

T.C.
İSTANBUL AREL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI



BÖBREK KİSTLERİNİN MAKİNE ÖĞRENMESİ
YARDIMIYLA ARAŞTIRILMASI

DOKTORA TEZİ

AZİZ İLYAS ÖZTÜRK

İSTANBUL, 2023

T.C.
İSTANBUL AREL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI



BÖBREK KİSTLERİNİN MAKİNE ÖĞRENMESİ
YÖNTEMİYLE ARAŞTIRILMASI

DOKTORA TEZİ

AZİZ İLYAS ÖZTÜRK

İSTANBUL, 2023

KABUL VE ONAY

AZİZ İLYAS ÖZTÜRK tarafından hazırlanan **“BÖBREK KİSTLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMİYLE ARAŞTIRILMASI”** adlı tez çalışmasının savunma tarihi 01.08.2023 tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği /oy çokluğu ile İstanbul Arel Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Doktora Tezi olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman

Prof.Dr. Osman YILDIRIM İstanbul

Aydın Üniversitesi

.....

Üye

Dr.Öğr.Üyesi Serdar KARGIN İstanbul

Arel Üniversitesi

.....

Üye

Dr.Öğr.Üyesi Emrah KOÇ İstanbul

Arel Üniversitesi

.....

Üye

Dr.Öğr.Üyesi Mohammed ALKRUNZ

İstanbul Aydın Üniversitesi

.....

Üye

Dr.Öğr.Üyesi Abbas UĞURENVER

.....

İstanbul Arel Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulu'nun
..... tarih ve sayılı kararıyla onaylanmıştır.

.....

Prof. Dr. Ali AKDEMİR

Lisansüstü Eğitim Enstitüsü Müdürü

YEMİN METNİ

Doktora Tezi olarak sunduđum “BÖBREK KİSTLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMİYLE ARAŞTIRILMASI” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere uygun şekilde tarafımdan yazıldığını, yararlandığım eserlerin tamamının kaynaklarda gösterildiğini ve çalışmanın içinde kullanıldıkları her yerde bunlara atıf yapıldığını belirtir ve bunu onurumla doğrularım.

08.01.2023

AZİZ İLYAS ÖZTÜRK

ÖZET

**BÖBREK KİSTLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMİYLE
ARAŞTIRILMASI
DOKTORA TEZİ
AZİZ İLYAS ÖZTÜRK
İSTANBUL AREL ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

(DANIŞMAN: PROF.DR.OSMAN YILDIRIM)

İSTANBUL, 2023

Böbrek kisti, böbrek içinde veya etrafında oluşabilir. Böbrek yetmezliği ve hipertansiyona sebep olabileceği gibi organın işlevini yerine getirememesine de neden olabilir. Bu çalışmada böbrek görüntülerine median, ikili, toplam varyasyon, gaussian, kenar belirleme ve sobel filtreleri uygulanarak kist görüntülerde tespit edilmiştir. Bilgisayarlı tomografiden alınan karın bölgesi görüntüleri bölütleme yapıldı. Bu bölütleme çalışması ile dokular ayrıştırıldı. Ayrıştırılan görüntülerden böbrek ve kistli böbrekler anlamlı bölütleme yapılarak ayrıştırıldı.

Makine öğrenmesinin önemi tıbbi görüntülemelerde her geçen gün artmaktadır. Yapılan çalışmada Unet, Rastgele Orman Algoritması, Kernel Destek Vektor Makineleri ve Lojistik Regresyon kullanılmıştır. Elde edilen sonuçlar Unet %92, Rastgele Orman Algoritması %99,2, Kernel Destek Vektor Makineleri %98,11, Lojistik Regresyon %96,49'dur.

Anahtar Kelimeler: Böbrek Kisti, Görüntü İşleme, Makine Öğrenmesi, Bölütleme

ABSTRACT

INVESTIGATION OF KIDNEY CYST WITH MACHINE LEARNING

PH.D THESIS

AZIZ ILYAS OZTURK

GRADUATE SCHOOL, ISTANBUL AREL UNIVERSITY

ELECTRICAL ELECTRONICS ENGINEERING

(SUPERVISOR: PROF.DR. OSMAN YILDIRIM)

İSTANBUL, 2023

A kidney cyst can form in or around the kidney. It can cause kidney failure and hypertension, as well as cause the organ to fail to function. In this study, cyst images were detected by applying median, binary, total variation, gaussian, edge detection and Sobel filters to kidney images. Abdominal images taken from computed tomography were segmented. Tissues were separated by this segmentation study. Kidneys and kidneys with cysts were separated from the separated images by meaningful segmentation.

The importance of machine learning is increasing day by day in medical imaging. In the study, Unet, Random Forest Algorithm, Kernel Support Vector Machines and Logistic Regression were used. The results obtained are Unet 92%, Random Forest Algorithm 99.2%, Kernel Support Vector Machines 98,11%, Logistic Regression 96,49%.

Key Words: Kidney Cyst, Image Processing, Machine Learning, Segmentation

İÇİNDEKİLER

Sayfa

ÖZET.....	1
ABSTRACT	2
İÇİNDEKİLER	3
ŞEKİL LİSTESİ.....	5
KISALTMA VE SEMBOL LİSTESİ.....	6
ÖNSÖZ.....	7
1 GİRİŞ	8
1.1 Problemin Tespiti	10
1.2 Çalışmanın Amacı	10
1.3 Araştırmanın Metodolojisi	10
1.4 Ünitelerin Planı	10
2 FİLTRELEME YÖNTEMİ KULLANILARAK İMAJLARIN GÜÇLENDİRİLMESİ.....	11
2.1 İmaj Güçlendirme.....	11
2.2 İmaj Güçlendirmenin Medikal Görüntüleme'deki Önemi	12
2.3 Otsu Eşikleme	13
2.4 Gaussian Filtre ve Keskinliği Azaltma Filtresi	14
2.5 İkili Filtre ve Toplam Varyasyon Filtresi.....	16
2.6 Median Filter.....	18
2.7 Eşik Değeri.....	18
2.8 Kenar Belirleme Filtresi.....	20
2.9 Sobel Filtre	22
2.10 Görüntüleme Cihazları	24
2.10.1 Bilgisayarlı Tomografi	24
2.10.2 Manyetik Rezonans Görüntüleme.....	25
2.10.3 Mammografi Görüntüleme.....	27
3 TIBBİ GÖRÜNTÜLEME VE BÖLÜTLEME	28
3.1 Bölütleme	28
3.2 Anlamsal Bölütleme.....	29
3.3 Tıbbi Görüntüleme'de Böbrek Kistlerinde Anlamlı Bölütlemenin Önemi .	31
3.4 Tıbbi Görüntüleme Teşhis.....	33
3.5 Tıbbi Görüntü Sentezi	34
3.6 Medikal Görüntü Analizi	35
3.7 Doku Analizi	36
3.8 Doku Bölütlemesi.....	37
3.9 Doku sınıflandırması	39
3.10 Tıbbi Görüntüleme'de Doku Sentezleme	40
3.11 Havza Algoritması	41
4 MAKİNE ÖĞRENMESİ.....	44
4.1 Makine Öğrenmesi	44
4.2 Makine Öğrenmesi Türleri.....	45
4.2.1 Denetimli Öğrenme.....	45
4.2.2 Denetimsiz Öğrenme.....	47
4.2.3 Takviyeli Öğrenme	48
4.3 Yapay Sinir Ağı.....	50

4.4	Derin Öğrenme	52
4.4.1	Derin Öğrenmenin Yapısı	53
4.4.1.1	Sapma (Bias).....	54
4.4.1.2	Aktivasyon Fonksiyonu	55
4.5	Evrişimli Sinir Ağları	56
4.5.1	Evrişim, Havuzlama ve Tamamen Bağlantılı Katman.....	59
4.5.2	Evrişimli Sinir Ağı Modelleri	63
4.5.2.1	Imagenet	63
4.5.2.2	Alexnet.....	63
4.5.2.3	Googlenet.....	64
4.5.2.4	Densenet	65
4.6	Tamamen Evrişimli Ağ	66
4.6.1	Tamamen Evrişimli Ağ Mimarisi	67
4.7	Özyinelemeli Sinir Ağı	68
4.7.1	Özyinelemeli Sinir Ağı Mimarisi.....	69
4.8	Çekişmeli Üretici Ağı	70
4.8.1	Çekişmeli Üretici Ağı Mimarisi.....	73
5	UNET VE RASTGELE ORMAN ALGORİTMASI	76
5.1	UNET	76
5.1.1	Unet Kod Çözücü.....	78
5.1.2	Unet Atlama Bağlantıları	79
5.2	Rastgele Orman Algoritması.....	81
5.2.1	Rastgele Orman Algoritması Mimarisi	82
5.2.1.1	Rastgele Orman Algoritması Rastgele Süreklilik.....	84
5.2.1.2	Rastgele Orman Algoritması Özellik Seçimi.....	85
5.2.1.3	Rastgele Orman Algoritması Ağaç Yapısı	85
5.2.1.4	Rastgele Orman Algoritması Toplu Öğrenme	86
5.2.1.5	Hiperparametre Ayarı	86
5.2.1.6	Torba Dışı Hata.....	87
5.3	Kernel Destek Vektör Makineleri	88
5.3.1	Kernel Destek Vektör Makineleri Mimarisi	89
5.4	Lojistik Regresyon	90
5.4.1	Lojistik Regresyon Mimarisi.....	91
6	ARAŞTIRMA VE TARTIŞMA	93
7	SONUÇ.....	102
8	KAYNAKLAR	103
9	ÖZGEÇMİŞ.....	113

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 Otsu Eşikleme	14
Şekil 2.2 Gaussian Filtreden Geçirilmiş Görüntüler	15
Şekil 2.3 Keskinliği Azaltılmış Filtre Görüntüleri	16
Şekil 2.4 İkili Filtreden Geçirilmiş Görüntü	17
Şekil 2.5 Toplam Varyasyon Filtresi'nden Geçirilmiş Görüntü	17
Şekil 2.6 Farklı Eşik Değerleri için Görüntüler	20
Şekil 2.7 Kenar Belirleme ve Sobel Filtrelerinden Geçirilen Görüntüler	24
Şekil 3.1 Bölütleme Yapılmış Görüntü (Sağdaki Görüntü Soldaki Görüntünün Bölütü)	29
Şekil 3.2 Kisti olan ve işaretlenmiş böbrek görüntüsü	33
Şekil 3.3 Böbrek ve Kist Bölütlemesi	43
Şekil 4.1 Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollove diğerleri,2013)....	51
Şekil 4.2 Ağı Mimarisi (Efendigil ve Kahraman, 2009:6697)	54
Şekil 4.3 Çok Katmanlı Yapay Sinir Ağ Modeli (Karaatlı ve diğerleri, 2012:87)	58
Şekil 4.4 Havuzlama işleminin uygulanması (Jeong, 2021)	61
Şekil 4.5 Tamamen bağlı katman (Jeong, 2021)	62
Şekil 5.1 UNET Mimarisi (Ronneberger ve diğerleri, 2015)	80
Şekil 6.1 Eşleme için giriş maskeleme örneği-1	93
Şekil 6.2 Eşleme için giriş maskeleme örneği-2	93
Şekil 6.3 Semantik Bölütleme -1	94
Şekil 6.4 Semantik Bölütleme -2	94
Şekil 6.5 Böbrek Kisti İçin Maskeleme Sonucu	95
Şekil 6.6 UNET Sonuçları	95
Şekil 6.7 Rastgele Orman Algoritması Sonuçları	100
Şekil 6.8 Kernel DVM Doğruluk Tahmini Oranı	100
Şekil 6.9 Durum Matrisi	100
Şekil 6.10 Pozitif Böbrek Kistleri	101
Şekil 6.11 Lojistik Regresyon Doğruluk Oranı	101
Şekil 6.12 Lojistik Regresyon Homojen Dağılımı	101

KISALTMA VE SEMBOL LİSTESİ

ESA	:	Evrişimli Sinir Ağı
BT	:	Bilgisayarlı Tomografi
MRG	:	Manyetik Rezonans Görüntüleme
TEA	:	Tamamen Evrişimli Ağ
PBH	:	Polikistik Böbrek Hastalığı
BDTGT	:	Bilgisayar Destekli Tıbbi Görüntü İşlemi
ÜÇA	:	Üretken Çekişmeli Ağ
DOK	:	Değişken Otomatik Kodlayıcı
USG	:	Ultrasonografi
İA	:	İlgi Alanı
GDBOM	:	Gri Düzey Birlikte Oluşum Matrisi
YİM	:	Yerel İkili Model
HA	:	Havza Algoritması
YSA	:	Yapay Sinir Ağı
ReLU	:	Doğrultulmuş Doğrusal Birim
DSA	:	Derin Sinir Ağı
ÖSA	:	Özyinelemeli Sinir Ağı
Tanh	:	Hiperbolik Tanjant
İBÖGTM	:	Imagenet Büyük Ölçekli Görsel Tanıma Mücadelesi
AB	:	Atlama Bağlayıcısı
ROA	:	Rastgele Orman Algoritması
DVM	:	Destek Vektör Makineleri
LR	:	Lojistik Regresyon

ÖNSÖZ

Danışman hocam Prof.Dr. Osman YILDIRIM'a tezin oluşumunda verdiği destek için müteşekkirim. Farklı açılardan bakmayı farklı sorular sorarak ve sordurarak çizdirdiğiniz yol için teşekkür ederim.

Sevgili eşim Dr. Öğretim Üyesi Özlem Aydın ÖZTÜRK'e verdiği destek için ne kadar teşekkür etsem az olur. Sen olmasan bu tez olmazdı, ben olmazdım.

Değerli arkadaşım Ali KURU'ya da çok teşekkür ederim. İyi ki, varsın, seni tanıdım.

İYİTEM Görüntüleme Merkezi'ne Dr. Bedri ÇARSANCAKLI'ya verdiği destek için müteşekkirim.

Annem ve kardeşlerime umutları için teşekkür ederim.

Babam ve oğluma, Can'a,

Su der gibi...

01.08.2023

AZİZ İLYAS ÖZTÜRK

1 GİRİŞ

Böbrek kisti, böbrekte gelişen sıvı dolu bir kesedir. Böbrek kistleri nispeten yaygındır ve genellikle herhangi bir belirtiyeye neden olmaz veya tedavi gerektirmez. Bununla birlikte, bazı durumlarda rahatsızlığa neden olacak veya böbrek fonksiyonlarını etkileyecek kadar büyüyebilirler.

İki ana böbrek kisti türü vardır:

Basit böbrek kistleri: Bunlar böbrek kistlerinin en yaygın türüdür ve genellikle iyi huyludur. Tipik olarak herhangi bir belirtiyeye neden olmazlar ve görüntüleme çekimleri sırasında tesadüf olarak keşfedilirler.

Polikistik böbrek hastalığı: Bu, her iki böbrekte birden çok kistin geliştiği genetik bir durumdur. Kistler böbrek dokusuna zarar verebilecek kadar büyüyebilir ve bazı durumlarda böbrek yetmezliğine de neden olabilir.

Diğer böbrek kisti türleri de şunlardır:

Edinilmiş kistik böbrek: Bu, tipik olarak uzun yıllar diyaliz tedavisinden sonra, uzun süreli böbrek hastalığının bir komplikasyonu olarak meydana gelir.

Medüller sünger böbrek: Medulla olarak bilinen böbreğin iç kısmında kistlerin geliştiği bir durumdur. Tekrarlayan böbrek taşlarına ve idrar yolu enfeksiyonlarına neden olabilir.

Parapelvik kistler: İdrarın üretere akmadan önce böbrek bölgesinde toplanıp gelişen kistlerdir

İnsanların nesneleri tanınması için önemli olan doku, tıbbi görüntülemelerde önemli bir yere sahiptir. Doku özelliklerine dayalı doku bölütlemesi, değişmeyen doku analizinde giderek daha fazla ilgi görmektedir. Normal dokuyu anormal dokudan ayıran doku bölütlemsi tıbbi uygulamada önemli bir yere sahiptir.

Dokuda, bölgenin muayenesi ve sınıflandırılması tıbbi görüntülemelerde tanı ve tedavide önemlidir.

Hastanın teşhis ve tedavi sürecinde kullanılan bölütleme görüntüsünden enfekte bölgenin çıkarılması için kullanılır. Parçalanmış bölgeden gelen öznelilikler, bölgenin doğruluğuna dayalı makine öğrenimi sistemlerinin geliştirilmesinde ve uygulamalarında kullanılır (Priya, 2015:306, Priya, 2014:1382, Akay, 2013:3066).

Anomali bölgelerinin görüntülerden çıkarılması, incelemeyi tanısal doğrulukla destekleyen bir durumdur (Çalışkan ve Türker, 2016:126). Segmentasyon (bölütleme) yapan çeşitli makine öğrenimi algoritmaları vardır. İlerleyen bölümlerde de görüleceği üzere bu çalışmada semantik bölütleme uygulanmıştır. Böbreklerdeki kistlerin incelendiği bu çalışmada sadece böbreklere odaklanıldı. Kullanılan görsellerde karaciğer, akciğer gibi organlarda görülmektedir. Örnek bölütleme kullanılsaydı karaciğer, akciğer gibi organlar da segmente edilerek algoritmaya verilirse bu hem zaman kaybına hem de sistemin aşırı yorulmasına neden olurdu.

Son zamanlarda, derin öğrenme modelleri tıbbi görüntülemelerde başarıyla uygulanmaya başlandı ve makine öğrenimi yöntemlerinin yerini almaya başladı (Liu, 2014:1015, Wang, 2018:1562, Acharya, 2018:270, Larie ve Abukmeil, 1998:110). Derin öğrenme modellerinin prostat ve meme kanseri çalışmalarında kullanılabileceğini göstermiştir (Litjens ve diğerleri, 2016:26282). Tıbbi görüntü bölütleme için yeni bir Evrişisel Sinir Ağı (ESA) modeli önermiştir (Wang ve diğerleri, 2018:1562). Önerilen model, mevcut yöntemlere göre daha az kullanıcı etkileşimi ve daha kısa sürede tıbbi görüntü bölütleme sağlayabilmektedir.

Çoğu otomatik segmentasyon çalışmasında, algılama, el yapımı özellikleri kullanan makine öğrenimi sınıflandırıcıları ile yapılır. Son yıllarda derin öğrenme algoritmaları, klasik makine öğrenme algoritmalarının sınırlamalarını ortadan kaldırıyor ve kendi kendine öğrenme yeteneği ile tıbbi görüntülerin özelliklerinin otomatik olarak keşfedilmesini sağlıyor.

Bu çalışmada GE Marka Brightspeed cihazından alınan karın görüntüleri kullanılarak görüntülere semantik bölütleme uygulandıktan sonra böbrekteki kistin başarı sonuçları UNET, Rastgele Orman Algoritması, Kernel Destek Makinesi ve Lojistik Regresyon ile araştırıldı.

1.1 Problemin Tespiti

Bilgisayarlı Tomografi (BT) cihazı diagnostik amaçlı kullanılan en yaygın cihazlardandır. Yapılan tanı amaçlı görüntülemelerde elde edilen BT tabanlı karın bölgesi çekimlerinde böbrek kistini tespit eden bir uygulamalara rastlanılmamıştır. Bu çalışmayla böbrek kistleri tespit edilerek makine öğrenmesi yöntemiyle araştırılmıştır.

