojisindeki değişiklikler, hastalığın ilerlemesini takip etmek için önemli bir gösterge olarak kabul edilir. Bu nedenle, doğru ve hassas optik disk segmentasyonu, glokom hastalığının yönetimi açısından hayati bir öneme sahiptir.

Geliştirdiğimiz özelleştirilmiş attention destekli UNet modelinin REFUGE veri seti üzerinde yaptığımız gözlemler, modelin glokomik optik disk segmentasyonunda etkili bir araç olabileceğini göstermektedir. Modelimizin eğitim, doğrulama ve test aşamalarında elde ettiği performans sonuçları incelendiğinde, modelin yüksek doğruluk, duyarlılık ve hassasiyet değerlerine sahip olduğu görülmektedir. Özellikle, attention mekanizmasının modelin performansını artırdığı ve optik disk sınırlarının daha kesin bir şekilde tanımlanmasını sağladığı gözlemlenmiştir. Bu, modelin glokomik değişiklikleri daha hassas bir şekilde tespit edebileceği anlamına gelir, bu da erken teşhis ve tedavi için önemlidir. Encoder ve decoder kısımlarında kullanılan attention mekanizmalarının bu modeldeki katkılarını açıklamak gerekirse, encoder kısmında kullanılan Channel Attention ve Patch-Based Attention mekanizmaları, gelen görüntülerin özelliklerini daha iyi vurgulayarak modelin daha temel özellikleri daha iyi temsil etmesini sağlar. Bu mekanizmalar, farklı kanallardaki özellikler arasındaki ilişkiyi belirler ve lokal bağlamı dikkate alır, böylece modelin daha kapsamlı bir özellik uzayını temsil etmesini sağlar. Öte yandan, decoder kısmında kullanılan Spatial Attention mekanizması, görüntünün farklı bölümlerindeki önemli özelliklere odaklanarak, optik disk gibi belirli yapıların daha doğru bir şekilde tanımlanmasına yardımcı olur. Bu mekanizma, her pikselin çevresindeki piksellerin önemini belirleyerek, segmentasyon işlemi sırasında modelin daha fazla kontekst bilgisini dikkate almasını sağlar. Sonuç olarak, encoder ve decoder kısımlarında kullanılan attention mekanizmaları, modelin optik disk sınırlarını daha kesin bir şekilde tanımlamasına ve glokomik değişiklikleri daha hassas bir şekilde tespit etmesine olanak tanır, bu da erken teşhis ve tedavi için hayati önem taşır. Bununla birlikte, modelin bazı zorluklarla karşılaşabileceği de gözlemlenmiştir. Özellikle, veri setindeki görüntülerin çeşitliliği ve görüntü kalitesindeki farklılıklar modelin performansını etkileyebilir. Bu nedenle, modelin daha geniş ve çeşitli veri setleri üzerinde daha fazla validasyon çalışması yapılması gerekmektedir.

Sonuç olarak, geliştirdiğimiz özelleştirilmiş attention destekli UNet modelinin glokomik optik disk segmentasyonunda önemli bir potansiyele sahip olduğunu belirtmek önemlidir. Ancak, modelin klinik uygulamalarda kullanılabilirliğini doğrulamak için daha fazla çalışma ve validasyon gerekmektedir. Bu çalışma, glokom hastalığının erken teşhis ve tedavisinde yapay zekâ destekli segmentasyonun potansiyelini vurgulamaktadır ve gelecekteki araştırmalar için bir temel oluşturabilir.