1.2 Çalışmanın Amacı

Bu tez çalışmasının amacı BT cihazıyla yapılan çekimlerde elde edilen abdomen bölgesi görüntülerinde böbreklerde bulunan kistik yapıların makine öğrenmesi yöntemleri ile araştırılıp doğruluğu test edilmiştir.

1.3 Araştırmanın Metodolojisi

Böbrek kistlerinin makine öğrenmesi yöntemi ile araştırılması amacıyla;

- Literatür araştırılması yapılmıştır.
- İstanbul İYİTEM Görüntüleme Merkezi'nden BT görüntüleri araştırılıp tez için kullanılmıştır.
- Filtreleme ve bölütleme yöntemleri araştırılmıştır
- Bölütleme sonrası için makine öğrenmesi algoritmaları araştırılmıştır.

1.4 Ünitelerin Planı

Birinci bölümde genel bilgiler ışığında böbrek kistleri anlatılmıştır. İkinci bölümde filtreleme yöntemleri ve imaj güçlendirme çalışmaları anlatılmıştır. Üçüncü bölümde bölütleme hakkında ve medikal görüntülemelerde sentezleme, analiz ve bölütlemenin tıbbi görüntülemedeki önemi belirtilmiştir. Dördüncü bölümde makine öğrenmesi açıklanmış olup makine öğrenmesi türlerine değinilmiştir. Beşinci bölümde tezi oluşturan makine öğrenmesi türleri açıklanmıştır. Altıncı bölümde yapılan araştırma ve sonuç bilgileri bulunmaktadır. Yedinci bölümde ise elde edilen veriler karşılaştırılmış olup bu sonuçların tıbbi görüntülemede nasıl uygulanabileceği anlatılmıştır.

2 FİLTRELEME YÖNTEMİ KULLANILARAK İMAJLARIN GÜÇLENDİRİLMESİ

2.1 İmaj Güçlendirme

Görüntü geliştirme, görüntünün görsel kalitesini iyileştirmeyi içeren görüntü işlemede temel bir işlemdir. Görüntü geliştirmenin amacı, görüntüyü insan algısı için daha uygun hale getirmek veya makine öğrenimi veya bilgisayarla görme algoritmaları ile daha ileri işlemler için sağlamaktır.

İki ana görüntü geliştirme kategorisi vardır: Nokta işleme ve uzamsal işleme (Gonzales ve Woods, 2008:3).

Nokta işleme, görüntüdeki her piksele matematiksel bir işlev uygulamayı içerir. İşlev tipik olarak görüntünün kontrastını veya parlaklığını artırarak veya azaltarak piksel yoğunluk değerlerini ayarlar. Nokta işleme, renk dengesini veya doygunluğu ayarlamak gibi renk düzeltmelerini uygulamak için de kullanılabilir.

Uzamsal işleme, komşu piksellerin değerlerine dayalı olarak bir görüntünün piksel değerlerinin değiştirilmesini içerir. Yaygın uzamsal işleme teknikleri, görüntüdeki gürültüyü azaltan Gauss veya Medyan Filtreler gibi yumuşatma filtrelerini ve görüntüdeki kenarlarda ve ince ayrıntılarda kontrastı artıran keskinleştirme filtrelerini içerir.

Görüntü geliştirmede kullanılan diğer teknikler, görüntüdeki kontrastı artırmak için piksel yoğunluk değerlerini yeniden dağıtan histogram eşitleme ve görüntüyü farklı frekans bileşenlerine ayrıştıran ve görüntüdeki belirli özellikleri geliştirmek için kullanılabilen dalgacık dönüşümlerini içerir (Pizer ve diğerleri, 1987:355).

Görüntü geliştirme, tıbbi görüntüleme, gözetim ve dijital fotoğrafçılık dahil olmak üzere çok çeşitli uygulamalarda kullanılır. Analiz için daha net ve daha belirgin görüntüler sağlayarak makine öğrenimi ve bilgisayarla görme algoritmalarının doğruluğunu artırabilir.

2.2 İmaj Güçlendirmenin Medikal Görüntülemedeki Önemi

Görüntü geliştirme, X-ray, BT taraması, Manyetik Rezonans Görüntüleme (MRG) ve ultrason gibi çeşitli tanısal görüntüleme modaliteleri yoluyla yakalanan görüntülerin kalitesini değiştirmeyi ve iyileştirmeyi içeren tıbbi görüntülemenin çok önemli bir yönüdür. Görüntü geliştirmenin birincil amacı, görüntüdeki orijinal görüntü kullanılarak saptanması veya ayırt edilmesi zor olabilecek önemli özellikleri vurgulayarak tıbbi teşhisin doğruluğunu ve güvenilirliğini artırmaktır.

Tıbbi görüntülemede görüntü geliştirmenin bu kadar önemli olmasının temel nedenlerinden bazıları şunlardır: (Gordillo ve diğerleri, 2013:1426).

Gelişmiş Teşhis: Görüntü geliştirme, tıp uzmanlarının görüntülerin netliğini, kontrastını ve çözünürlüğünü iyileştirerek tıbbi durumları daha doğru bir şekilde tanımlamasına ve teşhis etmesine yardımcı olabilir. Örneğin, kontrast geliştirme normal ve anormal doku arasında ayırım yapmaya yardımcı olurken, gürültü azaltma küçük lezyonların veya diğer anormalliklerin görünürliğini iyileştirebilir.

Daha İyi Tedavi Planlaması: Geliştirilmiş görüntüler, doktorlara hastanın durumu hakkında daha kapsamlı bir anlayış sağlayabilir ve bu da daha iyi tedavi planlamasına yol açabilir. Görüntülerin kalitesini ve netliğini iyileştirerek doktorlar, tedavi kararlarını etkileyebilecek tümörlerin, kırıkların veya diğer anormalliklerin yerini ve boyutunu daha doğru bir şekilde belirleyebilir.

Azaltılmış Radyasyona Maruz Kalma: Bazı durumlarda, görüntü geliştirme, hastanın radyasyona maruz kalmasını azaltmaya yardımcı olabilecek ek görüntüleme testlerine olan ihtiyacı azaltabilir. Bir görüntünün netliğini ve çözünürlüğünü iyileştirerek, doktorlar ek taramalara ihtiyaç duymadan daha doğru bir teşhis koyabilir.

Daha Hızlı Teşhis: Görüntü geliştirme teknikleri, görüntülerin okunmasını ve yorumlanmasını kolaylaştırarak tanılama sürecini hızlandırmaya da yardımcı olabilir. Görüntü geliştirme, manuel yorumlama ihtiyacını azaltarak doktorların tıbbi durumları daha hızlı ve verimli bir şekilde teşhis etmesine yardımcı olabilir.

Görüntü geliştirme, tıbbi teşhisin doğruluğunu, güvenilirliğini ve hızını artırabilen tıbbi görüntülemenin kritik bir yönüdür. Doktorlar, tıbbi görüntülerin kalitesini ve netliğini artırarak daha bilinçli tedavi kararları verebilir, radyasyona maruz kalmayı azaltabilir ve sonuç olarak hasta sonuçlarını iyileştirebilir.


2.3 Otsu Eşikleme

Otsu eşikleme, medikal görüntülemelerde yaygın olarak kullanılan bir görüntü bölütleme tekniğidir ve bir görüntüdeki ilgili nesneleri veya bölgeleri arka plandan ayırmaya yardımcı olabilir. Bu yöntem, bir görüntüdeki nesne ve arka plan pikselleri arasındaki ayrımı maksimize eden optimal bir eşik değeri bulma fikrine dayanmaktadır (Li ve diğerleri, 2018:223).

Otsu eşikleme yöntemi, görüntü histogramının, nesne piksellerinin bir tepe noktası etrafında kümелendiği ve arka plan piksellerinin başka bir tepe noktası etrafında kümелendiği iki modlu bir dağılımla modellenebileceğini varsayar. Algoritma daha sonra, nesne ve arka plan piksellerinin en doğru şekilde ayrılmasıyla sonuçlanan bu iki tepe noktası arasındaki sınıf içi varyansı en aza indiren optimum eşik değerini hesaplar (Yen ve Chang, 1995:1657).

Tıbbi görüntülemelerde, Otsu eşikleme yöntemi, tümörlerin saptanması, kan damarlarının bölütlenmesi veya BT veya MRG görüntülerinde kemik dokusunun yumuşak dokudan ayrılması gibi çeşitli uygulamalar için kullanılabilir. Doktorlar, bu yapıları doğru bir şekilde bölümlere ayırarak teşhis ve tedavi planlaması hakkında daha bilinçli kararlar verebilir.

Otsu eşikleme yönteminin bir avantajı, onu gerçek zamanlı uygulamalar için uygun kılan basitliği ve hesaplama verimliliğidir. Ancak performansı, hatalı segmentasyon sonuçlarına yol açabilen görüntü gürültüsünden, tekdüze olmayan ışıklandırmadan ve diğer görüntü yapaylıklarından etkilenebilir. Bu nedenle, her uygulamada Otsu eşikleme yönteminin performansını dikkatli bir şekilde değerlendirmek ve gerekirse alternatif bölütleme yöntemlerini değerlendirmek önemlidir.




Şekil 2.1 Otsu Eşikleme

2.4 Gaussian Filtre ve Keskinliği Azaltma Filtresi

Gauss filtresi, tıbbi görüntülemelerde görüntü parazitini azaltmaya ve görüntü ayrıntılarını yumuşatmaya yardımcı olan, yaygın olarak kullanılan bir görüntü filtreleme tekniğidir. Bu filtre, görüntüyü yakındaki piksellere daha fazla ağırlık ve uzaktaki piksellere daha az ağırlık atayan çan şeklindeki bir eğri olan Gauss çekirdeği ile evriştirerek çalışır. Düzleştirme miktarı, Gauss çekirdeğinin boyutu değiştirilerek ayarlanabilir (Krishnaveni ve Sivanandam, 2012:3045).

Medikal görüntü bölütlemelerde, Gauss filtresi, bölütlemekten önce gürültüyü azaltmak ve görüntülerin kalitesini iyileştirmek için bir ön işleme adımı olarak kullanılabilir. Görüntüyü yumuşatarak Gauss filtresi, bölütlemeyi engelleyebilecek küçük, istenmeyen ayrıntıları kaldırırken görüntünün genel yapısını korumaya yardımcı olabilir.




Şekil 2.2 Gaussian Filtreden Geçirilmiş Görüntüler

Keskinliği Azaltma filtresi, tıbbi görüntülemelerde görüntü ayrıntılarını iyileştirmeye ve görüntü kontrastını iyileştirmeye yardımcı olan, yaygın olarak kullanılan başka bir görüntü filtreleme tekniğidir. Bu filtre, görüntünün bulanık bir sürümünü orijinal görüntüden çıkararak çalışır, bu da yüksek frekanslı bileşenleri yükseltir ve düşük frekanslı bileşenleri azaltır. Bu, daha keskin kenarlara ve daha fazla kontrasta sahip bir görüntüyle sonuçlanır.

Medikal görüntü bölütlemesinde Keskinliği Azaltma Filtresi, segmente edilmiş bölgelerin kalitesini artırmak ve segmentasyonun doğruluğunu iyileştirmek için bir son işlem adımı olarak kullanılabilir. Keskinliği Azaltma filtresi, yüksek frekanslı bileşenleri güçlendirerek, ilgilenilen bölgeler ile arka plan arasında daha iyi ayrım yapılmasına yardımcı olabilir ve bu da daha doğru bir bölütleme sağlar (Agrawal, 2018:386).

Hem Gaussian hem de Keskinliği Azaltma filtrelerinin, düzgün kullanılmadıkları takdirde görüntü kalitesi üzerinde olumsuz etkileri olabileceğini unutmamak önemlidir. Gauss filtresiyle aşırı yumuşatma, önemli görüntü ayrıntılarının kaybolmasına neden olabilirken, Keskinliği Azaltma filtresiyle aşırı keskinleştirme, gürültü ve bozulmalara neden olabilir. Bu nedenle, her uygulamada bu filtrelerin performansını dikkatlice değerlendirmek ve optimum sonuçları elde etmek için parametreleri buna göre ayarlamak önemlidir.



Şekil 2.3 Keskinliği Azaltılmış Filtre Görüntüleri

2.5 İkili Filtre ve Toplam Varyasyon Filtresi


İkili filtre, tıbbi görüntü işlemede kullanılan, kenarlar ve doku gibi önemli görüntü özelliklerini korurken görüntü parazitini azaltmaya yardımcı olan bir görüntü filtreleme tekniğidir. Tüm pikselleri eşit şekilde yumuşatan Gauss filtresinden farklı olarak, ikili filtre piksellere hem uzamsal uzaklıklarına hem de yoğunluk farklarına göre ağırlıklar atar. Bu, benzer yoğunluğa ve uzamsal yakınlığa sahip piksellere daha fazla ağırlık verilirken, benzer olmayan piksellere daha az ağırlık verildiği anlamına gelir (Tian ve diğerleri, 2016).

Tıbbi görüntü işlemede, çift taraflı filtre, daha fazla analiz veya bölümlenmeden önce gürültüyü azaltmak ve görüntülerin kalitesini iyileştirmek için bir ön işleme adımı olarak kullanılabilir. Kenarları ve dokuyu koruyarak, iki taraflı filtre ilgilenilen bölgeler ile arka plan arasında daha iyi ayrım yapılmasına yardımcı olabilir ve bu da daha doğru bir segmentasyon veya teşhis sağlar.


Toplam varyasyon filtresi, tıbbi görüntü işlemede kullanılan ve önemli görüntü ayrıntılarını korurken görüntü parazitini azaltmaya yardımcı olan başka bir görüntü filtreleme tekniğidir. Bu filtre, bir görüntüdeki piksel yoğunluğu değerlerindeki varyasyon miktarının bir ölçüsü olan görüntünün toplam varyasyonunu en aza indirerek çalışır. Filtre, toplam değişimi en aza indirerek, kenarlar ve doku gibi önemli görüntü özelliklerini korurken görüntü parazitini yumuşatabilir (Zhang ve diğerleri, 2016:1425, Cui ve diğerleri, 2019:39, Qu ve Sun, 2017:12, Manjusha ve diğerleri, 2016:767, Zhang ve diğerleri, 2018:79).

Tıbbi görüntü işlemede, toplam varyasyon filtresi, bölümlere ayrılmış bölgelerin kalitesini iyileştirmek ve görüntü kusurlarını azaltmak için bir işlem sonrası adım olarak kullanılabilir. Gürültüyü azaltarak ve önemli görüntü özelliklerini koruyarak toplam varyasyon filtresi, segmentasyon ve teşhisin doğruluğunu geliştirmeye yardımcı olabilir.

Hem ikili hem de toplam varyasyon filtrelerinin, gerçek zamanlı işleme gerektiren tıbbi görüntüleme uygulamalarında zorluk teşkil edebilecek hesaplama karmaşıklığına sahip olabileceğini not etmek önemlidir. Bu nedenle, her uygulamada bu filtrelerin performansını dikkatlice değerlendirmek ve gerekirse alternatif filtreleme tekniklerini değerlendirmek önemlidir.



Şekil 2.4 İkili Filtreden Geçirilmiş Görüntü



Şekil 2.5 Toplam Varyasyon Filtresi'nden Geçirilmiş Görüntü

2.6 Median Filter

Medyan filtre, kenarlar ve doku gibi önemli görüntü özelliklerini korurken görüntü parazitini azaltmaya yardımcı olan, tıbbi görüntü işlemede yaygın olarak kullanılan bir görüntü filtreleme tekniğidir. Bu filtre, görüntüdeki her pikseli, belirli bir pencere veya çekirdek boyutu içindeki komşu piksellerin medyan değeriyle değiştirerek çalışır.

Medikal görüntü işlemede medyan filtre, ileri analiz veya bölümlmeden önce gürültüyü azaltmak ve görüntülerin kalitesini iyileştirmek için bir ön işleme adımı olarak kullanılabilir. Medyan filtre, kenarları ve dokuyu koruyarak, ilgilenilen bölgeler ile arka plan arasında daha iyi ayırım yapılmasına yardımcı olabilir ve bu da daha doğru bir bölütleme veya teşhis sağlar (Yeung ve diğerleri, 2019:131)

Medyan filtrenin bir avantajı, tıbbi görüntülerde sık görülen, tuz-biber gürültüsü olarak da bilinen dürtüsel gürültüyü azaltmada etkili olmasıdır. Bu tür gürültü, bir görüntüdeki rasgele pikseller tamamen siyah veya tamamen beyaz olduğunda ortaya çıkar ve bu da görüntü analizi ve yorumunu etkileyebilir. Medyan filtre, aşırı piksel değerlerini, gürültüden daha az etkilenen komşu piksellerin medyan değeriyle değiştirdiği için bu tür gürültüyü azaltmada iyi çalışır (Akram ve diğerleri, 2019, Kaur ve diğerleri, 2020, Ataş ve Ünal, 2019).

Bununla birlikte, medyan filtrenin de sınırlamaları olabilir. Örneğin, tıbbi görüntülerde yaygın olarak görülen diğer bir gürültü türü olan Gauss gürültüsünü azaltmada etkili olmayabilir. Ek olarak, büyük bir çekirdek boyutunun kullanılması, önemli görüntü ayrıntılarının kaybolmasına neden olabilirken, küçük bir çekirdek boyutunun kullanılması paraziti etkili bir şekilde azaltmayabilir. Bu nedenle, her uygulamada medyan filtrenin performansını dikkatli bir şekilde değerlendirmek ve en iyi sonuçları elde etmek için çekirdek boyutunu buna göre ayarlamak önemlidir.

2.7 Eşik Değeri

Eşikleme, bir görüntüyü ikili veya çok düzeyli bölgelere bölmek için tıbbi görüntü işlemede yaygın olarak kullanılan bir tekniktir. Eşikleme, skaler bir değer veya bir değerler aralığı olan bir eşik değeri ayarlamayı ve görüntüdeki her pikseli,


piksel deęerinin eřik deęerinin üstüne veya altına düşmesine baęlı olarak ön plan veya arka plan olarak sınıflandırmayı içerir.

Tıbbi görüntü işlemede, tümörler veya lezyonlar gibi ilgilenilen bölgeleri arka plan dokusundan ayırmak için eşikleme kullanılabilir. Örneęin, akcięerlerin BT taramasında, akcięer dokusunu çevreleyen doku ve hava boşluklarından ayırmak için bir eşik uygulanabilir. Beynin bir MRG'sinde, beyaz madde veya gri madde gibi belirli bir doku tipini segmentlere ayırmak için bir eşik kullanılabilir.

Eřik deęerinin seçimi, görüntü bölütlemenin doğruluęu için kritik öneme sahiptir. Eřik deęeri çok düşük ayarlanırsa, görüntüdeki gürültü ve yapaylıklar ön plan olarak yanlış sınıflandırılabilir ve bu da yanlış pozitiflere neden olur. Öte yandan, eşik deęeri çok yüksek ayarlanırsa, görüntüdeki önemli özellikler ve yapılar arka plan olarak yanlış sınıflandırılarak yanlış negatiflere neden olabilir.

Tıbbi görüntü işlemede eşik deęeri belirlemek için çeřitli teknikler vardır. Bir yaklaşım, önceki bilgilere veya ampirik gözlemlere dayanan sabit bir eşik deęeri kullanmaktır. Başka bir yaklaşım, yerel piksel yoğunluk dağılımına dayalı olarak eşik deęerini ayarlayan Otsu yöntemi veya uyarlamalı eşikleme teknięi gibi eşik deęerini tahmin etmek için istatistiksel yöntemler kullanmaktır (Zhou ve Zheng, 2019:43)

Eřiklemenin basit ve etkili bir teknik olduęunu not etmek önemlidir, ancak her tür görüntü bölümleme görevi için uygun olmayabilir. Ön plan ve arka plan bölgelerinin benzer yoğunluk deęerlerine sahip olduęu durumlarda veya görüntünün farklı yoğunluk deęerlerine sahip birden çok bölge içerdieęi durumlarda, bölge büyütme veya kümeleme algoritmaları gibi daha karmařık bölümleme teknikleri gerekebilir.



Şekil 2.6 Farklı Eşik Değerleri için Görüntüler

2.8 Kenar Belirleme Filtresi

Kenar belirleme filtresi, bir görüntüdeki kenarları belirlemek için kullanılan bir dijital sinyal işleme tekniğidir. Bu filtreler, bir görüntüdeki piksel yoğunluğunu kullanarak bir pikselin komşularıyla olan farkını hesaplar.

Kenar belirleme filtreleri, çeşitli boyutlarda ve şekillerde olabilir. En yaygın olanlarından biri, 3x3 boyutunda bir matris şeklinde olan Sobel filtresidir. Sobel filtresi, bir pikselin sağında ve solunda bulunan piksellerin farkını hesaplayarak yatay kenarları belirler. Benzer şekilde, filtre üstündeki ve altındaki piksellerin farkını hesaplayarak dikey kenarları da belirleyebilir.

Sobel filtresi gibi diğer kenar belirleme filtreleri, bir pikselin etrafındaki piksellerin farkını hesaplayarak kenarların sertliğine ve yönelimine bağlı olarak kenarları tespit etmeye çalışır. Bu filtreler, gürültülü görüntülerde bile iyi sonuçlar verebilirler.

Kenar belirleme filtreleri, görüntü işleme uygulamalarında yaygın olarak kullanılmaktadır. Örneğin, tıbbi görüntüleme, organların ve lezyonların sınırlarını

belirlemek için kullanılabilirler. Ayrıca, görüntü işleme, görüntü analizi ve diğer alanlarda da kullanılmaktadırlar.

Tıbbi görüntülemede kenar belirleme filtresinin önemi büyüktür çünkü görüntülerin çoğu organların veya dokuların sınırlarını belirleme amacıyla kullanılır. Bu sınırların doğru bir şekilde belirlenmesi, tıbbi teşhis ve tedavinin doğru yapılmasında kritik öneme sahiptir.

Kenar belirleme filtreleri, görüntülerdeki organların veya dokuların sınırlarını belirlemek için kullanılabilir. Bu sınırların belirlenmesi, birçok tıbbi uygulama için gereklidir. Örneğin, bir tümörün sınırlarını belirlemek, bir bölgenin iltihaplanma derecesini tespit etmek veya bir kasın sınırını belirlemek gibi durumlarda kenar belirleme filtreleri kullanılabilir.

Ayrıca, kenar belirleme filtreleri, görüntülerdeki nesnelerin büyüklük, şekil, konum ve oryantasyonunu analiz etmek için kullanılabilir. Bu özellikleri kullanarak, görüntülerdeki nesnelerin çeşitli özellikleri tanımlanabilir ve bu özellikler daha sonra görüntüleri sınıflandırmak veya nesneleri tespit etmek için kullanılabilir.

Bu nedenle, kenar belirleme filtreleri, tıbbi görüntülemede sıkça kullanılan bir araçtır ve tıbbi teşhis ve tedavi süreçlerinde önemli bir rol oynamaktadır.

Ayrıca, kenar belirleme filtreleri, görüntülerin daha fazla analiz edilmesi için önemli bir adımdır. Bu filtreler, görüntülerin daha sonra kullanılacak diğer işlemler için daha iyi hazırlanmasına yardımcı olur. Örneğin, bir görüntüdeki organların sınırlarını doğru bir şekilde belirlemek, daha sonra bu organların hacmini veya yoğunluğunu hesaplamak için gereklidir.

Kenar belirleme filtreleri, tıbbi görüntülemede kullanılan diğer görüntü işleme teknikleriyle de birlikte kullanılabilir. Örneğin, kenar belirleme filtreleri, morfolojik işlemler gibi diğer filtreleme teknikleriyle birleştirilerek daha karmaşık işlemler gerçekleştirilebilir.

Sonuç olarak, tıbbi görüntülemede kenar belirleme filtreleri, organların ve dokuların sınırlarını belirleme, nesnelerin özelliklerini tanımlama ve görüntülerin daha fazla analizi için önemli bir araçtır. Bu filtreler, tıbbi teşhis ve tedavi süreçlerinde

önemli bir rol oynamaktadır ve tıbbi görüntülemelerde yaygın bir şekilde kullanılmaktadır.

2.9 Sobel Filtre

Sobel filtresi, dijital görüntülerdeki kenarları algılamak için kullanılan popüler bir görüntü işleme tekniğidir. Adını mucidi Irwin Sobel'den almıştır. Sobel filtresi, görüntü yoğunluğunun gradyan yaklaşımını hesaplamak için girdi görüntüsü üzerinde kıvrılan çekirdek tabanlı bir filtredir.

Sobel filtresi, biri yatay kenarları algılamak için ("x" veya "dikey" Sobel filtresi) ve diğeri dikey kenarları algılamak için ("y" veya "yatay" Sobel filtresi) olmak üzere iki 3x3 evrişim çekirdeğinden oluşur. Yatay filtre soldan sağa uzanan kenarları vurgularken, dikey filtre yukarıdan aşağıya doğru uzanan kenarları vurgular.

Sobel filtresini uygulamak için çekirdek, giriş görüntüsüyle sarılır. Filtre, her piksel konumunda, çevreleyen pikselleri ilgili çekirdekle çarparak ve sonucu toplayarak x ve y yönlerindeki gradyan yaklaşımını hesaplar. Bu işlem görüntüdeki her piksel için tekrarlanarak kenarların iyileştirildiği yeni bir görüntü elde edilir.

Sobel filtresinin çıktısı, kenarların vurgulandığı bir görüntüdür. Kenarın büyüklüğü, kenarın her iki tarafındaki piksellerin yoğunluk değerleri arasındaki farkla orantılıdır. Ortaya çıkan görüntü, kenarları çıkarmak için daha fazla işlenebilir veya nesne tanıma veya izleme gibi daha ileri analizler için kullanılabilir.

Sobel filtresi, basitliği ve etkinliği nedeniyle yaygın olarak kullanılan bir kenar algılama tekniğidir. Ancak, kalın kenarlar üretebilir ve giriş görüntüsündeki gürültüye karşı hassastır. Bu sorunları çözmek için Sobel filtresinde çeşitli değişiklikler önerilmiştir.

Yaygın bir değişiklik, daha kalın kenarlar üretmek için 5x5 veya 7x7 gibi daha büyük bir çekirdek boyutu kullanmaktır. Başka bir değişiklik, gürültüyü azaltmak için Sobel filtresini uygulamadan önce giriş görüntüsüne Gauss yumuşatma uygulamaktır. Bu, Gauss Sobel filtresi olarak bilinir.

Sobel filtresi, kenarları algılamaya ek olarak, görüntü bölümleme, özellik çıkarma ve doku analizi gibi diğer görüntü işleme görevleri için de kullanılabilir. Kenar algılamamanın doğruluğunu daha da artırmak için eşikleme ve maksimum olmayan bastırma gibi diğer tekniklerle birleştirilebilir.

Genel olarak, Sobel filtresi, bilgisayar görüşü, robotik ve tıbbi görüntüleme dahil olmak üzere çeşitli alanlarda geniş uygulamalar bulan basit ama güçlü bir görüntü işleme tekniğidir. Kenarları algılamadaki etkinliği ve uygulama kolaylığı, onu birçok görüntü işleme görevi için popüler bir seçim haline getiriyor.


Tıbbi görüntüleme, genellikle yüksek çözünürlüklü görüntülerin işlenmesi gerektiği bir alandır. Bu görüntülerdeki kenarların doğru bir şekilde tespit edilmesi ve işlenmesi, tanı ve tedavi sürecinde önemli bir rol oynamaktadır. Bu nedenle, kenar tespiti için Sobel filtresi tıbbi görüntülemede sıkça kullanılan bir tekniktir.

Sobel filtresi, bir görüntüdeki kenarları tespit etmek için kullanılan bir filtreleme tekniğidir. Görüntüdeki kenarlar, yoğunluk değişimlerinden kaynaklanır. Sobel filtresi, bir pikselin yoğunluğundaki değişikliğin bir ölçüsünü hesaplar ve bu değişikliğin büyüklüğüne göre kenarları tespit eder.

Tıbbi görüntülemede Sobel filtresi, hastalıklı dokuların tespitinde ve tıbbi teşhislerin yapılmasında kullanılmaktadır. Örneğin, bir MRG görüntüsünde tümörlerin tespit edilmesi veya bir röntgen görüntüsünde kemiklerin tespit edilmesi için Sobel filtresi kullanılabilir.

Sobel filtresi, yüksek çözünürlüklü tıbbi görüntülerdeki kenarları tespit etmek için etkili bir yöntemdir. Ancak, görüntülerdeki gürültüyü azaltmak için diğer filtreleme teknikleri ile birlikte kullanılması önerilir. Ayrıca, kenarların kalınlığı da bazen önemlidir ve bu durumda Sobel filtresi gibi ince kenarlar tespit eden filtreler yerine daha kalın kenarlar tespit eden filtreler kullanılabilir.

Sobel filtresi, tıbbi görüntülemede kenar tespiti için sıkça kullanılan bir tekniktir. Bu filtre, doğru tespit edilmiş kenarlar sayesinde hastalıkların tespit edilmesi ve teşhislerin yapılması için önemli bir araçtır.



Şekil 2.7 Kenar Belirleme ve Sobel Filtrelerinden Geçirilen Görüntüler

2.10 Görüntüleme Cihazları

2.10.1 Bilgisayarlı Tomografi

Bilgisayarlı tomografi, X-ışınlarının kullanıldığı bir görüntüleme tekniğidir. BT görüntüleme, vücudun kesitler halinde görüntülenmesine olanak tanır. Bu kesitler, 3D bir görüntü oluşturmak için bilgisayar tarafından bir araya getirilir.

BT görüntülemesi için, hasta bir tüp içinde uzanır ve tüp, dairesel bir hareketle etrafında döner. Bu dönme sırasında, X-ışınları, hastanın vücudundan geçer ve algılayıcılar tarafından tespit edilir. Bilgisayar, algılayıcılardan gelen verileri kullanarak, her açıdan alınan kesitleri bir araya getirir ve 3D bir görüntü oluşturur.

BT görüntüleme, vücuttaki birçok yapıyı ayrıntılı bir şekilde gösterir. Bu görüntüleme tekniği, beyin, göğüs, karın ve pelvis gibi birçok bölgenin görüntülenmesinde kullanılır. BT görüntülemesi, tıbbi teşhislerin yapılması, hastalıkların tespit edilmesi ve tedavinin planlanması için sıkça kullanılır.

BT görüntülemesi, bazı durumlarda kontrast madde kullanılarak da gerçekleştirilebilir. Kontrast madde, damar yoluyla verilir ve belirli yapıların daha iyi

görüntülenmesine olanak tanır. Örneğin, kontrast madde kullanılarak, beyin tümörleri, damar anomalileri veya kanamalar gibi yapılar daha iyi görüntülenebilir.

Ancak, BT görüntülemesi, yüksek dozda radyasyon maruziyeti ile ilişkilidir ve bu nedenle sık sık tekrarlanması önerilmez. Ayrıca, bazı insanlar için kontrast madde kullanımı sakıncalı olabilir. Bu nedenle, BT görüntülemesi, yararları ve riskleri dikkate alınarak doktorlar tarafından gerektiği şekilde kullanılmalıdır.

2.10.2 Manyetik Rezonans Görüntüleme

Manyetik rezonans görüntüleme, vücut içindeki organların, dokuların ve yapıların ayrıntılı bir şekilde görüntülenmesini sağlayan bir tıbbi görüntüleme tekniğidir. MRG, manyetik alan ve radyo dalgalarının kullanıldığı bir görüntüleme yöntemidir.

MRG görüntülemesi için, hasta büyük bir manyetik alana yerleştirilir. Manyetik alan, insan vücudu tarafından oluşturulan su moleküllerinin hareketini değiştirir. Bu nedenle, radyo dalgaları, vücudun içindeki dokulara yönlendirilir ve vücuttan yansıyan dalgalar, bir anten aracılığıyla alınır. Bu veriler, bilgisayar tarafından işlenir ve kesitli görüntüler oluşturulur.

MRG görüntülemesi, manyetik alan ve radyo dalgalarının kullanımı nedeniyle, radyasyon içermez ve genellikle diğer görüntüleme tekniklerine göre daha güvenlidir. Ayrıca, farklı doku tipleri arasındaki farklılıkları daha iyi gösterir ve hatta dokuların moleküler yapısını dahi belirleyebilir. Bu nedenle, MRG görüntülemesi, birçok tıbbi durumun tanısında ve tedavisinde yaygın olarak kullanılır.

MRG görüntülemesi, vücudun herhangi bir bölgesindeki birçok yapıyı görüntüleyebilir. Örneğin, MRG görüntülemesi, beyin, omurilik, kalp, karaciğer, böbrekler, kaslar, kemikler ve eklemler gibi birçok yapıyı ayrıntılı bir şekilde gösterir. Bu nedenle, MRG görüntülemesi, birçok tıbbi durumun tanısı ve takibi için kullanılabilir.

MRG görüntülemesi, aynı zamanda bazı minimal invaziv işlemlerin yapılmasında da kullanılır. Bu işlemler, MRG görüntülemesi ile yönlendirilir ve hedef

bölgeye ulaşır. Bu yöntem, hastanın iyileşme süresini kısaltır ve komplikasyon riskini azaltır.

Manyetik Rezonans Görüntüleme, manyetik alan ve radyo dalgalarının kullanıldığı, vücudun kesitler halinde görüntülenmesini sağlayan ve birçok tıbbi durumun tanısı ve takibinde kullanılan bir görüntüleme tekniğidir. MRG, radyasyon içermez ve diğer görüntüleme tekniklerine göre daha güvenlidir.

MRG'nin çalışma prensibi, manyetik alana ve radyo dalgalarına dayanır. Bir MRG cihazı, büyük bir manyetik alan oluşturarak, vücudun içindeki su moleküllerinin hareketini değiştirir. Bu manyetik alan, bir güçlendirici bobin kullanılarak oluşturulur. Daha sonra, bir anten aracılığıyla vücuttan yansıyan radyo dalgaları toplanır ve bilgisayar tarafından işlenir.

MRG, farklı dokuların farklı manyetik özellikleri sayesinde çalışır. Su molekülleri, manyetik bir alan içinde dönerek manyetik moment oluştururlar. Bu moment, radyo dalgalarının etkisi altında değiştirilir. Farklı dokuların manyetik özellikleri farklı olduğu için, farklı dokuların manyetik momentleri de farklıdır. Bu nedenle, MRG cihazı, farklı dokuların manyetik özelliklerine göre farklı sinyaller oluşturur.

Bilgisayar, MRG cihazından alınan sinyalleri işleyerek, vücudun kesitler halinde görüntülerini oluşturur. Bu görüntüler, farklı tıbbi durumların tanısı ve takibi için kullanılır. MRG, özellikle beyin, omurilik, kalp, karaciğer, böbrekler, kaslar, kemikler ve eklemler gibi birçok yapıyı ayrıntılı bir şekilde görüntüleyebilir.

MRG görüntülemesi, radyasyon içermez ve genellikle diğer görüntüleme tekniklerine göre daha güvenlidir. Ancak, bazı durumlarda, manyetik alana maruz kalmak, kalp pili, beyin anevrizması klipsi, metal kalça protezi veya metal yabancı cisimleri olan kişiler için sakıncalı olabilir. Bu nedenle, MRG yapılacak kişilerin önceden doktorlarına danışmaları ve MRG uygunluğunu belirlemeleri önerilir.

Sonuç olarak, MRG, manyetik alan ve radyo dalgalarının kullanıldığı bir tıbbi görüntüleme tekniğidir. Farklı dokuların manyetik özellikleri sayesinde çalışan MRG, birçok tıbbi durumun tanısı ve takibi için kullanılır. MRG, radyasyon içermez ve diğer görüntüleme tekniklerine göre daha güvenlidir.

2.10.3 Mammografi Görüntüleme

Mammografi, kadınların meme kanseri taraması için kullanılan bir görüntüleme teknolojisidir. Mammografi, x-ışınları kullanarak meme dokusunun iç yapısını görüntülemeyi sağlar. Bu teknik, kanserin erken teşhisinde önemli bir rol oynar, çünkü kanserin erken evrelerinde teşhis edilmesi, tedavi şansını artırır ve hayatta kalma oranını yükseltir.

Mammografi işlemi, kadınların göğüslerini bir plaka üzerine yerleştirerek sıkıştırmayı içerir. Bu işlem, meme dokusunun daha net görüntülenebilmesi için sıkıştırma yaparak meme dokusunun kalınlığını azaltır. Sıkıştırma işlemi bazen hafif bir acıya neden olabilir, ancak işlem genellikle çok kısa sürer ve çoğu kadın için tolerans edilebilir bir düzeydedir.

Mammografi, x-ışınları kullanarak meme dokusunun iç yapısını görüntüleyerek çalışır. X-ışınları, meme dokusunun farklı yoğunluklarına göre emilir. Bu emilim farklılıkları, filmin üzerinde farklı yoğunluklar olarak görüntülenir ve doktorlar tarafından incelenir. Bu şekilde, meme dokusundaki kitleler, kalsiyum birikintileri veya diğer anormallikler tespit edilebilir.

Mammografi, erken teşhisin yanı sıra, risk faktörleri yüksek olan kadınlar için de önerilir. Bu faktörler arasında ailede meme kanseri öyküsü, önceki meme kanseri teşhisi veya radyoterapi tedavisi öyküsü bulunur. Mammografi, aynı zamanda kadınların meme dokusunu takip etmek için de kullanılır.

Mammografi, kadınların meme kanseri taraması için kullanılan bir görüntüleme teknolojisidir. X-ışınları kullanarak meme dokusunun iç yapısını görüntüleyen mammografi, kanserin erken teşhisi ve risk faktörleri yüksek olan kadınların takibi için önemlidir. Mammografi, sıkıştırma işlemi nedeniyle bazen hafif bir acıya neden olsa da, erken teşhisin önemini vurgulamak için kadınların yılda bir kez mammografi yaptırmaları önerilir.

3 TIBBİ GÖRÜNTÜLEME VE BÖLÜTLEME

3.1 Bölütleme

Tanısal görüntüleme tıpta çok önemlidir. Manyetik rezonans görüntüleme, bilgisayarlı tomografi, dijital mamografi gibi görüntüleme cihazları, doku anatomisini invazif olmayan bir şekilde belirlemek için kullanılır. Bu sistemler, tıbbi araştırmalar için doku bilgisini büyük ölçüde artırdı ve teşhis ve tedavi planlamasında kritik bir bileşendir.

Bu tıbbi görüntülerdeki artan veri boyutu, işleme ve analizi kolaylaştırmak için bilgisayarların kullanılmasını gerektirdi. Özellikle, dokuların tasviri için bilgisayar algoritmaları, belirli tıbbi görevleri desteklemek için daha önemli hale geliyor. Görüntü bölütleme algoritmaları olarak adlandırılan bu algoritmalar, doku hacimlerinin ölçümü, tanı, patolojinin lokalizasyonu, anatomik yapının incelenmesi, tedavi planlaması, cerrahi ve bilgisayar gibi alanlarda oldukça önemlidir (Larrie ve Abukmeil, 1998:110, Taylor, 1995:945, Zijdenbos ve Dawant, 1994:401, Worthve diğerleri, 1997:1167, Khoo ve diğerleri, 1997:15, Grimson ve diğerleri, 1997:1367).