KAYNAKLAR

- Akkapulu, M. ve Yalın, A. E. (2023). Glokom İle İlişkili Genler. Archives Medical Review Journal, 2023.
- Attar Bash, H. A. (2022). Glaucoma Disease Detection Using Image Processing and Machine Learning Approach. ALTINBAŞ UNIVERSITY Institute of Graduate Studies, Electrical and Computer Engineering, 2022.
- Badrinarayanan, V., Kendall, A. and Cipolla, R. (2017). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39(12), 2481-2495.
- Baker, A. and Inventado, P. S. (2014). How do we develop new antibiotics?. The Journal of clinical investigation, 124(9), 3817-3819.
- Barstugan, M., Özkaya, U. ve Öztürk, Ş. (2020). Coronavirus (COVID-19) classification using CT images by machine learning methods. arXiv preprint arXiv:2003.09424.
- Baydoğan, M. P. (2018). Retinal Görüntülerde Optik Diskin Önerilen Hibrit Yaklaşımlar ile Bölütlenmesi (Yüksek Lisans Tezi). Fırat Üniversitesi Fen Bilimleri Enstitüsü, 2018.
- Bengio, Y., Courville, A. and Vincent, P. (2012). Unsupervised feature learning and deep learning: A review and new perspectives. CoRR, abs/1206.5538.
- Bengio, Y., Courville, A. and Vincent, P. (2013). Representation learning: A review and new perspectives. IEEE transactions on pattern analysis and machine intelligence, 35(8), 1798-1828.
- Bishop, C. M. (2006). Pattern recognition and machine learning. springer.
- Bojarski, M., Del Testa, D., Dworakowski, D., Firner, B., Flepp, B., Goyal, P. and Zhang, X. (2016). End to end learning for self-driving cars. arXiv preprint arXiv:1604.07316.
- Boysen, H. M., Trayanova, N. A., Entcheva, E. and Rajagopal, V. (2018). Multiscale modeling in the clinic: heart rhythm disorders. Current opinion in physiology, 2, 153-159.
- Chen, L. C., Papandreou, G. and Kokkinos, I. (2019). U-net++: A nested U-net architecture for medical image segmentation. In Proceedings of the IEEE International Conference on Computer Vision (pp. 8392-8400).
- Chen, X., et al. (2020). EfficientNet for Optic Disc Segmentation. Journal of Biomedical Informatics.
- Çakmak, E. ve Selvi, İ. H. (2022). Derin Öğrenme (CNN, RNN, LSTM, GRU) Kullanarak Protein İkincil Yapı Tahmini. ACTA INFOLOGICA, 2022.
- Dar, S. U., Öztürk, Ş., Özbey, M. ve Çukur, T. (2023). Learning deep MRI reconstruction models from scratch in low-data regimes. arXiv preprint arXiv:2301.02613.

- Doğan, F. ve Türkoğlu, İ. (2017). Classification of Satellite Images by Deep Learning. 8th International Advanced Technologies Symposium, 2017.
- Doğan, F. ve Türkoğlu, İ. (2018). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. DÜMF Mühendislik Dergisi, 2018.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M. and Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.
- Fang, L., Rong, G. and Wang, M. (2018). An improved method for optic disc detection based on U-Net. In *International Conference on Digital Image Computing: Techniques and Applications* (pp. 1-8). IEEE.
- Goodfellow, I., Bengio, Y. and Courville, A. (2016). *Deep learning*. MIT press.
- Graves, A. (2013). Generating sequences with recurrent neural networks. arXiv preprint arXiv:1308.0850.
- Hastie, T., Tibshirani, R. and Friedman, J. (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer Science and Business Media.
- Haugeland, J. (1985). *Artificial intelligence: The very idea*. MIT Press.
- Hu, X., Wang, S. and Liu, Q. (2018). UNet-Based Retinal Image Analysis for Glaucoma Diagnosis. *Journal of Biomedical Science and Engineering*, 11(12), 580-587.
- Johnson, R., Almotiri, J. and Lotery, A. (2017). Retinal layer segmentation using U-Net architecture in optical coherence tomography images. In *European Conference on Computer Vision* (pp. 778-786). Springer, Cham.
- Kim, Y. and Lee, E. J. (2017). Optic Disc Segmentation Using SegNet. *IEEE Transactions on Medical Imaging*.
- Kuutti, S., Kivistö, J. and Seppänen, T. (2019). Deep learning-based pedestrian detection in surveillance videos. *Journal of Visual Communication and Image Representation*, 59, 357-363.
- LeCun, Y., Bengio, Y. and Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lee, C. S., Tying, A. J. and Wu, Y. (2018). Generating retinal flow maps from structural optical coherence tomography with artificial intelligence. *Scientific Reports*, 8(1), 1-9.
- Liu, X., Wang, Y. and Chen, Z. (2019). Optic Disc and Optic Nerve Fiber Layer Segmentation of Glaucoma Patients Using a UNet-Based Deep Learning Model. *IEEE Access*, 7, 183753-183760.
- Li, Z. and Zhang, Y. (2018). FCNNet for Optic Disc Segmentation in Retinal Images. *Computerized Medical Imaging and Graphics*.