Bölütlemeye bir görüntü, bir veya daha fazla özelliğine göre homojen bölgelere ayrılır. Tıbbi görüntülemeye önemli bir yere sahip olan bölütleme, lezyon kalifikasyonu, cerrahi simülasyonlar, cerrahi planlar, fonksiyonel haritalama, bilgisayar destekli tanı ve görüntü eşleştirme gibi birçok uygulamada kullanılmaktadır (Kaur ve diğerleri, 2018:156).

Çeşitli bölütleme teknikleri önerilmesine rağmen, tüm görüntü uygulamaları için standart bir bölütleme uygulaması yoktur. Beyin, akciğer ve böbrek gibi anatomik yapıları bölümlere ayırmak için modellenmiştir ve genellikle MRG ve BT gibi görüntüleme yöntemleri için optimize edilmiştir.

Çalışmalar, MRG ve BT görüntülemeye üç tür bilginin kullanılmasının faydalı olacağını göstermiştir. Yapıların gri seviyeli görünümü için yoğunluk modelleri, farklı yapıların şeklini tanımlayan şekil modelleri, görüntüleme sürecinin özelliklerini yakalayan görüntüleme modelleri (Suri ve diğerleri, 2005:495).

Anatomik lokalizasyon olan segmentasyon uygulamasının amacı, bölgenin ilgili anatomik yapılarla betimlenmesidir. Bölütleme, aynı dokuya ait tüm pikselleri veya vokselleri tanımlar. Bölütleme sadece özellik çıkarma için değil, aynı zamanda ölçümler ve görüntü sıkıştırma için de kullanılır (Suri ve diğerleri, 2005:495).

Segmentasyon örnek ve semantik (anlamalı) olarak ikiye ayrılır. Bu çalışmada böbrek görüntülerinde bulunan kistlere odaklanılacağı için anlamalı bölütleme uygulanmıştır. Örnek bölütleme uygulansaydı, görüntülerde böbrek dışında yer alan karaciğer, akciğer gibi organlara odaklanmak gerekirdi. Bu hem sistemi yorar hem de zaman kaybına neden olur.



Şekil 3.1 Bölütleme Yapılmış Görüntü (Sağdaki Görüntü Soldaki Görüntünün Bölütü)

3.2 Anlamsal Bölütleme

Tıbbi görüntüleme anlamalı bölütleme çok önemlidir çünkü doktorların ve tıp uzmanlarının bir hastanın anatomisindeki belirli ilgi alanlarını belirlemesine ve analiz etmesine olanak tanır. Bu, teşhis, tedavi planlaması ve hastalık ilerlemesinin izlenmesi için değerli bilgiler sağlayabilir (Li-Ping ve diğerleri, 2014).

Örneğin beyin görüntüleme, korteks, beyaz madde ve kortikal altı yapılar gibi beynin farklı bölgelerini tanımlamak için anlamalı bölütleme kullanılabilir. Bu, doktorların hastanın bilişsel işlevini etkileyebilecek lezyonları, tümörleri veya diğer anormallikleri bulmasına yardımcı olabilir. Benzer şekilde, kardiyak görüntüleme, kalbin işlevini değerlendirmek ve kardiyovasküler hastalıkları teşhis etmek için kalbin ventriküller ve kulakçıklar gibi farklı yapılarını segmentlere ayırmak için anlamalı segmentasyon kullanılabilir.

Anlamalı bölütleme, bilgisayar destekli tanı ve tedavi planlaması için de kullanılabilir. Örneğin, radyasyon tedavisi planlamasında, tümörü ve çevredeki sağlıklı dokuyu tanımlamak için semantik segmentasyon kullanılabilir, bu da radyasyon onkologlarının sağlıklı dokuya verilen zararı en aza indirirken tümörü yüksek hassasiyetle hedeflemesine olanak tanır.

Tıbbi görüntülemelerde anlamalı bölütleme, doğru tanı, tedavi planlaması ve hastalık ilerlemesinin izlenmesi için gereklidir (Chan ve diğerleri, 2018:2125). Hastanın anatomisine ilişkin değerli içgörüler sağlar ve doktorların hastanın bakımı hakkında bilinçli kararlar vermesine yardımcı olabilir.

Anlamalı bölütleme, tıbbi görüntülerdeki anatomik yapıların ve anormalliklerin doğru ve kesin olarak tanımlanmasına izin verdiği için tıbbi görüntülemelerde özellikle önemlidir. Bu segmentasyon, tümörler, lezyonlar, organlar ve kan damarları gibi belirli ilgi alanlarını belirlemek ve analiz etmek için kullanılabilir. Tıp uzmanları, bu yapıları doğru bir şekilde tanımlayarak teşhis, tedavi ve hastalığın ilerlemesini izleme hakkında daha bilinçli kararlar verebilir. Anlamsal bölümlleme, tıbbi görüntü yorumlamada gözlemciler arası değişkenliği azaltmaya yardımcı olabilir. Farklı doktorların tıbbi görüntüleri farklı yorumlamaları olabilir, ancak anlamalı bölütleme, görüntüleri analiz etmek için tutarlı ve objektif bir yol sağlayarak doğruluğu artırır ve hataları azaltır.

Bir görüntünün dokularının her pikseli, bir sınıf etiketi atama sürecini ifade eder. Piksele göre görüntü sınıflandırması da denir. Tıbbi görüntüleme alanında çok önemlidir. Anlamalı bölümlleme, görüntüdeki sayılamayanları arar. Her görüntü pikselini inceler ve temsil ettiği dokuyu ayrı ayrı sınıflandırır (Hesamian ve diğerleri, 2019:582).

Anlamalı bölümlleme, bir görüntünün, her bir bölümün görüntüdeki belirli bir nesneye veya ilgi alanına karşılık geldiği farklı bölgelere veya bölümlere bölünmesini içeren bir bilgisayarla görme görevidir. Anlamalı bölütlemenin amacı, görüntüdeki her pikseli "araba", "ağaç", "gökyüzü", "yol", "kişi" vb. gibi önceden tanımlanmış birkaç kategoriden birine sınıflandırmaktır.

Tüm görüntüye tek bir etiket atayan basit görüntü sınıflandırma görevlerinden farklı olarak, semantik bölütleme, her pikseli ayrı ayrı etiketleyerek görüntünün içeriğinin daha ayrıntılı bir şekilde anlaşılmasını sağlar. Bu, onu otonom sürüş, tıbbi görüntü analizi ve görüntü ve video düzenleme dahil olmak üzere çok çeşitli uygulamalar için güçlü bir araç haline getirir.

Anlamlı bölütleme, geleneksel bilgisayar görme yöntemleri ve evrişimli sinir ağları (ESA) gibi derin öğrenme algoritmaları dahil olmak üzere çeşitli teknikler kullanılarak gerçekleştirilebilir. Anlamlı segmentasyon için en popüler derin öğrenme mimarileri arasında U-Net, Mask Bölge-ESA ve Tamamen Evrişimli Ağ (TEA) bulunur.

Klasik filtreleme yöntemlerinin yetersizliği nedeniyle semantik bölütleme alanında derin öğrenme yöntemleri başarıyla uygulanmaktadır. Ronneberger ve ark. çalışmalarında tıbbi görüntüleri segmentlere ayırmak için UNET derin öğrenme mimarisini önerdiler (Ronneberger ve diğerleri, 2015:234).

3.3 Tıbbi Görüntülemede Böbrek Kistlerinde Anlamlı Bölütlemenin Önemi

Tıbbi görüntülemede böbrek kistlerinin anlamlı bölütlemesi birkaç nedenden dolayı önemlidir.

İlk olarak, böbrek kistlerinin anlamlı bölütlemesi, böbrek yetmezliğine yol açabilen yaygın bir genetik bozukluk olan polikistik böbrek hastalığının (PBH) teşhisinde yardımcı olabilir. PBH, böbreklerde çok sayıda kistin büyümesi ile karakterize edilir ve anlamlı bölütlemesi, tanı ve tedavi planlamasına yardımcı olarak bu kistlerin boyutunu ve sayısını doğru bir şekilde tanımlayabilir ve ölçebilir (Vardhanabbuti ve Venkatesh, 2019:329).

İkincisi, böbrek kistlerinin anlamlı bölütlemesi, PBH'li hastalarda hastalığın ilerlemesini izlemek için kullanılabilir. Tıp uzmanları, zaman içinde kistlerin boyutu ve sayısındaki değişiklikleri izleyerek tedavinin etkinliğini değerlendirebilir ve tedavi planlarını buna göre ayarlayabilir.

Üçüncüsü, böbrek kistlerinin semantik bölütlenmesi, böbrek ameliyatlarının ameliyat öncesi planlamasına yardımcı olabilir. Örneğin, bir hastanın kistinin çıkarılması gerekiyorsa anlamlı bölütleme, kistin kesin yerini ve boyutunu belirlemeye yardımcı olarak cerrahların prosedürü daha doğru ve güvenli bir şekilde planlamasına olanak tanır.

Böbrek kistlerinin anlamlı bölütlemesi, PBH için yeni tedavilerin geliştirilmesine ve değerlendirilmesine yardımcı olabilir. Tıp uzmanları, yeni tedavilere yanıt olarak kistlerin boyutunu ve sayısını doğru bir şekilde ölçerek, bunların etkinliğini değerlendirebilir ve potansiyel olarak hastalığın ilerlemesini yavaşlatabilecek veya durdurabilecek yeni tedaviler geliştirebilir.


Ayrıca, böbrek kistlerinin anlamlı bölütlemesi, diğer renal kistik lezyonların saptanmasına ve karakterizasyonuna yardımcı olabilir. Renal kistik lezyonlar tıbbi görüntülemelerde yaygındır ve tiplerine ve özelliklerine bağlı olarak farklı klinik etkileri olabilir. Anlamlı bölütleme, farklı yönetim stratejileri ve prognozları olabilen basit kistler, kompleks kistler ve kistik tümörler gibi farklı böbrek kistleri türleri arasında ayırım yapmaya yardımcı olabilir.

Böbrek kistlerinin anlamlı bölütlemesi, otozomal dominant tubulointerstisyel böbrek hastalığı gibi diğer böbrek durumlarının tanı ve tedavisinde de yardımcı olabilir. Otozomal dominant tubulointerstisyel böbrek hastalığı, renal tübülleri ve interstisyumu etkileyen, böbrek yetmezliğine yol açan nadir bir genetik bozukluktur. Anlamlı Bölütleme, renal tübüller ve interstisyumdaki değişiklikleri doğru bir şekilde tanımlayabilir ve ölçebilir, bu durumun teşhisine ve izlenmesine yardımcı olur (Glass ve diğerleri, 2019:22)

Böbrek kistlerinin semantik segmentasyonu, tıbbi görüntü analizinin doğruluğunu ve tekrarlanabilirliğini geliştirmeye yardımcı olabilir ve böbrek kistlerini segmentlere ayırmak için standartlaştırılmış ve otomatikleştirilmiş bir yöntem sağlayarak, gözlemciler arası değişkenliği azaltabilir ve tıbbi görüntü yorumlamada verimliliği artırabilir.

Tıbbi görüntülemelerde böbrek kistlerinin anlamsal bölütlenmesi tanı, hastalık takibi, tedavi planlaması, cerrahi planlama ve polikistik böbrek hastalığı için yeni

tedavilerin geliştirilmesi için önemlidir. Tıbbi görüntülemede böbrek kistlerinin anlamlı segmentasyonu, polikistik böbrek hastalığının yanı sıra diğer renal kistik lezyonlar ve durumların teşhisi, izlenmesi ve yönetimi için çok önemlidir. Ameliyat öncesi planlamayı iyileştirebilir, yeni tedavilerin geliştirilmesine ve değerlendirilmesine yardımcı olabilir ve tıbbi görüntü analizinin doğruluğunu ve tekrarlanabilirliğini artırabilir.



Şekil 3.2 Kisti olan ve işaretlenmiş böbrek görüntüsü

3.4 Tıbbi Görüntüleme Teşhis

Tıbbi görüntü teşhisi, tıbbi durumları teşhis etmek ve tedavi etmek için X-ışınları, BT taramaları, MRG taramaları ve ultrason gibi tıbbi görüntüleme tekniklerini kullanma sürecini ifade eder. Tıbbi görüntüleme teknikleri, doktorların ve tıp uzmanlarının invaziv prosedürler olmadan insan vücudunun içini görmelerine izin vererek onları çok çeşitli tıbbi durumların teşhisinde değerli bir araç haline getirir.

Tıbbi görüntü teşhisi, anormallikleri, lezyonları veya diğer hastalık belirtilerini belirlemek için bu tekniklerle üretilen görüntülerin analiz edilmesini içerir. Bu işlem, eğitimli bir tıp uzmanı tarafından görsel olarak veya bilgisayar algoritmaları ve yapay zeka yardımıyla yapılabilir.

Bilgisayar destekli tıbbi görüntü teşhisi (BDTGT), tıbbi görüntüleri otomatik olarak analiz etmek ve anormallikleri tespit etmek için evrişimli sinir ağları gibi makine öğrenimi ve derin öğrenme tekniklerinin kullanılmasını içerir (Fathima ve Manivannan, 2021:38). BDTGT, tıbbi teşhisin doğruluğunu ve hızını artırma

potansiyeline sahiptir ve tıp uzmanlarına daha doğru teşhis ve tedavi planları yapmalarında yardımcı olabilir.

Tıbbi görüntü teşhisi, diğerleri arasında radyoloji, kardiyoloji, onkoloji ve nöroloji dahil olmak üzere birçok tıbbi alanda kullanılmaktadır. Vücuttaki tümörleri ve diğer anormallikleri tespit etmekten hastalığın ilerlemesini izlemeye ve tedavilerin etkinliğini değerlendirmeye kadar geniş bir uygulama yelpazesine sahiptir.

Tıbbi görüntüleme, sağlık sistemindeki hastalar arasındaki çeşitli hastalık türlerinin teşhisinde çok önemlidir (National Academies Press,2015). MRG, BT, Ultrason ve X-Işınlarını içeren tıbbi görüntüler, radyologlar tarafından manuel olarak uygulanan hastalık teşhisi için kullanılmaktadır. Ancak teşhis hataları, radyologlar iyi eğitilmiş olmadığında veya çok sayıda hasta nedeniyle zamanları veya dikkatleri ile sınırlı olmadığında ortaya çıkar. Bu nedenle, bazı araştırmacılar radyologlara hastalık tanısında yardımcı olmak için bilgisayar destekli tanıyı keşfetmeyi amaçlamaktadır (Reis ve diğerleri, 2009:339, Rajkomar ve diğerleri, 2016:29, Beam ve Kohane, 2018:1317). Klinisyenler için iyi becerili veya deneyimli bilgi gerektiren öznel olarak çıkarmada makine öğreniminin sınırlılığı göz önüne alındığında, derin öğrenme tanı sistemi, otomatik öznel seçim yeteneği nedeniyle büyük ilgi görmektedir. Spesifik olarak, derin sinir ağları, tıbbi görüntü verilerinden insan müdahalesi olmadan bilgilendirici bilgileri otomatik olarak öğrenebilir. Derin öğrenmenin, koronavirüs hastalığı 2019 (Li ve diğerleri, 2020:65), cilt kanseri (Esteva ve diğerleri, 2017:115) ve diyabetik retinopati (Keremany ve diğerleri, 2018:1122) gibi tıbbi görüntüleme bilgisayar destekli tanı için avantajlı olduğu kanıtlanmıştır. Ayrıca, örneğin akciğer kanseri (Blanc-Duran ve diğerleri, 2020:1,Xu ve diğerleri, 2019:3266), gliomalar (Tang ve diğerleri, 2020:2100) ve nazofarenks kanseri (Peng ve diğerleri, 2019:4271) gibi hastalıkların prognozunda bir iyileşmeye yol açan, görüntülemeye dayalı biyobelirteçlerin tanımlanmasına yardımcı olmak için geliştirilmiştir.

3.5 Tıbbi Görüntü Sentezi

Tıbbi görüntü sentezi, makine öğrenimi ve derin öğrenme gibi hesaplama yöntemlerini kullanarak gerçekçi tıbbi görüntüler oluşturmayı içeren bir araştırma alanıdır. Tıbbi görüntü sentezinin amacı, tıbbi teşhis, tedavi planlaması ve tıp eğitimi dahil olmak üzere çeşitli amaçlar için kullanılabilen yüksek kaliteli görüntüler

oluşturmaktır (Havaei ve diğerleri, 2017:1114, Mohammed ve Hamarneh, 2019:13, Wei ve diğerleri, 2018:5405).

Tıbbi görüntü sentezi, özellikle yüksek kaliteli tıbbi görüntülerin elde edilmesinin zor veya pahalı olduğu veya mevcut verilerin az olduğu durumlarda yararlıdır. Örneğin, tıbbi görüntü sentezi, nadir görülen hastalıkların veya durumların sentetik görüntülerini oluşturmak veya mevcut tıbbi görüntü veri setlerini kalite ve niceliklerini iyileştirmek için çoğaltmak için kullanılabilir.

Üretken çekişmeli ağlar (ÜÇA), değişken otomatik kodlayıcılar (DOK) ve koşullu üretken modeller dahil olmak üzere tıbbi görüntü sentezi için kullanılan çeşitli teknikler vardır. Bu teknikler, tıbbi görüntülerin temel dağılımını öğrenebilir ve görünüş olarak gerçek tıbbi görüntülere benzeyen yeni görüntüler oluşturabilir.

Tıbbi görüntü sentezi, tıp eğitimi, cerrahi planlama ve tıbbi araştırma dahil olmak üzere geniş bir uygulama yelpazesine sahiptir. Yeni tıbbi görüntüleme teknikleri ve algoritmaları geliştirmek ve test etmek ve tıbbi görüntü analizinin doğruluğunu ve verimliliğini artırmak için de kullanılabilir.

3.6 Medikal Görüntü Analizi

Medikal görüntü analizi, temizleme kamerasının dijital formatta analiz edilmesi ve yorumlanması işlemidir. Bu tür görüntüler, genellikle X-ışınları, manyetik rezonans görüntüleme, bilgisayarlı tomografi, ultrasonografi (USG) veya pozitron emisyon tomografisi gibi tıbbi cihazlar tarafından üretilir.

Medikal görüntü analizi, bu analizin ölçülmesi ve tedavi edilmesi için incelenmesini ve değerlendirilmesini sağlar. Bu işlem sırasında, görüntüler genellikle yapılandırma, renk, şekil ve boyut gibi işlemlere göre parçalanır ve bu özelliklerin analizi yapılır.

Medikal görüntü analizi, birçok farklı amaç için kullanılabilir. Örneğin, kanser hücreleri, kalp hastalığı incelemesi, beyin hasarı değerlendirmesi ve kemik kırıklarının sonuçları gibi birçok bakımlı durumda kullanılabilir. Ayrıca, bu teknoloji ayrıca arıtma tesislerinde ve görüntü yönlendirilmiş cerrahi bölümünde de kullanılır.

Tıbbi görüntü analizi tipik olarak görüntü elde etme, ön işleme, segmentasyon, özellik çıkarma ve sınıflandırma dahil olmak üzere birkaç adımı içerir. Görüntü elde etme, tıbbi görüntünün özel ekipman kullanılarak yakalanmasını içerir. Ön işleme, görüntünün analize hazır olduğundan emin olmak için görüntü kalitesini artırmayı, gürültüyü gidermeyi ve artefaktları düzeltmeyi içerir.

Segmentasyon, görüntüde bulunan dokuların veya yapıların özelliklerine dayalı olarak görüntüyü ilgilenilen bölgelere ayırma işlemidir. Bu, eşikleme, bölge büyütme veya kenar algılama gibi çeşitli teknikler kullanılarak yapılabilir.

Özellik çıkarımı, bölümlere ayrılmış bölgelerden anlamlı özelliklerin tanımlanmasını ve çıkarılmasını içerir. Bu özellikler, uygulamaya bağlı olarak doku, şekil veya yoğunluk özelliklerini içerebilir.

Sınıflandırma, çıkarılan özelliklere dayalı olarak her parçalanmış bölgeye bir etiket veya kategori atamayı içerir. Bu, destek vektör makineleri, karar ağaçları veya sinir ağları gibi makine öğrenimi teknikleri kullanılarak yapılabilir.

Tıbbi görüntü analizinin çıktısı, hastalıkları tanımlama ve teşhis etme, hastalık ilerlemesini izleme veya tedavilerin etkinliğini değerlendirme gibi çeşitli amaçlar için kullanılabilir. Ayrıca cerrahi, radyasyon tedavisi veya iğne biyopsisi gibi tıbbi prosedürlere rehberlik etmek için de kullanılabilir.

Genel olarak tıbbi görüntü analizi, klinisyenlerin daha doğru teşhisler koymasına, daha etkili tedaviler planlamasına ve hasta sonuçlarını iyileştirmesine olanak tanıyarak modern tıpta önemli bir rol oynar.

3.7 Doku Analizi

Doku analizi, bir görüntü içindeki farklı yoğunluk değerlerinin uzamsal düzenlenmesini karakterize etmek ve ölçmek için görüntü işlemede kullanılan bir tekniktir. Bir görüntünün yerel komşuluklarında tekrar eden yoğunluktaki varyasyon modellerinin tanımlanmasını içerir.

Tıbbi görüntü analizinde, çeşitli tıbbi durumların teşhisinde, prognozunda ve tedavisinde yardımcı olabilecek BT, MRG veya ultrason gibi tıbbi görüntülerden

anlamalı özellikler çıkarmak için doku analizi kullanılır. Doku özellikleri, benzer gri seviyelerine sahip dokuları analiz etmede özellikle yararlıdır ve bu da onları görsel olarak ayırt etmeyi zorlaştırır.

Doku analizi yöntemleri genel olarak iki kategoriye ayrılabilir: istatistiksel ve model tabanlı. İstatistiksel yöntemler, ortalama, varyans, çarpıklık ve basıklık gibi istatistiksel ölçümler kullanılarak tanımlanmış bir ilgi alanı (İA) içindeki piksel değerlerinin dağılımının analiz edilmesini içerir. Bu istatistiksel ölçümler, İA içindeki dokunun homojenliğini, kontrastını ve pürüzsüzlüğünü karakterize etmek için kullanılabilir.

Öte yandan, model tabanlı yöntemler, dokuyu bir dizi rastgele değişken olarak modellemeyi ve aralarındaki mekansal ilişkiyi açıklamak için matematiksel modeller kullanmayı içerir. Böyle bir model, bir görüntüde birlikte ortaya çıkan gri düzey değerleri çiftlerinin sıklığını hesaplayan Gri Düzey Birlikte Oluşum Matrisidir. Başka bir model, gri seviye değerinin komşu piksellerle karşılaştırılmasına dayalı olarak bir görüntüdeki her piksel için bir ikili kod hesaplayan Yerel İkili Modeldir.

Doku özellikleri çıkarıldıktan sonra, tıbbi görüntülerin sınıflandırılması, segmentasyonu ve görselleştirilmesi için kullanılabilirler. Doku analizi, tümörlerin tespiti, doku tiplerinin sınıflandırılması ve tedavi yanıtının değerlendirilmesi dahil olmak üzere birçok tıbbi uygulamada kullanılmıştır.

3.8 Doku Bölütlemesi

Doku bölütleme (segmentasyon), bir görüntüyü, görüntüde bulunan doku bilgilerine dayalı olarak bölgelere ayırma işlemidir. Başka bir deyişle, bir görüntünün benzer doku özelliklerine sahip farklı bölgelerinin tanımlanmasını içerir.

Doku segmentasyonu, nesne tanıma, sahne anlayışı ve tıbbi görüntü analizi gibi birçok görüntü analizi görevinde önemli bir adımdır. Örneğin, tıbbi görüntülemede, tümörler, kan damarları veya kemikler gibi belirli doku türlerini içeren görüntülerde ilgi alanlarını (İA) belirlemek için doku segmentasyonu kullanılabilir.

Doku bölütleme, denetimli ve denetimsiz teknikler gibi farklı yöntemler kullanılarak gerçekleştirilebilir. Denetimli doku segmentasyonunda, bir görüntünün

farklı bölgelerini bir dizi etiketli eğitim verisine dayalı olarak sınıflandırmak için eğitilmiş bir model kullanılır. Bu yaklaşım, görüntüde bulunan doku türleri hakkında ön bilgi gerektirir ve segmentasyon sürecinde yüksek doğruluk sağlayabilir.

Denetimsiz doku bölütlemeye ise görüntünün farklı bölgeleri, görüntünün istatistiksel özelliklerine göre tanımlanır. Denetimsiz doku segmentasyonunda kullanılan yaygın teknikler, k-ortalamlar ve bulanık c-ortalamlar gibi kümeleme algoritmalarını veya Canny veya Sobel kenar algılama gibi kenar algılama tekniklerini içerir.

Genel olarak, doku segmentasyonu, bir görüntünün farklı bölgelerini doku özelliklerine göre tanımlamaya ve karakterize etmeye yardımcı olabilecek, görüntü analizinde güçlü bir araçtır. Tıbbi görüntüleme, uzaktan algılama ve bilgisayar görüşü dahil olmak üzere farklı alanlarda çok sayıda uygulamaya sahiptir.

Ayrıca doku tabanlı, bölge tabanlı ve kenar tabanlı teknikler dahil olmak üzere çeşitli yaklaşımlar kullanılarak da elde edilebilir.

Doku tabanlı segmentasyon yöntemleri, benzer dokulara sahip bölgeleri belirlemek için istatistiksel ölçümlere ve doku özelliklerine dayanır. Bu yöntemler, gri düzey birlikte oluşum matrisi (GDBOM), yerel ikili model (YİM) ve Gabor filtrelerini içerir. GDBOM, bir görüntünün bir mahallesindeki gri seviyelerin birlikte oluşumunu hesaplar, YİM, her pikseli komşularıyla karşılaştırarak görüntünün yerel modellerini yakalar. Gabor filtreleri ise görüntüyü frekans ve yön bileşenlerine ayırır ve her bileşenden doku özelliklerini çıkarır.

Bölge tabanlı bölütleme teknikleri, bir görüntüyü, bölgedeki dokunun homojenliğine bağlı olarak örtüşmeyen bölgelere ayırır. Bu yöntemler, eşikleme, bölge büyütme ve grafik-kesme tabanlı yöntemleri içerir. Eşikleme teknikleri, görüntünün tamamına veya görüntünün bir alt kümesine tek bir eşik atarken, bölge büyütme teknikleri bir tohum noktasıyla başlar ve benzer doku özelliklerine sahip komşu pikselleri ekleyerek bölgeyi genişletir.

Kenar tabanlı bölütleme teknikleri, farklı doku özelliklerine sahip bölgeler arasındaki kenarları veya sınırları algılar. Bu yöntemler arasında Canny kenar dedektörü, Sobel operatörü ve Laplacian of Gaussian (LoG) filtresi bulunur. Canny

kenar dedektörü, kenarları yüksek doğrulukla tespit etmek için bir dizi filtre ve eşikleme işlemi kullanırken, Sobel operatörü kenarları belirlemek için görüntünün gradyan büyüklüğünü hesaplar. LoG filtresi, görüntünün ikinci türevindeki sıfır geçişleri bularak kenarları tespit eder.

Doku segmentasyonu, farklı görüntülerde bulunan dokuların değişkenliği nedeniyle zorlu bir iştir. Bununla birlikte, güçlü bilgi işlem kaynaklarının ve gelişmiş makine öğrenimi algoritmalarının mevcudiyeti ile doku segmentasyonu, çeşitli alanlarda çok sayıda uygulama ile umut verici bir araştırma alanı haline geldi.

3.9 Doku sınıflandırması

Doku sınıflandırması, medikal görüntüleme gibi uygulamalarda kullanılan bir tekniktir ve bir görüntüdeki dokuları farklı sınıflara ayırmayı amaçlar. Bu teknik, dokuların farklı anatomik bölgeleri veya patolojik durumları arasındaki farklılıkları belirleyerek tanı ve tedavi süreçlerinde yardımcı olabilir.

Doku sınıflandırması, özellikle büyük veri setleri içeren ve el ile sınıflandırmanın zaman alıcı veya zor olduğu durumlarda yararlıdır. Bu nedenle, makine öğrenimi teknikleri sıklıkla kullanılır.

Doku sınıflandırması genellikle üç adımda gerçekleştirilir: öznitelik çıkarımı, öznitelik seçimi ve sınıflandırma. Öznitelik çıkarımı, görüntüdeki dokuların karakteristik özelliklerini tanımlayan sayısal özelliklerin (özniteliklerin) çıkarılmasıdır. Bu özellikler, doku yoğunluğu, dokunun büyüklüğü, doku şekli, dokunun homojenliği veya heterojenliği gibi faktörlere dayanabilir.

Öznitelik seçimi, gereksiz veya tekrarlayan öznitelikleri kaldırarak özniteliklerin boyutunu azaltır ve sınıflandırma performansını artırır. Bu adım, enformasyon kazancı, özellik seçimi, özellik önem sıralaması gibi yöntemler kullanılarak gerçekleştirilebilir.

Sınıflandırma, özniteliklerin çıkarılması ve seçilmesinden sonra, belirlenen özelliklere göre görüntüdeki dokuları farklı sınıflara ayırmaktır. Sınıflandırma için kullanılabilecek birçok yöntem vardır, ancak yaygın olarak kullanılanlar arasında karar ağaçları, destek vektör makineleri ve yapay sinir ağları yer alır.

Doku sınıflandırması, özellikle tıbbi görüntüleme gibi uygulamalarda, diğer uygulamalara kıyasla benzersiz zorluklar sunar. Bu zorluklar arasında dokular arasındaki benzerlik, gürültü, yüzey örtüşmesi ve kısmi hacim etkileri sayılabilir. Ancak, doğru özelliklerin seçilmesi ve uygun sınıflandırma yöntemlerinin kullanılmasıyla, doku sınıflandırması, hastalık tanısında ve tedavisinde önemli bir araç olabilir.

3.10 Tıbbi Görüntülemede Doku Sentezleme

Tıbbi görüntülemede doku sentezi, farklı görüntüleme modalitelerinden (örneğin manyetik rezonans görüntüleme veya bilgisayarlı tomografi) elde edilen görüntülerden, tek bir sentez görüntüsü oluşturmak için kullanılan bir tekniktir. Bu sentez görüntüsü, farklı modalitelerin avantajlarını birleştirerek daha iyi bir görüntüleme sonucu sağlayabilir.

Dokunun sentezi, farklı görüntüleme modalitelerinin sağladığı bilgileri bir araya getirerek daha ayrıntılı ve kapsamlı bir görüntü sağlar. Örneğin, bir MRG görüntüsü yüksek çözünürlüğe ve yumuşak dokuların ayrıntılı görüntülenmesine olanak tanırken, bir BT görüntüsü kemik dokuların görüntülenmesinde daha iyi performans gösterir. Bu nedenle, birleştirilen görüntü, hem yumuşak dokuları hem de kemikleri ayrıntılı bir şekilde gösterebilir.

Doku tabanlı sentez, görüntü kaydı adı verilen bir işlemle gerçekleştirilir. Bu işlemde, farklı modalitelerden elde edilen görüntüler, kayıt işlemiyle birbirleriyle hizalanır ve ardından sentez görüntüsü oluşturmak için birleştirilir.

Doku sentezi, klinik uygulamalarda yaygın bir şekilde kullanılır. Örneğin, MRG ve BT görüntülemeleri kullanarak beyin tümörleri gibi bazı hastalıkların teşhis ve tedavisi için kullanılır ve tıbbi görüntüleme alanındaki teknolojik gelişmelerle birlikte, görüntüleme teknolojilerinin daha etkili bir şekilde kullanılmasını sağlayarak hastalık tanısında ve tedavisinde yardımcı olabilir.

Doku sentezleme, derin öğrenmede önemli bir rol oynar. Derin öğrenme, büyük veri kümelerindeki desenleri tespit ederek, tıbbi görüntüleme alanında teşhis ve tedavi için kullanılan görüntülerdeki anlamlı bilgileri çıkarmak için kullanılır. Ancak,

derin öğrenme modellerinin eğitimi, yeterli miktarda eğitim verisi olmadan zorlu olabilir.

Dokunun sentezlenmesi, farklı görüntüleme modalitelerinden elde edilen verileri bir araya getirerek, derin öğrenme modellerinin daha iyi bir şekilde eğitilmesini sağlayabilir. Örneğin, bir manyetik rezonans görüntüsü, yüksek çözünürlüğe ve yumuşak dokuların ayrıntılı görüntülenmesine olanak tanırken, bir bilgisayarlı tomografi görüntüsü sert dokuların görüntülenmesinde daha iyi performans gösterir. Ancak, MR görüntüsü ve BT görüntüsü farklı özelliklere sahiptir ve derin öğrenme modelinin hem kemik hem de yumuşak dokuları doğru bir şekilde sınıflandırmasını zorlaştırabilir.

Bu sorunu çözmek için, doku sentezi kullanılarak farklı modalitelerden elde edilen görüntüler bir araya getirilir ve tek bir sentez görüntüsü oluşturulur. Bu sentez görüntüsü, derin öğrenme modelinin daha iyi bir şekilde eğitilmesine yardımcı olur, çünkü görüntülerin özelliklerini daha iyi bir şekilde temsil edebilir.

Doku sentezlemek, tıbbi görüntüleme alanında derin öğrenme modellerinin daha doğru ve güvenilir hale gelmesini sağlayarak hastalık teşhisinde ve tedavisinde daha iyi sonuçlar elde edilmesine yardımcı olabilir.

3.11 Havza Algoritması

Havza algoritması (HA), dijital görüntü işlemede kullanılan iyi bilinen bir görüntü bölütleme algoritmasıdır. Benzer yoğunluk değerlerine sahip bir görüntüdeki örtüşen nesneleri ayırmak için kullanılır. Algoritma, görüntüyü, yüksek yoğunluk değerlerinin yüksek yüksekliklere ve düşük yoğunluk değerlerinin düşük yüksekliklere karşılık geldiği bir topografik harita olarak ele alarak çalışır. Algoritma daha sonra haritayı yerel minimumdan başlayarak "sular" ve su seviyesi yükseldikçe farklı havzaları ayırır.

HA, görüntü bölütleme için güçlü bir araçtır ve tıbbi görüntüleme, jeoloji ve uzaktan algılama gibi çeşitli alanlarda yaygın olarak kullanılmaktadır. Bununla birlikte, birçok küçük bölgeye yol açabilen aşırı segmentasyon ve yanlış segmentasyona yol açabilen gürültüye duyarlılık gibi bazı sınırlamaları vardır. Bu


sınırlamaların üstesinden gelmek için, literatürde HA çeşitli modifikasyonlar ve iyileştirmeler önerilmiştir (Ercan ve Kalkan, 2020:159).

Genel olarak, bu algoritma, görüntü bölümleme için yararlı bir araçtır ve uygun şekilde kullanıldığında doğru ve sağlam bölümleme sonuçları sağlayabilir.

Havza algoritmasının birkaç çeşidi vardır. Bu algoritma, görüntüdeki nesnelerin konumu hakkında ön bilgi olduğunda özellikle yararlıdır. Başka bir varyant, önce görüntünün mesafe dönüşümünü hesaplayan ve ardından Havza algoritmasını elde edilen mesafe haritasına uygulayan Mesafe Dönüşümü Havzası algoritmasıdır (Ersin ve Karaman, 2017:967). Bu değişken, görüntüdeki nesnelerin şeklini ve boyutunu dikkate aldığı için aşırı bölümleme sorununun üstesinden gelmeye yardımcı olabilir.

Havza algoritması, tümör segmentasyonu ve kan damarı tespiti gibi görevler için kullanıldığı manyetik rezonans görüntüleme ve bilgisayarlı tomografi taramaları gibi tıbbi görüntüler de dahil olmak üzere birçok farklı görüntü türüne uygulanmıştır. Ayrıca arazi örtüsü sınıflandırması için uydu görüntülerini bölümlere ayırmak için uzaktan algılamada ve faylar ve kıvrımlar gibi jeolojik özellikleri belirlemek için jeolojide kullanılmıştır.

Havza algoritması, doğru ve sağlam segmentasyon sonuçları sağlayabilen güçlü bir görüntü segmentasyonu aracıdır. Ancak performansı gürültü, görüntü çözünürlüğü ve parametre seçimi gibi çeşitli faktörlerden etkilenebilir. Herhangi bir görüntü bölümleme algoritmasında olduğu gibi, uygun algoritmayı dikkatlice seçmek ve parametrelerini analiz edilen görüntünün belirli özelliklerine göre ayarlamak önemlidir.



Şekil 3.3 Böbrek ve Kist Bölütlemesi

Şekil 3-1'deki örnek karın görüntüsünde sadece böbreklere odaklanılarak yapılan bölütleme Şekil 3-3'de gösterilmiştir.

4 MAKİNE ÖĞRENMESİ

4.1 Makine Öğrenmesi

Makine öğrenimi, verilerden öğrenebilen ve açıkça programlanmadan tahminler veya kararlar verebilen algoritmalar ve modeller geliştirmeye odaklanan bir yapay zeka alanıdır. Başka bir deyişle, makine öğrenimi, bilgisayarlara verilerdeki kalıpları tanımayı ve bu kalıpları tahminlerde bulunmak veya harekete geçmek için kullanmayı öğretmenin bir yoludur.

Makine öğrenimi süreci genellikle birkaç temel adımı içerir:

Veri toplama: Makine öğrenimindeki ilk adım, eldeki sorunu veya görevi temsil eden bir veri kümesi toplamaktır. Bu veri kümesi, tablolar veya elektronik tablolar gibi yapılandırılmış verilerden veya metin veya resimler gibi yapılandırılmamış verilerden oluşabilir.

Veri ön işleme: Veri seti toplandıktan sonra, herhangi bir gürültüyü veya alakasız bilgiyi ortadan kaldırmak ve verileri makine öğrenimi algoritmaları tarafından kullanılabilir bir formata dönüştürmek için ön işleme tabi tutulmalıdır.

Model seçimi: Bir sonraki adım, eldeki görev için uygun bir makine öğrenimi algoritması veya modeli seçmektir. Bu, denetimli öğrenme, denetimsiz öğrenme veya pekiştirmeli öğrenme gibi farklı algoritma türleri arasında seçim yapmayı ve seçilen algoritma için belirli parametreleri veya ayarları seçmeyi içerebilir.