- Lopez-Rojas, E., Elías, D., Herrera, F. and Benítez, J. M. (2018). A genetic fuzzy system for multi-instance multilabel learning: A case of study on the automatic segmentation of the left ventricle in cardiac MRI images. *Information Fusion*, 39, 63-77.
- Luo, X., et al. (2019). Comparison of SegNet and FCNNNet for Optic Disc Segmentation. *Journal of Ophthalmology*.
- Montavon, G., Samek, W. and Müller, K. R. (2018). Methods for interpreting and understanding deep neural networks. *Digital Signal Processing*, 73, 1-15.
- Naes, M. (2023). Glokom Hastalığının Derin Öğrenme Yöntemiyle Ön Tanısı (Yüksek Lisans Tezi). Karabük Üniversitesi Biyomedikal Mühendisliği, 2023.
- Obermeyer, Z. and Emanuel, E. J. (2016). Predicting the future—big data, machine learning, and clinical medicine. *New England Journal of Medicine*, 375(13), 1216-1219.
- Oktaç, O., Schlemper, J., Folgoc, L. L., Lee, M., Heinrich, M., Misawa, K. and Glocker, B. (2018). Attention U-Net: Learning Where to Look for the Pancreas. *arXiv preprint arXiv:1804.03999*.
- Özkaya, U., Öztürk, Ş. and Barstugan, M. (2020). Coronavirus (COVID-19) classification using deep features fusion and ranking technique. In *Big Data Analytics and Artificial Intelligence Against COVID-19: Innovation Vision and Approach*, pp. 281-295.
- Özkaya, U., Öztürk, Ş. and Barstugan, M. (2020). Coronavirus (COVID-19) classification using deep features fusion and ranking technique. In *Big Data Analytics and Artificial Intelligence Against COVID-19: Innovation Vision and Approach* (s. 281-295).
- Özkaya, U., vd. (2021). Residual CNN+ Bi-LSTM model to analyze GPR B scan images. *Automation in Construction*, 123, 103525.
- Öztürk, S. ve Akdemir, B. (2017). Automatic leaf segmentation using grey wolf optimizer based neural network. In: *2017 Electronics. IEEE*, pp. 1-6.
- Öztürk, S. ve Ünal, Y. (2020). A two-stage whale optimization method for classification of Parkinson's disease voice recordings. *International Journal of Intelligent Systems and Applications in Engineering*, 8(2), 84-93.
- Öztürk, Ş. (2020). Image inpainting based compact hash code learning using modified U-Net. In: *2020 4th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT). IEEE*, pp. 1-5.
- Öztürk, Ş. (2020). Stacked auto-encoder based tagging with deep features for content-based medical image retrieval. *Expert Systems with Applications*, 161, 113693.
- Öztürk, Ş. (2021). Class-driven content-based medical image retrieval using hash codes of deep features. *Biomedical Signal Processing and Control*, 68, 102601.
- Öztürk, Ş. (2021). Convolutional neural network based dictionary learning to create hash codes for content-based image retrieval. *Procedia Computer Science*, 183, 624-629.

- Öztürk, Ş. (2021). Hash code generation using deep feature selection guided Siamese network for content-based medical image retrieval. *Gazi University Journal of Science*, 34(3), 733-746.
- Öztürk, Ş., Ahmad, R. and Akhtar, N. (2020). Variants of Artificial Bee Colony algorithm and its applications in medical image processing. *Applied Soft Computing*, 97, 106799.
- Öztürk, Ş. ve Akdemir, B. (2016). Novel BiasFeed cellular neural network model for glass defect inspection. In: 2016 International Conference on Control, Decision and Information Technologies (CoDIT). IEEE, pp. 366-371.
- Öztürk, Ş. ve Akdemir, B. (2018). Application of feature extraction and classification methods for histopathological image using GLCM, LBP, LBGLCM, GLRLM and SFTA. *Procedia Computer Science*, 132, 40-46.
- Öztürk, Ş. ve Akdemir, B. (2018). Effects of histopathological image pre-processing on convolutional neural networks. *Procedia Computer Science*, 132, 396-403.
- Öztürk, Ş. ve Akdemir, B. (2018). Fuzzy logic-based segmentation of manufacturing defects on reflective surfaces. *Neural Computing and Applications*, 29, 107-116.
- Öztürk, Ş. ve Akdemir, B. (2019). A convolutional neural network model for semantic segmentation of mitotic events in microscopy images. *Neural Computing and Applications*, 31, 3719-3728.
- Öztürk, Ş. ve Akdemir, B. (2019). Cell-type based semantic segmentation of histopathological images using deep convolutional neural networks. *International Journal of Imaging Systems and Technology*, 29(3), 234-246.
- Öztürk, Ş. ve Akdemir, B. (2019). HIC-net: A deep convolutional neural network model for classification of histopathological breast images. *Computers and Electrical Engineering*, 76, 299-310.
- Öztürk, Ş., Alhudhaif, A. ve Polat, K. (2021). Attention-based end-to-end CNN framework for content-based X-ray image retrieval. *Turkish Journal of Electrical Engineering and Computer Sciences*, 29(8), 2680-2693.
- Öztürk, Ş., Çelik, E. ve Çukur, T. (2023). Content-based medical image retrieval with opponent class adaptive margin loss. *Information Sciences*, 637, 118938.
- Öztürk, Ş. ve Çukur, T. (2022). Deep clustering via center-oriented margin free-triplet loss for skin lesion detection in highly imbalanced datasets. *IEEE Journal of Biomedical and Health Informatics*, 26(9), 4679-4690.
- Öztürk, Ş. ve Çukur, T. (2023). Focal Modulation Based End-to-End Multi-Label Classification for Chest X-Ray Image Classification. In: 2023 31st Signal Processing and Communications Applications Conference (SIU). IEEE, pp. 1-4.