Model eğitimi: Model seçildikten sonra, önceden işlenmiş veri kümesi üzerinde eğitilmelidir. Bu, algoritmayı girdi verileri ve ilişkili çıktı veya hedef değişkenlerle beslemeyi ve modelin tahminleri ile gerçek çıktılar arasındaki farkı en aza indirecek şekilde yinelemeli olarak ayarlamayı içerir.

Model değerlendirmesi: Model eğitildikten sonra, performansını ve genelleme yeteneğini değerlendirmek için ayrı bir veri kümesi üzerinde değerlendirilmelidir. Bu, verilerin eğitim, doğrulama ve test kümelerine bölünmesini ve doğruluk, kesinlik, geri çağırma veya F1 puanı gibi ölçütlerin ölçülmesini içerebilir.

Model dağıtımı: Son olarak, eğitilen model, yeni, görünmeyen verilere dayalı tahminler veya kararlar almak için gerçek dünya ortamında dağıtılabılır.

Makine öğreniminin finans, sağlık, doğal dil işleme, bilgisayarla görme ve diğer pek çok alanda çok sayıda uygulaması vardır. Eylem halindeki makine öğreniminin bazı yaygın örnekleri arasında konuşma tanıma, görüntü sınıflandırma, kestirimci bakım, dolandırıcılık algılama ve öneri sistemleri yer alır.

Genel olarak, makine öğrenimi, nasıl çalıştığımız ve iletişim kurduğumuzdan nasıl karar verdiğimiz ve sorunları nasıl çözdüğümüze kadar hayatımızın birçok yönünü dönüştürme potansiyeline sahip, güçlü ve hızla büyüyen bir alandır.

4.2 Makine Öğrenmesi Türleri

Makine öğrenimi, verilerden öğrenebilen ve açıkça programlanmadan tahminler veya kararlar verebilen algoritmalar ve modeller geliştirmeye odaklanan bir yapay zeka dalıdır. Başka bir deyişle, makine öğrenimi, bilgisayarlara verilerdeki kalıpları tanımayı ve bu kalıpları tahminlerde bulunmak veya harekete geçmek için kullanmayı öğretmenin bir yoludur.

4.2.1 Denetimli Öğrenme

Denetimli öğrenme, algoritmanın, her veri noktasının bilinen bir çıktı veya hedef değişkenle ilişkilendirildiği etiketli bir veri kümesi üzerinde eğitildiği bir makine öğrenimi türüdür (Kelleher ve Tierney, 2018). Algoritmanın amacı, girdileri çıktılarına eşleyebilen bir işlevi öğrenmek ve bu işlevi yeni, görünmeyen veriler üzerinde tahminler yapmak için kullanmaktır.

Denetimli öğrenme süreci genellikle aşağıdaki adımları içerir:

Veri toplama: Denetimli öğrenmede ilk adım, eldeki sorunu veya görevi temsil eden bir veri kümesi toplamaktır. Bu veri kümesi, tahmin yapmak için kullanılan değişkenler veya özellikler olan girdi verilerini ve algoritmanın tahmin etmeye çalıştığı değerler olan ilişkili çıktı veya hedef değişkenleri içermelidir.

Veri ön işleme: Veri seti toplandıktan sonra, herhangi bir gürültüyü veya alakasız bilgiyi ortadan kaldırmak ve verileri makine öğrenimi algoritmaları tarafından

kullanılabilecek bir formata dönüştürmek için ön işleme tabi tutulmalıdır. Bu, normalleştirme, özellik ölçeklendirme veya boyutluluk azaltma gibi adımları içerebilir.

Model seçimi: Bir sonraki adım, eldeki görev için uygun bir makine öğrenimi algoritması veya modeli seçmektir. Bu, doğrusal regresyon, lojistik regresyon, karar ağaçları veya sinir ağları gibi farklı algoritma türleri arasında seçim yapmayı ve seçilen algoritma için belirli parametreleri veya ayarları seçmeyi içerebilir.

Model eğitimi: Model seçildikten sonra, önceden işlenmiş veri kümesi üzerinde eğitilmelidir. Bu, algoritmayı girdi verileri ve ilişkili çıktı veya hedef değişkenlerle beslemeyi ve modelin tahminleri ile gerçek çıktılar arasındaki farkı en aza indirecek şekilde yinelemeli olarak ayarlamayı içerir.

Model değerlendirmesi: Model eğitildikten sonra, performansını ve genelleme yeteneğini değerlendirmek için ayrı bir veri kümesi üzerinde değerlendirilmelidir. Bu, verilerin eğitim, doğrulama ve test kümelerine bölünmesini ve doğruluk, kesinlik, geri çağırma veya F1 puanı gibi ölçütlerin ölçülmesini içerebilir.

Model dağıtımı: Son olarak, eğitilen model, yeni, görünmeyen verilere dayalı tahminler veya kararlar almak için gerçek dünya ortamında dağıtılabilir.

Denetimli öğrenmenin finans, sağlık, doğal dil işleme, bilgisayar görüşü ve diğer pek çok alanda çok sayıda uygulaması vardır. Uygulamalı denetimli öğrenmenin bazı yaygın örnekleri arasında müşteri kaybının tahmin edilmesi, hastalıkların tıbbi görüntülerden teşhis edilmesi ve spam e-postaların sınıflandırılması yer alır.

Genel olarak, denetimli öğrenme, makine öğreniminde güçlü ve yaygın olarak kullanılan bir tekniktir ve özellikle girdi ve çıktı değişkenleri arasında açık bir ilişki olduğunda ve algoritmayı eğitmek için etiketli bir veri kümesi mevcut olduğunda yararlıdır.

4.2.2 Denetimsiz Öğrenme

Denetimsiz öğrenme, algoritmanın hiçbir çıktı veya hedef değişkenin sağlanmadığı, etiketlenmemiş bir veri kümesi üzerinde eğitildiği bir makine öğrenimi türüdür. Bunun yerine, algoritma verilerdeki kalıpları, yapıları veya ilişkileri kendi başına bulmalı ve bunları tahminlerde bulunmak veya başka görevleri gerçekleştirmek için kullanmalıdır (Bishop, 2006)

Bu öğrenme süreci genellikle aşağıdaki adımları içerir:

Veri toplama: Denetimsiz öğrenmede ilk adım, eldeki sorunu veya görevi temsil eden etiketlenmemiş bir veri kümesi toplamaktır. Bu veri kümesi, verilerdeki kalıpları veya yapıları bulmak için kullanılan değişkenler veya özellikler olan girdi verilerini içermelidir.

Veri ön işleme: Veri seti toplandıktan sonra, herhangi bir gürültüyü veya alakasız bilgiyi ortadan kaldırmak ve verileri makine öğrenimi algoritmaları tarafından kullanılabilir bir formata dönüştürmek için ön işleme tabi tutulmalıdır. Bu, normalleştirme, özellik ölçeklendirme veya boyutluluk azaltma gibi adımları içerebilir.

Model seçimi: Bir sonraki adım, eldeki görev için uygun bir makine öğrenimi algoritması veya modeli seçmektir. Bu, kümeleme, boyutluluk azaltma veya anormallik tespiti gibi farklı algoritma türleri arasında seçim yapmayı ve seçilen algoritma için belirli parametreleri veya ayarları seçmeyi içerebilir.

Model eğitimi: Model seçildikten sonra, önceden işlenmiş veri kümesi üzerinde eğitilmelidir. Bu, algoritmayı girdi verileriyle beslemeyi ve verilerdeki kalıpları, yapıları veya ilişkileri bulmasına izin vermeyi içerir.

Model değerlendirmesi: Model eğitildikten sonra, performansını ve genelleme yeteneğini değerlendirmek için ayrı bir veri kümesi üzerinde değerlendirilmelidir. Bu, siluet puanı, dirsek yöntemi veya yeniden oluşturma hatası gibi ölçüm ölçümlerini içerebilir.

Model dağıtımı: Son olarak, eğitilen model, kümeleme, anormallik algılama veya veri sıkıştırma gibi görevleri gerçekleştirmek için gerçek dünya ortamında dağıtılabılır.

Denetimsiz öğrenmenin finans, sağlık, doğal dil işleme, bilgisayarla görme ve diğer pek çok alanda çok sayıda uygulaması vardır. Denetimsiz öğrenmenin bazı yaygın örnekleri arasında benzer belgelerin gruplandırılması, finansal işlemlerde dolandırıcılık modellerinin belirlenmesi ve büyük miktarda verinin sıkıştırılması yer alır.

Genel olarak, denetimsiz öğrenme, makine öğreniminde güçlü ve kullanışlı bir tekniktir ve özellikle etiketli veri olmadığında veya amaç verilerdeki gizli kalıpları veya yapıları keşfetmek olduğunda kullanışlıdır.

4.2.3 Takviyeli Öğrenme

Takviyeli öğrenme, bir aracının bir ortamla etkileşime girerek ve eylemlerine göre ödüller veya cezalar alarak karar vermeyi öğrendiği bir makine öğrenimi türüdür. Temsilcinin amacı, uzun vadeli kümülatif ödülünü en üst düzeye çıkaran, durumlardan eylemlere doğru bir haritalama olan bir politika öğrenmektir (Kaelbling ve diğerleri, 1996:237).

Takviyeli öğrenme süreci tipik olarak aşağıdaki adımları içerir:

Çevre: Takviyeli öğrenmede ilk adım, ajanın etkileşime gireceği bir ortam tanımlamaktır. Bu ortam bir oyun, simülasyon, gerçek dünya sistemi veya Markov Karar Süreci (MDP) olarak modellenebilecek herhangi bir sistem olabilir.

Durum alanı: Ortam tanımlandıktan sonra, durum alanı belirtilmelidir. Durum uzayı, ortama ve kendi eylemlerine bağlı olarak, aracının içinde olabileceği tüm olası durumların bir kümesidir.

Eylem alanı: Eylem alanı, aracının ortamın her durumunda gerçekleştirebileceği tüm olası eylemlerin bir kümesidir.

Ödül işlevi: Ödül işlevi, aracının eylemleri için aldığı ödülleri veya cezaları belirtir. Temsilcinin amacı, uzun vadeli kümülatif ödülünü en üst düzeye çıkarmaktır,

bu nedenle ödöl işlevi, aracıyı daha yüksek ödüllere yol açan eylemlerde bulunmaya teşvik edecek şekilde tasarlanmalıdır.

Hareket tarzı: Hareket tarzı, aracının deneme yanılma yoluyla öğrendiği durumlardan eylemlere eşlenmesidir. Temsilcinin amacı, uzun vadeli kümülatif ödölünü maksimize eden bir hareket tarzı bulmaktır.

Değer işlevi: Değer işlevi, belirli bir politikayı izlemenin beklenen kümülatif ödölünü tahmin eden bir işlevdir. Değer işlevi, farklı politikaları değerlendirmek ve karşılaştırmak için kullanılır.

Keşfetmeye karşı sömürü: Takviyeli öğrenmede, aracı, keşif (daha iyi politikalar keşfetmek için yeni eylemler denemek) ve sömürü (ödölü en üst düzeye çıkarmak için mevcut politikayı kullanmak) arasında denge kurmalıdır. Bu, epsilon-greedy, softmax veya üst güven sınırı gibi çeşitli keşif stratejileri aracılığıyla elde edilebilir.

Model tabanlı ve modelsiz: Takviyeli öğrenmede, aracı, eylemlerinin sonucunu tahmin etmek için bir çevre modeli kullanabilir veya model olmadan doğrudan deneyimden öğrenebilir. Model tabanlı yöntemler, örnekleme açısından daha verimli olabilir, ancak doğru modeller gerektirirken, modelden bağımsız yöntemler daha sağlamdır ancak daha fazla örnek gerektirebilir.

Takviyeli öğrenmenin robotik, oyun, kontrol sistemleri ve diğer pek çok alanda çok sayıda uygulaması vardır. Takviyeli öğrenmenin bazı yaygın örnekleri arasında satranç gibi oyunlar oynamak, bir robotik kolu kontrol etmek ve bir binada enerji tüketimini optimize etmek yer alır.

Genel olarak, takviyeli öğrenme, makine öğreniminde güçlü ve esnek bir tekniktir ve hedef, dinamik ve belirsiz bir ortamda en uygun karar verme tarzını öğrenmek olduğunda özellikle yararlıdır.

4.3 Yapay Sinir Ağı

Yapay sinir ağı (YSA), insan beyninin yapısından ve işleyişinden ilham alan bir hesaplama modelidir. Katmanlar halinde düzenlenmiş birbirine bağlı bir dizi düğümden veya "nöronlardan" oluşur.

Bir YSA'nın temel yapı taşı, diğer nöronlardan veya harici kaynaklardan giriş sinyallerini alan ve ağırlık adı verilen bir dizi dahili parametreye dayalı olarak bir çıkış sinyali hesaplayan bir nörondur. Ağırlıklar, nöronlar arasındaki bağlantıların gücünü temsil eder ve öğrenme sürecinde ağı performansını optimize etmek için ayarlanır (LeCun, 2015:436).

Bir YSA tipik olarak, her bir katman bilgiyi farklı bir şekilde işleyen çok sayıda nöron katmanından oluşur. Girdi katmanı ham verileri alır ve veriler üzerinde dönüşümler gerçekleştiren bir veya daha fazla gizli katmana ve son olarak da ağı son çıktısını üreten çıktı katmanına iletir.

Bir YSA'yı eğitmek, onu eğitim örnekleri olarak adlandırılan bir dizi girdi-çıkış çifti ile sunmayı ve her örnek için ağı son çıktısı ile istenen çıktı arasındaki farkı en aza indirmek için nöronlar arasındaki bağlantıların ağırlıklarını ayarlamayı içerir. Bu işlem genellikle, ağ hatasının ağırlıklara göre gradyanını hesaplayan ve bunları güncellemek için kullanan geri yayılım adı verilen bir teknik kullanılarak yapılır.

Eğitildikten sonra, yeni girdi verilerine dayalı olarak tahminler yapmak veya kararlar almak için bir YSA kullanılabilir. YSA'lar, görüntü ve konuşma tanıma, doğal dil işleme ve kontrol sistemleri dahil olmak üzere çok çeşitli görevlere başarıyla uygulanmıştır.

Bir YSA'nın performansı, katmanların sayısı ve boyutu, nöronlar tarafından kullanılan aktivasyon fonksiyonu, eğitim için kullanılan öğrenme algoritması ve eğitim veri setinin boyutu ve kalitesi gibi çeşitli faktörlere bağlıdır (Özgüven ve Çakır, 2019:83).


Bir nöronun aktivasyon fonksiyonu, girişlerine ve ağırlıklarına göre çıkış sinyalini nasıl hesaplayacağını belirler. Yaygın aktivasyon fonksiyonları, düzgün, S-şekilli bir eğri oluşturan sigmoid fonksiyonunu ve pozitif girişler için doğrusal bir çıkış

ve negatif girişler için sıfır üreten doğrultulmuş doğrusal birim (ReLU) fonksiyonunu içerir (Öztürk ve diğerleri, 2021:5665).

YSA'lar, her eğitim örneğinden sonra ağırlıkları güncelleyen stokastik gradyan iniş ve bir grup örneği işledikten sonra ağırlıkları güncelleyen toplu gradyan iniş dahil olmak üzere çeşitli öğrenme algoritmaları kullanılarak eğitilebilir. Ağın performansını ve kararlılığını iyileştirmek için momentum, öğrenme oranı düşüşü ve düzenleme gibi diğer teknikler de kullanılabilir.

Derin öğrenme, derin sinir ağları (DSA) olarak bilinen birçok katmana sahip YSA'lara odaklanan makine öğreniminin bir alt alanıdır. DSA'lar, görüntü ve konuşma tanıma, doğal dili anlama ve oyun oynama gibi birçok karmaşık görevde çok iyi performans elde etti.

Özetle yapay sinir ağları, girdiler ve çıktılar arasındaki karmaşık ilişkileri modellemek için güçlü bir araçtır. İnsan beyninin yapısından ve işleyişinden ilham alırlar ve çok çeşitli görevlerde performanslarını optimize etmek için çeşitli teknikler kullanılarak eğitilebilirler.



Şekil 4.1 Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollove diğerleri,2013)

4.4 Derin Öğrenme

Derin öğrenme, derin sinir ağları olarak bilinen birçok katmana sahip yapay sinir ağlarını eğitmeye odaklanan makine öğreniminin bir alt alanıdır. Derin öğrenme algoritmaları, hiyerarşik ve karmaşık olan verilerin temsillerini öğrenme yeteneğine sahiptir, bu da onları özellikle görüntü ve konuşma tanıma, doğal dil işleme ve oyun oynama gibi görevler için etkili kılar.

Derin öğrenmenin arkasındaki ana fikir, girdi verilerinin giderek daha karmaşık ve soyut temsillerini öğrenmek için birçok katmana sahip YSA'ları kullanmaktır. Ağın her katmanı, girdiyi doğrusal olmayan bir şekilde dönüştürür ve bir katmanın çıktısı, bir sonrakinin girdisi olarak hizmet eder. Ağın alt katmanları, kenarlar veya köşeler gibi basit özellikleri tanımayı öğrenirken, üst katmanlar şekiller veya desenler gibi daha karmaşık özellikleri tanımayı öğrenir. Ağ, öğrenilen bu özellikleri birleştirerek, yeni girdi verilerine dayalı olarak doğru tahminler veya kararlar verebilir (LeCun ve diğerleri, 2015:436).

Derin öğrenmenin ana zorluklarından biri, ağın verilerin doğru temsillerini öğrenmesi için eğitilmesidir. Bu, her eğitim örneği için ağın çıktısı ile istenen çıktı arasındaki farkı en aza indirmek için eğitim süreci sırasında nöronlar arasındaki bağlantıların ağırlıklarının ayarlanmasını içerir. Bu genellikle, ağ hatasının ağırlıklara göre gradyanını hesaplayan ve bunları güncellemek için kullanan, geri yayımlı stokastik gradyan iniş gibi bir optimizasyon algoritması kullanılarak yapılır.

Diğer bir zorluk ise, ağ çok karmaşık hale geldiğinde ve genelleştirilebilir özellikleri öğrenmek yerine eğitim verilerini ezberlemeye başladığında ortaya çıkan aşırı uyumdur. Aşırı uyumu önlemek için, bırakma, ağırlık azaltma veya erken durdurma gibi çeşitli düzenleme teknikleri kullanılabilir (Srivastava ve diğerleri, 2014:1929, Zhang ve diğerleri, 2019:5666).

Derin öğrenme, nesne tanıma, konuşma tanıma, makine çevirisi ve oyun oynama gibi birçok karmaşık görevde en son teknolojiye sahip performans elde etti. En popüler derin öğrenme mimarilerinden bazıları, görüntü tanıma için evrişimli sinir ağlarını, dizi modelleme için özyinelemeli sinir ağlarını (ÖSA) ve doğal dil işleme için dönüştürücüleri içerir.

Derin öğrenme, girdi verilerinin giderek daha karmaşık ve soyut temsillerini öğrenmek için birçok katmana sahip derin sinir ağlarını kullanan makine öğreniminin güçlü bir alt alanıdır. Derin öğrenme algoritmaları, öğrenilen bu özellikleri birleştirerek, yeni girdi verilerine dayalı olarak doğru tahminler veya kararlar verebilir ve birçok karmaşık görevde son teknoloji performans elde etmiştir.

4.4.1 Derin Öğrenmenin Yapısı

Bir yapay sinir ağının yapısı, beyindeki biyolojik nöronların organizasyonuna dayanır. YSA'lar, katmanlar halinde düzenlenmiş düğümlerden veya "nöronlardan" oluşur. Bir YSA'nın temel yapı taşı, diğer nöronlardan veya harici kaynaklardan giriş sinyallerini alan ve ağırlık adı verilen bir dizi dahili parametreye dayalı olarak bir çıkış sinyali hesaplayan bir nörondur.