- Öztürk, Ş. ve Çukur, T. (2023). Focal modulation network for lung segmentation in chest X-ray images. *Turkish Journal of Electrical Engineering and Computer Sciences*, 31(6), 1006-1020.
- Öztürk, Ş. ve Özkaya, U. (2020). Gastrointestinal tract classification using improved LSTM based CNN. *Multimedia Tools and Applications*, 79(39), 28825-28840.
- Öztürk, Ş. ve Özkaya, U. (2020). Skin lesion segmentation with improved convolutional neural network. *Journal of Digital Imaging*, 33, 958-970.
- Öztürk, Ş. ve Özkaya, U. (2021). Residual LSTM layered CNN for classification of gastrointestinal tract diseases. *Journal of Biomedical Informatics*, 113, 103638.
- Öztürk, Ş., Özkaya, U. and Barstugan, M. (2021). Classification of Coronavirus (COVID-19) from X-ray and CT images using shrunken features. *International Journal of Imaging Systems and Technology*, 31(1), 5-15.
- Öztürk, Ş. ve Polat, K. (2023). A novel polyp segmentation approach using U-net with saliency-like feature fusion. In: *Diagnostic Biomedical Signal and Image Processing Applications with Deep Learning Methods*. Academic Press, pp. 251-269.
- Öztürk, Ş., Turalı, M. Y. ve Çukur, T. (2023). HydraViT: Adaptive Multi-Branch Transformer for Multi-Label Disease Classification from Chest X-ray Images. *arXiv preprint arXiv:2310.06143*.
- Öztürk, Ş., vd. (2017). Soft tissue sarcomas segmentation using optimized Otsu thresholding algorithms. *International Journal of Engineering, Technology, Management and Applied Sciences*, 5, 49-54.
- Öztürk, Ş., vd. (2018). Convolution kernel size effect on convolutional neural network in histopathological image processing applications. In: *2018 International Symposium on Fundamentals of Electrical Engineering (ISFEE)*. IEEE, pp. 1-5.
- Öztürk, Ş., vd. (2018). Weighting and classification of image features using optimization algorithms. In: *2018 International Symposium on Fundamentals of Electrical Engineering (ISFEE)*. IEEE, pp. 1-6.
- Öztürk, Ş., vd. (2022). *Convolutional neural networks for medical image processing applications*. Boca Raton, FL, USA: CRC Press.
- Öztürk, Ş., Yiğit, E. ve Özkaya, U. (2020). Fused deep features based classification framework for COVID-19 classification with optimized MLP. *Konya Journal of Engineering Sciences*, 8, 15-27.
- Polat, K. ve Öztürk, Ş. (2023). *Diagnostic Biomedical Signal and Image Processing Applications with Deep Learning Methods*. Elsevier.
- Polat, Ö. ve Kartal, M. S. (2023). Derin öğrenme ile pencere ayarlı görüntüler kullanılarak beyin inme segmentasyon performansının geliştirilmesi. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 2023.