Bir YSA'nın tipik yapısı, bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşur. Girdi katmanı, ham verileri alır ve girdi üzerinde doğrusal olmayan bir dönüşüm gerçekleştiren ilk gizli katmana iletir. Birinci gizli katmanın çıktısı, bir sonraki gizli katmana girdi görevi görür ve son gizli katman ağın çıktısını üretene kadar bu böyle devam eder. Çıkış katmanı, son gizli katmanın çıktısına dayalı olarak ağın nihai çıktısını üretir (Zeng ve Yu, 2018, Zhang ve LeCun, 2015).

Gizli katmanların sayısı ve boyutu, görevin karmaşıklığına ve mevcut veri miktarına bağlı olarak değişebilir. Genel olarak, daha fazla gizli katmana sahip YSA'lar, girdi verilerinin daha karmaşık temsillerini öğrenme yeteneğine sahiptir, ancak eğitilmesi daha zor olabilir.

Nöronlar arasındaki bağlantıların ağırlıkları tipik olarak rastgele başlatılır ve ağın performansını optimize etmek için eğitim sürecinde ayarlanır. Bu, ağın eğitim örnekleri olarak adlandırılan bir dizi girdi-çıkış çifti ile sunulmasını ve her örnek için ağın çıktısı ile istenen çıktı arasındaki farkı en aza indirmek için ağırlıkların ayarlanmasını içerir. Bu işlem genellikle, ağ hatasının ağırlıklara göre gradyanını hesaplayan ve bunları güncellemek için kullanan geri yayılım adı verilen bir teknik kullanılarak yapılır (LeCun ve diğerleri, 2015:436, Goodfellow ve diğerleri, 2016, Bishop, 2015, Schmidhuber, 2015:85, Rumelhart ve diğerleri, 1986:533).

Bir nöronun aktivasyon fonksiyonu, girişlerine ve ağırlıklarına göre çıkış sinyalini nasıl hesaplayacağını belirler. Yaygın aktivasyon fonksiyonları, düzgün, S-şekilli bir eğri oluşturan sigmoid fonksiyonunu ve pozitif girişler için doğrusal bir çıkış ve negatif girişler için sıfır üreten doğrultulmuş doğrusal birim (ReLU) fonksiyonunu içerir.

Özetle, bir yapay sinir ağının yapısı, katmanlar halinde düzenlenmiş birbirine bağlı düğümlerden veya nöronlardan oluşur. Ağ tipik olarak bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı içerir. Nöronlar arasındaki bağlantıların ağırlıkları, ağın performansını optimize etmek için eğitim sürecinde ayarlanır ve bir nöronun aktivasyon işlevi, girdilerine ve ağırlıklarına dayalı olarak çıkış sinyalini nasıl hesaplayacağını belirler.



Şekil 4.2 Ağ Mimarisi (Efendigil ve Kahraman, 2009:6697)

4.4.1.1 Sapma (Bias)

Yapay sinir ağlarında (YSA) yanlılık, nöronlar arasındaki bağlantıların ağırlıklarına ek olarak her bir nöronla ilişkilendirilen ek bir parametredir. Yanlılık terimi, girdi olmadığında bile nöronun ateşleme veya bir sinyal verme eğilimini temsil eder.

Matematiksel olarak bias terimi, nöronun ateşlenip ateşlenmeyeceğini belirleyen bir eşik değeri olarak düşünülebilir. Önyargılı bir nöronun çıktısı şu şekilde hesaplanabilir:

$$\text{çıkıtı} = \text{aktivasyon_fonksiyonu}(\text{ağırlıklı_toplam} + \text{yanlılık})$$

Burada, ağırlıklı toplam, girdilerin çarpımlarının ve bunlara karşılık gelen ağırlıkların toplamını temsil eder ve aktivasyon fonksiyonu, ağırlıklı toplam ve yanlılığa dayalı olarak nöronun çıktısını belirler.

Önyargı terimi YSA'larda önemlidir, çünkü ağırlık karmaşık işlemlere daha iyi uymasına ve sıfır etrafında ortalanmayan verilerden öğrenmesine olanak tanır. Önyargı olmadan, ağırlık yalnızca orijinden geçen işlevleri öğrenebilir.

Eğitim sürecinde, belirli bir görevde ağırlık performansını optimize etmek için önyargı terimi, nöronlar arasındaki bağlantıların ağırlıklarıyla birlikte ayarlanır. Sapma terimi tipik olarak rastgele başlatılır ve önyargı terimini ağırlık eğitim verilerindeki hatasını azaltan yönde ayarlayan stokastik gradyan iniş gibi bir optimizasyon algoritması kullanılarak güncellenir.

Yanlılık, bir YSA'daki her bir nöronla ilişkilendirilen ve girdi yokluğunda nöronun ateşleme eğilimini temsil eden ek bir parametredir. Ağırlık karmaşık işlemlere daha iyi uymasına ve sıfır etrafında ortalanmayan verilerden öğrenmesini sağlar ve eğitim sürecinde ağırlıklarla birlikte ayarlanır.

4.4.1.2 Aktivasyon Fonksiyonu

Yapay sinir ağlarında, aktivasyon fonksiyonları, ağırlık hesaplamalarına doğrusal olmayanlığı getirmek için bireysel nöronların çıktılarına uygulanan matematiksel fonksiyonlardır. Etkinleştirme işlevleri, ağırlık girdiler ve çıktılar arasındaki doğrusal olmayan karmaşık ilişkileri modellemesine izin verdiği için YSA'larda önemlidir.

Aktivasyon fonksiyonları iki türe ayrılabilir: doğrusal ve doğrusal olmayan. Doğrusal aktivasyon işlevleri, girdi ve çıktı arasında doğrusal bir ilişki üretir ve bu da ağırlık karmaşık işlevleri modelleme yeteneğini sınırlar. Öte yandan, doğrusal olmayan

aktivasyon fonksiyonları, ağın hesaplamalarına doğrusal olmama durumu getirerek daha karmaşık ilişkileri modellemesine izin verir.

YSA'larda kullanılan bazı yaygın doğrusal olmayan aktivasyon işlevi türleri şunları içerir:

Sigmoid işlevi: Sigmoid işlevi, herhangi bir gerçek değerli sayıyı 0 ile 1 arasındaki bir değere eşler. Genellikle, amacın pozitif bir sınıfın olasılığını tahmin etmek olduğu bir ikili sınıflandırma probleminin çıktı katmanında bir aktivasyon işlevi olarak kullanılır. .

Düzeltilmiş Doğrusal Birim (ReLU) işlevi: ReLU işlevi, tüm negatif girişleri sıfıra ayarlayan ve pozitif girişleri değiştirmeden bırakan doğrusal olmayan bir aktivasyon işlevidir. Basitliği ve etkinliği nedeniyle YSA'ların gizli katmanlarında sıklıkla aktivasyon fonksiyonu olarak kullanılır.

Hiperbolik tanjant (Tanh) işlevi: Tanh işlevi, herhangi bir gerçek değerli sayıyı -1 ile 1 arasında bir değerle eşler. Genellikle YSA'ların gizli katmanlarında bir aktivasyon işlevi olarak kullanılır ve sigmoid işlevine benzer. şekil.

Softmax fonksiyonu: Softmax fonksiyonu, çok sınıflı sınıflandırma görevleri için kullanılan YSA'ların çıkış katmanında genellikle aktivasyon fonksiyonu olarak kullanılır. Gerçek değerli sayıların bir vektörünü sınıflar üzerindeki bir olasılık dağılımına eşler.

Genel olarak, etkinleştirme işlevinin seçimi, belirli göreve ve ağı yapısına bağlıdır. Doğru aktivasyon işlevinin seçilmesi, eğitim sırasında yakınsama hızını ve ağı yeni verilere genelleme yapma yeteneğini etkileyebileceğinden, ağı performansı için kritik olabilir.

4.5 Evrişimli Sinir Ağları

Evrişimli Sinir Ağları, görüntü sınıflandırma, nesne algılama ve görüntü bölümlendirme görevleri için yaygın olarak kullanılan bir tür yapay sinir ağıdır. ESA'lar, insan beyninin görsel korteksinin organizasyonundan esinlenmiştir ve görüntüleri otomatik olarak öğrenerek ve onlardan özellikler çıkararak işlemek için tasarlanmıştır

(LeCun ve diğeri, 2015:436, Krizhevsky ve diğeri, 2012:1097, Simonyan ve Zisserman, 2015).

Bir ESA, evrişimli katmanlar, havuzlama katmanları ve tamamen bağı katmanlar dahil olmak üzere birkaç katmandan oluşur. Evrişimli katmanlar, girdi görüntüsü üzerinde kıvrılarak kenarlar, köşeler ve dokular gibi önemli özellikleri çıkarmak için bir dizi filtre kullanır. Havuzlama katmanları, önemli özellikleri korurken evrişimli katmanların çıktısının uzamsal boyutlarını azaltır. Son olarak, tamamen bağlantılı katmanlar, girdi görüntüsünü farklı kategorilerde sınıflandırmak için kullanılır.

ESA'lar, birçok görüntü sınıflandırma ve nesne algılama görevinde en son teknolojiye sahip sonuçlar elde etmiştir ve bilgisayarla görme uygulamalarında yaygın olarak kullanılmaktadır.

Görüntü sınıflandırma ve nesne algılamaya ek olarak, ESA'lar doğal dil işleme ve konuşma tanıma gibi diğer görevlere de uygulanmıştır. Başarılı oldular çünkü verilerin hiyerarşik temsillerini öğrenebiliyorlar, yani katmanları aracılığıyla verileri işlerken giderek daha karmaşık ve soyut özellikleri otomatik olarak keşfedebiliyorlar.


Bir ESA'nın eğitim süreci, parametrelere göre kayıp fonksiyonunun gradyanını hesaplayan ve bunları buna göre güncelleyen bir teknik olan geri yayılım yoluyla filtrelerin ve katmanların parametrelerinin öğrenilmesini içerir. Kayıp fonksiyonu, ağı tahmin edilen çıktısı ile gerçek çıktı arasındaki farkı ölçer ve eğitim sürecinin amacı bu farkı en aza indirmektir (Goodfellow ve diğeri, 2016, Zhang ve Wallace, 2017).

Video analizi ve dizi modelleme için kullanılan Özyinelemeli ESA'lar (ÖESA) ve sentetik görüntüler ve videolar oluşturmak için kullanılan üretken çekişmeli ağlar (ÜÇA) gibi ESA'ların birçok varyasyonu ve uzantısı da vardır.

Genel olarak, ESA'lar görüntü ve video verilerini işlemek ve analiz etmek için güçlü bir araçtır ve bilgisayarla görme alanına önemli katkılarda bulunmuştur.

Makine öğrenimi, bir sistemin belirli bir sorunu üzerinde aktarılan verileri kullanarak sonuç üreten yöntemlerin geliştirildiği bilgisayar bilimi alanıdır. Yapay

Sinir Ağları, insan beyninden ilham alınarak geliştirilmiş ve matematiksel ortamda yapay olarak sonuçlar üreten algoritmalar (Cengil ve diğerleri, 2017). Derin öğrenmede, büyük miktarda veriyi sınıflandırmak için çok katmanlı derin sinir ağları kullanılır. Derin öğrenme, makine öğrenimidir ve bilgisayarla görmede çok önemli bir çalışma alanı olmuştur.



Şekil 4.3 Çok Katmanlı Yapay Sinir Ağ Modeli (Karaatlı ve diğerleri, 2012:87)

Evrişimsel sinir ağı algoritmaları derin öğrenme yöntemleridir ve görüntü sınıflandırma, nesne tanıma ve tanıma tespitinde yaygın olarak kullanılmaktadır (Gao ve diğerleri, 2017:103). Kullanılan bu algoritmalar yüksek doğruluk oranı verebilmektedir (Gao ve diğerleri, 2017:49, Ari ve diğerleri, 2016:).

Evrişimli sinir ağlarında veriler doğrudan işlenir ve sonuçlar elde edilir (Acharya ve diğerleri, 2018:270). Evrişimli sinir ağı modelinde evrişimli katman, havuzlama katmanı ve bağlantılı gizli katmanlardan oluşur (Goodfellow ve diğerleri, 2016). Evrişim katmanında öznitelik elde edilirken, havuzlama katmanında öznitelik ve parametre sayısı azaltılır. Böylece hesaplamada tasarruf sağlanmaktadır. Bağlantılı katmanlar ise makine öğrenimindeki katmanlar gibi yapay sinir ağları gibi çalışır. Bu katmanların farklı sayı ve kombinasyonlarına göre Alexnet, UNET, VGG gibi modeller geliştirilmiştir (Krizhevsky ve diğerleri, 2012:105, He ve diğerleri, 2016:770). Bu modelleri parametrelerin girişine uygulanan verilerden öğrenirler. Bu nedenle, derin öğrenme modellerini eğitmek için çok fazla veriye ihtiyaç vardır (Yamashita ve diğerleri, 2018:611).

4.5.1 Evriřim, Havuzlama ve Tamamen Baęlantılı Katman

Evriřim katmanında, sonuçların bir sonraki katmanda kullanılması için girdiye bir filtre matrisi uygulanır. 3x3 ve 5x5 gibi filtre matrisi görüntünün tamamına uygulanır. Dokudaki ayırt edici özellik kaldırılır ve yeni bir görüntü elde edilir. Filtre matris aęırlıkları, evriřimli sinir aęının öğrenme aşamasında belirlenir. Sonuç, bir sonraki katman için girdi olur. Son katman, sonuç görüntüsüdür. Bu katmanda ayırt edici özelliklere dayalı bir görüntü elde edilir.

Evriřimli katman, girdisinde evriřim adı verilen matematiksel bir işlemi gerçekleřtiren evriřimli sinir aęındaki bir katman türüdür. Evriřim işlemi, filtre veya çekirdek adı verilen küçük bir matrisin girdi verileri üzerinde kaydırılmasını ve filtre ile o anda ele alınan girdi verilerinin yerel bölgesi arasında iç çarpımın hesaplanmasını içerir. Bu işlemin çıktısı, girdi verilerinde belirli özelliklerin veya kalıpların varlığını veya yokluęunu temsil eden yeni bir matristir.

Evriřimli katmanlar, bir görüntüdeki nesneleri tanıma veya bir zaman serisindeki belirli kalıpları algılama gibi eldeki görevle ilgili girdi verilerinden özellikler çıkarmak için tasarlanmıştır. Bir ESA, farklı filtrelere ve havuzlama işlemlerine sahip çoklu evriřimli katmanlar uygulayarak, girdi verilerinden giderek daha karmařık ve soyut özellikler öğrenebilir, bu da daha doęru tahminlere ve sınıflandırmalara yol aęar.

Evriřimli katmanları tipik olarak, aęa doęrusal olmama özellięini sokmak ve ifade gücünü artırmak için ReLU gibi aktivasyon fonksiyonları takip eder. ESA'lerde yaygın olarak kullanılan dięer katman türleri, evriřimli katmanların çıktısını altörnekleyen havuzlama katmanlarını ve nihai bir tahmin veya sınıflandırma yapmak için evriřimli katmanların çıktısını kullanan tam baęlantılı katmanları içerir.

Evriřimli katmanlar, aęın performansını iyileřtirmek için eğitim sırasında ayarlanabilen birkaç önemli parametreye sahiptir. Bunlar, filtre sayısını, filtrelerin boyutunu, adımı (yani, filtrenin her adımda hareket ettięi mesafe) ve dolguyu (yani, çıktının istenen boyuta sahip olmasını saęlamak için giriş verilerinin doldurulma şeklini içerir.). Bu parametrelerin ayarlanması, katmandaki her bir nöronun duyarlı olduęu giriş verileri bölgesinin boyutunu belirleyen evriřim katmanının alıcı alanını

etkileyebilir (Xu ve diğerleri, 2020:495, Zhang ve diğerleri, 2018:6848, Sandler ve diğerleri, 2018:4510).

Geleneksel evrişimli katmanlara ek olarak, ESA’larda yaygın olarak kullanılan evrişimli katmanların çeşitli varyantları ve uzantıları da vardır. Örneğin, genişletilmiş evrişimli katmanlar, filtrenin boyutunu büyütmeden daha geniş bir alıcı alana sahip olmasını sağlar ve derinlemesine ayrılabilir evrişimli katmanlar, uzamsal ve kanal bazında evrişimleri ayırarak ağdaki parametre sayısını azaltır.

Genel olarak, evrişimli katmanlar, çeşitli alanlardaki verileri işlemek ve analiz etmek için güçlü bir araçtır ve görüntü sınıflandırma, nesne algılama ve segmentasyon gibi görevler için ESA’ların başarısında önemli bir rol oynamıştır.

Havuzlama katmanında, ağ içindeki parametreler azaltılarak hesaplama yükü dengelenir. İşlem sonucunda görüntünün en boy oranı azalır. Bu işlem pikselleri kaybeder ve sonraki katmanlar için çok az hesaplama yükü oluşturur. Tamamen bağlı katman genellikle evrişimli sinir ağının sonunda bulunur. Sınıflandırmada kullanılır. Sınıf puanları optimize edilmiştir. Burada bulunan gizli katmanların sayısı derin öğrenme mimarilerinde farklılık göstermektedir (Meunier ve Chandy, 2019:376, Umer ve diğerleri, 2021:13).

Havuzlama katmanı, girdi verilerinin küçük bölgelerini özetleyerek önceki evrişimli katmanın çıktısını altörnekleyen bir evrişimli sinir ağındaki bir katman türüdür. Havuzlama katmanının amacı, giriş verileriyle ilgili en önemli bilgileri korurken, evrişim katmanı tarafından üretilen özellik haritalarının boyutsallığını azaltmaktır.

Havuzlama katmanları tipik olarak özellik haritalarının havuzlama pencereleri adı verilen dikdörtgen bölgelerinde çalışır ve maksimum havuzlama veya ortalama havuzlama gibi bir havuzlama işlevi kullanarak her penceredeki bilgileri özetler. Maksimum havuzlama, her havuzlama penceresindeki maksimum değeri alırken, ortalama havuzlama ortalama değeri alır.

Havuzlama katmanları, özellik haritalarının boyutsallığını azaltarak, ağın hesaplama maliyetini düşürmenin yanı sıra aşırı uydurmayı önleyerek performansını

artırmaya yardımcı olabilir. Havuzlama, ağıın, çeviriler veya döndürmeler gibi girdi verilerindeki küçük değışikliklere karşı daha değışmez olmasına da yardımcı olabilir.

Aşağıdakiler de dahil olmak üzere ESA’larda kullanılabilecek birkaç havuzlama katmanı çeşidi vardır:


Maksimum havuzlama: her havuzlama penceresindeki maksimum değeri alır.

Ortalama havuzlama: her havuzlama penceresindeki ortalama değeri alır.

Global havuzlama: tüm özellik haritası boyunca maksimum veya ortalama değeri alır ve her bir özellik haritası için tek bir değeri sonuçlanır.

Uyarlanabilir havuzlama: havuzlama penceresinin boyutunu girdi verilerinin boyutuna göre dinamik olarak ayarlar.

Genel olarak, havuzlama katmanları, özellik haritalarının boyutsallığını azaltmaya ve ağıın performansını artırmaya yardımcı olan evrişimli sinir ağlarının önemli bir bileşenidir.