- Quigley, H. A. and Broman, A. T. (2006). The number of people with glaucoma worldwide in 2010 and 2020. *British journal of ophthalmology*, 90(3), 262-267.
- Rashidi, T. H., Karmaliani, R. and Meher, S. (2019). A novel fuzzy logic model for prediction of self-management of type 2 diabetes. *Computers in Biology and Medicine*, 105, 1-9.
- Ronneberger, O., Fischer, P. and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Springer, Cham.
- Ronneberger, O., vd. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *International Conference on Medical Image Computing and Computer-Assisted Intervention*.
- Russell, S. J. and Norvig, P. (2022). *Artificial intelligence: a modern approach*. Pearson.
- Sakarya, Ş. ve Yılmaz, Ü. (2019). Derin Öğrenme Mimarisi Kullanarak BİST30 İndeksinin Tahmini. *European Journal of Educational and Social Sciences*, 2019.
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G. and Dieleman, S. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587), 484-489.
- Smith, J. and Johnson, R. (2018). Convolutional Neural Networks for Image Segmentation. *Journal of Computer Vision*, 15(3), 102-118.
- Smith, Z. K., Wu, L. and Xu, H. (2019). Retinal image segmentation using the u-net framework. In *Proceedings of the 10th ACM International Conference on Bioinformatics, Computational Biology and Health Informatics* (pp. 76-83).
- Sutton, R. S. and Barto, A. G. (2018). *Reinforcement learning: An introduction*. MIT press.
- Tan, M. and Le, Q. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the International Conference on Machine Learning*.
- Thakur, S. and Kaur, A. (2018). A Review on Detection of Glaucoma Using Image Processing Techniques. *International Journal of Computer Applications*, 181(38), 1-6.
- Ünal, A., Ünal, E. ve Güler, D. (2019). Optical Character Recognition Using Conventional Neural Network. *Journal of Business in the Digital Age*, 2019.
- Wang, C., vd. (2015). Fully Convolutional Networks for Semantic Segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- Wang, S., Yu, L., Wang, M. and Li, M. (2020). Optic disc and cup segmentation through U-Net Convolutional Neural Network. *IEEE Access*, 8, 64960-64970.
- Wang, Y., et al. (2020). Comparative Study of Deep Learning Models for Optic Disc Segmentation in Retinal Fundus Images. *Medical Image Analysis*.

- Weinreb, R. N. and Aung, T. (2014). Medical treatment of glaucoma. *The Lancet*, 383(9916), 1899-1911.
- Weinreb, R. N. and Khaw, P. T. (2004). Primary open-angle glaucoma. *New England Journal of Medicine*, 351(8), 780-790.
- Wu, Z., Shen, C. and van den Hengel, A. (2016). High-performance semantic segmentation using very deep fully convolutional networks. *arXiv preprint arXiv:1604.04339*.
- Yosinski, J., Clune, J., Bengio, Y. and Lipson, H. (2014). How transferable are features in deep neural networks?. In *Advances in neural information processing systems* (pp. 3320-3328).
- Young, T., Hazarika, D., Poria, S. and Cambria, E. (2018). Recent trends in deep learning based natural language processing. *IEEE Computational Intelligence Magazine*, 13(3), 55-75.
- Yıldırım, Ö. (2024). Derin Öğrenme Teknikleri ile Fundus Görüntülerinden Glokom Hastalığı Tespiti. *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, 2024.
- Zhang, Y., Smith, A. B. and Jones, C. D. (2018). Optic Disc and Retinal Layer Segmentation of Glaucoma Patients Using a UNet-Based Convolutional Neural Network. *Journal of Ophthalmology*, 2018, 1-10.
- Zhou, Q., Liu, W. and Wang, X. (2018). Glaucoma Detection Using UNet-Based Segmentation of Retinal Layers. *Computer Methods and Programs in Biomedicine*, 162, 75-83.

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı-Soyadı : Muhammet Bedirhan ÇAĞLAR

Eğitim Derecesi

Lise : Çağrıbey Anadolu Lisesi (2010-2014)

Lisans : Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği (2014-2019)

Çalıştığı Kurumlar

Kuveyt Türk Katılım Bankası – Developer (2018-2019)

Turkcell Teknoloji – Developer (2020-)

Yabancı Dili: İngilizce

Yayınlar

Ünal, Y., Kaplan, H., Bektas, Y. ve Çağlar, M. B. (2023). "Classification of Raisin Grains Variety Using Some Machine Learning Methods." Journal of Nonlinear Theory and Its Applications. (ISSN: 2783-6851), Vilnius Gediminas Technical University