Şekil 4.4 Havuzlama işleminin uygulanması (Jeong, 2021)

Yoğun katman olarak da bilinen tam bağlantılı katman, katmandaki her nöronun önceki katmandaki her nörona bağlı olduğu evrişimli sinir ağındaki bir katman türüdür. Tamamen bağlantılı bir katmanın amacı, evrişim ve havuzlama katmanları tarafından öğrenilen özellikleri, nihai sınıflandırma veya regresyon görevi için kullanılabilecek yüksek seviyeli bir temsilde birleştirmektir (Han, 2020:6,


Ciresan, 2012:1223, Gao, 2019:1223). Tamamen bağılı bir katmanda, her nöron bir önceki katmandan gelen girdilerin ağırlıklı bir toplamını ve ardından bir aktivasyon fonksiyonunu gerçekleştirir. Tamamen bağılı katmandaki nöronların ağırlıkları ve sapmaları, geri yayılım ve gradyan iniş kullanılarak eğitim sürecinde öğrenilir.

Tamamen bağılı katmanın çıktısı daha sonra ESA'nın son çıktısını üretmek için sınıflandırma için softmax veya regresyon için doğrusal bir aktivasyon işlevi gibi bir son aktivasyon fonksiyonundan geçirilir.

Tamamen bağılı katmandaki nöronların sayısı, tipik olarak önceki evrişimsel ve havuzlama katmanlarındaki nöronların sayısından çok daha azdır, çünkü tamamen bağılı katman, en önemli özellikleri kompakt bir gösterimde birleştirmekten sorumludur.

Bazı durumlarda, bir ESA'da birden çok tam bağlantılı katman kullanılabilir ve her katman, sınıflandırma veya regresyon görevi için uygun sayıda nöron içeren son bir çıkış katmanına kadar nöron sayısını kademeli olarak azaltır.

Genel olarak, tamamen bağlantılı katmanlar, evrişimsel ve havuzlama katmanları tarafından öğrenilen özellikleri son sınıflandırma veya regresyon görevi için kullanılacak yüksek seviyeli bir temsilde birleştirmeye yardımcı olan evrişimli sinir ağlarının önemli bir bileşenidir.



Şekil 4.5 Tamamen bağılı katman (Jeong, 2021)

4.5.2 Evriřimli Sinir Ađı Modelleri

Evriřimli Sinir Ađı modellerinden birkaç rnek ařađıda verilmiřtir.

4.5.2.1 Imagenet

ImageNet, grsel nesne tanıma arařtırmalarında kullanılmak zere tasarlanmış byk lekli bir grnt veritabanıdır. 2009 yılında Princeton niversitesi'ndeki arařtırmacılar tarafından oluřturuldu ve 20.000'den fazla nesne kategorisini kapsayan 14 milyondan fazla grnt ieriyor.

ImageNet veri tabanı, zellikle grnt sınıflandırması ve nesne algılama iin derin đrenme modellerinin geliřtirilmesi ve deđerlendirilmesinde, bilgisayarlı gr arařtırmalarında yaygın olarak kullanılmaktadır. Veritabanındaki grntler, sınıf etiketleriyle etiketlenerek arařtırmacıların modellerini ok eřitli nesne ve kategoriler zerinde eđitip test etmelerine olanak tanır (Deng ve diđerleri, 2009:248, Russakovsky ve diđerleri, 2015:211, Zhou ve diđerleri, 2016:2921).

ImageNet veri tabanının en iyi bilinen kullanımı, Stanford niversitesi'ndeki arařtırmacılar tarafından dzenlenen yıllık bir yarıřma olan ImageNet Byk lekli Grsel Tanıma Mcadelesidir (IBGTM). IBGTM yarıřmasında, katılımcılara bir dizi eđitim grnts ve etiketi verilir ve ardından, ayrı bir test grnts kmesinin etiketlerini tahmin etmesi iin bir modeleđitmeleri istenir. Yarıřma, modelleri, modelin ilk 5 tahmininde dođru etiketin yer almadıđı test grntlerinin yzdesi olan ilk 5 hata oranına gre deđerlendirir.

IBGTM, bilgisayarla gr iin derin đrenmenin geliřtirilmesinde itici bir g olmuřtur ve alandaki en bařarılı modellerin ođu, ImageNet veri tabanında geliřtirilmiř ve deđerlendirilmiřtir. Rekabet ayrıca grnt tanıma dođruluđuunda geliřmelere yol atı ve nesne algılama ve grnt blmlleme gibi ilgili alanlarda ilerlemeler sađladı.

4.5.2.2 Alexnet

AlexNet, 2012 yılında Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından geliřtirilen derin evriřimli bir sinir ađıdır. Derin đrenme ve bilgisayarla

görme alanında öncü bir modeldir ve derin öğrenmenin geliştirilmesinde görüntü sınıflandırması için kilit rol oynamıştır.

AlexNet mimarisi, beş evrişimli katman ve üç tamamen bağlı katman dahil olmak üzere sekiz katmandan oluşur. Konvolüsyonel katmanlar, giriş görüntüsünden özniteliklerin çıkarılmasından sorumluyken, tamamen bağlantılı katmanlar sınıflandırma için kullanılır. Ağ, ReLU aktivasyon işlevini kullanır ve fazla uydurmayı önlemek için bırakma düzenlemesini kullanır (Zhou ve diğerleri, 2016:2927, Simonyan ve Zisserman, 2014:1409).

AlexNet, 1.000 kategoride milyonlarca etiketli görüntü içeren ImageNet veri kümesi üzerinde eğitildi. 2012'deki ImageNet Büyük Ölçekli Görsel Tanıma Mücadelesinde, AlexNet %15,3'lük ilk 5 hata oranına ulaşarak bir sonraki en iyi rakibini önemli ölçüde geride bıraktı.

AlexNet'in başarısı, derin öğrenmenin gücünü gösterdi ve bu alana yeniden ilgi duymaya yol açtı. Mimarisi ve teknikleri, sonraki modellerde geliştirildi ve geliştirildi, bu da bilgisayarla görme görevlerinin doğruluğunda önemli gelişmelere yol açtı.

4.5.2.3 Googlenet

Inception v1 olarak da bilinen GoogleNet, 2014 yılında Google'daki araştırmacılar tarafından geliştirilen derin bir evrişimli sinir ağı mimarisidir. Yüksek hesaplama maliyeti ve daha derin modelleri eğitme zorluğu gibi önceki modellerin bazı eksikliklerini gidermek için tasarlanmıştır.

GoogleNet'in temel özelliklerinden biri, ağın özellikleri birden çok ölçekte verimli bir şekilde yakalamasına olanak tanıyan "başlangıç modüllerinin" kullanılmasıdır. Her bir başlangıç modülü, farklı filtre boyutlarına sahip çoklu evrişimli katmanların yanı sıra havuzlama katmanları ve 1x1 evrişimlerden oluşur. Bu farklı yolların çıktıları birleştirilir ve bir sonraki katmana beslenir.

GoogleNet, başlangıç modüllerine ek olarak, tek bir özellik vektörü oluşturmak için özellik haritalarının uzamsal boyutlarda ortalamasını alan bir küresel ortalama havuzlama katmanı da kullanır. Bu, modeldeki parametre sayısını azaltma ve bir düzenileştirme biçimi sağlama avantajına sahiptir.

GoogleNet'teki bir başka yenilik de, ağın ara katmanlarına eklenen yardımcı sınıflandırıcıların kullanılmasıdır. Bu sınıflandırıcılar, girdi için doğru sınıf etiketlerini tahmin etmek üzere eğitilir ve kayıp, tüm ağ boyunca geri yayılır. Bu, ek denetim sağlama ve derin ağlarda oluşabilen yok olan gradyan sorunuyla mücadele etmeye yardımcı olma etkisine sahiptir.

Genel olarak GoogleNet, IBÖGTM 2014 yarışmasında %6,67'lik ilk 5 hata oranıyla ImageNet veri kümesinde son teknoloji ürünü bir performans elde etti. O zamandan beri, her biri farklı iyileştirmelere ve varyasyonlara sahip olan Inception mimarisinin birkaç başka versiyonu izledi.

4.5.2.4 Densenet

DenseNet, 2017 yılında Facebook AI Research'teki araştırmacılar tarafından geliştirilen derin bir evrişimli sinir ağı mimarisidir. Önceki modellerin, kaybolan gradyan sorunu ve derin ağları eğitmek için büyük miktarda veriye duyulan ihtiyaç gibi bazı sınırlamalarını ele almak üzere tasarlanmıştır.

DenseNet'in temel özelliklerinden biri, her katmanın önceki tüm katmanlara ileri beslemeli bir şekilde bağlandığı birden çok katmandan oluşan yoğun blokların kullanılmasıdır. Bu, her katmanın çıktısının önceki tüm katmanların çıktılarıyla birleştirildiği ve bir sonraki katmana girdi olarak iletildiği anlamına gelir. Bu yoğun bağlantı modeli, ağ üzerinden bilgi akışını artırma ve eğitim sırasında gradyan akışını iyileştirme etkisine sahiptir (Huang ve diğerleri, 2017:4700, Jegou ve diğerleri, 2017:11, Huang ve diğerleri, 2018:2752).

Yoğun bloklara ek olarak, DenseNet, yoğun bloklar arasındaki özellik haritalarının uzamsal boyutlarını azaltmak için kullanılan geçiş katmanlarını da kullanır. Bu katmanlar, toplu normalleştirme katmanı, 1x1 evrişim katmanı ve 2x2 ortalama havuzlama katmanından oluşur. Bu katmanların kombinasyonu, özellik kanallarının sayısını korurken, özellik haritalarının sayısını ve uzamsal boyutları azaltır. DenseNet'in bir diğer önemli yönü, 3x3 evrişimli katmanlardan önceki kanal sayısını azaltan 1x1 evrişimli katmanlar olan darboğaz katmanlarını kullanmasıdır. Bu, temsil gücünü geliştirirken ağın hesaplama maliyetini düşürme etkisine sahiptir (İşler ve Torresani, 2017:3981, Huang ve diğerleri, 2017:4705)

Genel olarak, DenseNet, görüntü sınıflandırma, nesne algılama ve semantik bölümlendirme dahil olmak üzere çeşitli bilgisayarla görme görevlerinde son teknoloji performans elde etti. Başarısı, kısmen parametrelerin verimli kullanımı ve ağıın birden çok katmanından gelen bilgileri kullanma becerisinden kaynaklanmaktadır.

4.6 Tamamen Evrişimli Ağ

Tamamen evrişimli ağlar (TEA) girdi olarak bir görüntü alır ve piksel düzeyinde sınıflandırma yaparak görüntü segmentasyonu görevlerini gerçekleştirir.

TEA, geleneksel bir ESA mimarisine benzerdir, ancak son katmanları değiştirilir ve daha genişletilir. ESA'lardaki son katmanlar, genellikle bir tamamen bağlı katmandır ve bu katmanlar, sınıflandırma işlemini gerçekleştirir. Ancak TEA'da, son katmanlar evrişim katmanlarına dönüştürülür ve her bir pikselin sınıflandırması için bir sonuç üretir.

Genellikle üç aşamalı bir yapıya sahiptir: Kodlayıcı, Dekodlayıcı ve Atlama Bağlayıcısı (AB). Kodlayıcı, girdi görüntüyü küçük özellik haritalarına (feature map) indirger ve önemli özellikleri çıkarmak için evrişim katmanlarını kullanır. Dekodlayıcı, özellik haritalarını orijinal boyutuna döndürmek için ters evrişim katmanlarını kullanır ve ayrıca daha yüksek çözünürlükteki özellik haritalarını birleştirmek için ölçekleme işlemleri gerçekleştirir. Atlama Bağlayıcısı, kodlayıcı ve dekodlayıcı arasında bir bağlantıdır ve daha yüksek seviyedeki özellikleri daha düşük seviyedeki özelliklerle birleştirerek daha doğru sınıflandırma sonuçları elde etmek için kullanılır ve derin öğrenme modellerinde sıkça kullanılan bir bağlantı tipidir ve özellikle görüntü segmentasyonu gibi görsel işleme görevlerinde yaygın olarak kullanılır.

AB, önceki katmanların çıkışlarına doğrudan erişim sağlayan bir bağlantıdır. Bu bağlantılar, daha yüksek seviyedeki özelliklerin daha düşük seviyedeki özelliklerle birleştirilerek, daha yüksek kaliteli sonuçlar elde etmek için kullanılır.

Örneğin, bir tamamen evrişimli ağ için, özellikle bir görüntü segmentasyonu görevinde, kodlayıcı (encoder) katmanları girdi görüntüsünden daha düşük özellik haritaları (feature map) çıkarırken, dekodlayıcı (decoder) katmanları bu özellik

haritalarını orijinal boyuta geri getirir ve daha yüksek çözünürlükte özellik haritaları oluşturur. Ancak, bu işlem, yüksek frekanslı bilgilerin kaybedilmesine neden olabilir.

Bu sorunu çözmek için, skip-connection kullanarak önceki kodlayıcı katmanlarından elde edilen özellik haritalarını dekodlayıcı katmanlarına doğrudan bağlayarak, daha yüksek kaliteli sonuçlar elde edilebilir. Böylece, yüksek seviyedeki özellikler (örneğin, nesne konumları) daha düşük seviyedeki özelliklerle (örneğin, kenarlar) birleştirilerek, daha doğru segmentasyon sonuçlarına ulaşılabilir.

Skip-connection'ın kullanımı, modelin daha hızlı öğrenmesini, daha yüksek doğruluk oranlarını ve daha az overfitting (aşırı öğrenme) eğilimini sağlayabilir. Bu nedenle, AB, derin öğrenme modellerinde sıkça kullanılan bir tekniktir

TEA, özellikle görüntü segmentasyonu gibi piksel bazlı sınıflandırma görevleri için kullanışlıdır. Bu nedenle, biyomedikal görüntüleme, robotik görüş, trafik akışı analizi ve otonom araçlar gibi birçok uygulama alanında yaygın olarak kullanılmaktadır.

4.6.1 Tamamen Evrişimli Ağ Mimarisi

Tamamen evrişimli ağlar, end-to-end görüntü segmentasyonu için özel olarak tasarlanmış bir derin öğrenme mimarisidir. TEA mimarisi, tamamen evrişimli tabakalardan oluşur ve özellikle piksel tabanlı tahminler yapmak için tasarlanmıştır.

BU mimari, bir kodlayıcı (encoder) ve bir dekodlayıcı (decoder) bölümden oluşur. Kodlayıcı bölümü, birbirini takip eden birkaç evrişimli katmandan oluşur ve görüntüyü daha yüksek seviyeli özellik haritalarına dönüştürür. Özellik haritaları, daha sonra dekodlayıcı bölümünde kullanılacak şekilde kodlayıcı katmanlarından çıkartılır.

Dekodlayıcı bölümü, kodlayıcı bölümünde çıkarılan özellik haritalarını girdi olarak alır ve piksel bazında bir tahmin yaparak girdi görüntüyü segmente eder ve daha yüksek çözünürlükte özellik haritaları oluşturmak için birkaç transpoze evrişimli katman (transpose convolution layer) ve birkaç evrişimli katman kullanır. Ayrıca, kodlayıcı bölümündeki katmanlardan özellik haritalarını alan birkaç AB katmanı da dekodlayıcı bölümünde kullanılabilir.

TEA, giriş görüntüsü boyutuna bağlı olarak farklı boyutlarda çıktı verebilir. Örneğin, girdi görüntüsü boyutu $n \times n$ ise, bu sinir ağının çıktısı $n \times n$ boyutunda bir özellik haritasıdır. Bu özellik haritası, her piksel için bir sınıflandırma sonucu verir ve her bir pikselin hangi sınıfa ait olduğunu tahmin eder.

TEA, özellikle görüntü segmentasyonu için tasarlanmış bir mimari olduğu için, daha iyi sonuçlar elde etmek için genellikle eğitim verilerinde piksel seviyesinde etiketleme yapılması gerektirir. Bu etiketleme işlemi, manuel olarak veya otomatik olarak gerçekleştirilebilir.

4.7 Özyinelemeli Sinir Ağı

Rekürrent sinir ağları (RNN), derin öğrenme yöntemleri arasında yer alan bir tür yapay sinir ağıdır. RNN, zaman serileri ve doğal dil işleme gibi sıralı verilerin işlenmesi için tasarlanmıştır. RNN, girdi verilerindeki zamansal bağımlılıkları modellemek için özel olarak tasarlanmıştır.

RNN'nin en önemli özelliği, önceki adımlardaki girdi ve saklı durum (hidden state) bilgisini hafızasında tutabilmesidir. Bu sayede, RNN'ler önceki adımlardan gelen bilgileri kullanarak mevcut adımdaki çıktıyı hesaplayabilir. Bu özelliği nedeniyle, RNN'ler özellikle zaman serilerinde ve doğal dil işlemede etkilidir.

RNN'nin yapısal olarak en önemli özelliği, geri besleme bağlantılarına sahip olmasıdır. Bu geri besleme bağlantıları, önceki adımlardaki çıktıların saklanması ve daha sonra kullanılmasını sağlar. RNN'nin girdi, saklı durum ve çıktı katmanlarından oluşur. Girdi katmanı, verinin RNN'ye girilmesini sağlar. Saklı durum katmanı, önceki adımlardan gelen bilgiyi saklar ve mevcut adımdaki çıktıyı hesaplamak için kullanılır. Çıktı katmanı ise, RNN'nin çıktısını verir.

RNN eğitimi, geriye doğru yayılım algoritması kullanılarak yapılır. Eğitim verileri, belirli bir sıraya göre RNN'ye verilir ve her adımda RNN tarafından tahmin edilen çıktılar ile gerçek çıktılar arasındaki fark hesaplanarak bir hata hesaplanır. Hatanın geriye doğru yayılmasıyla, RNN'nin ağırlıkları güncellenir ve eğitim verilerine daha iyi uyum sağlaması sağlanır.

RNN'lerin bazı dezavantajları da vardır. Özellikle, uzun zaman serilerinde ve uzun cümlelerde, önceki adımlardaki bilgilerin kaybolması sorunu ortaya çıkabilir. Bu sorunu çözmek için, uzun-kısa süreli bellek (LSTM) ve GRU (Gated Recurrent Unit) gibi RNN türevleri geliştirilmiştir. Bu türevler, RNN'nin yapısına ekstra mekanizmalar ekleyerek, önceki adımlardaki bilgilerin daha iyi korunmasını sağlarlar.

4.7.1 Özyinelemeli Sinir Ağı Mimarisi

Özyinelemeli Sinir Ağları (ÖSA), girdi verilerindeki zamansal bağımlılıkları modellemek için özel olarak tasarlanmış yapay sinir ağı türüdür ve önceki adımlardaki girdi ve saklı durum bilgisini hafızasında tutarak, mevcut adımdaki çıktıyı hesaplayabilirler. Bu özelliği nedeniyle, ÖSA'lar özellikle zaman serileri ve doğal dil işlemede etkilidir.

ÖSA, girdi verilerini sıralı bir şekilde işleyen bir yapıdadır. Her adımda, önceki adımdan gelen bilgi ve mevcut adımın girdisi birleştirilerek yeni bir saklı durum hesaplanır. Bu saklı durum, ağın hafızasını temsil eder ve önceki adımlardan gelen bilgiyi saklamak için kullanılır.

Özyinelemeli Sinir Ağı'nın yapısal olarak üç önemli bileşeni vardır: girdi katmanı, saklı durum katmanı ve çıktı katmanı. Girdi katmanı, verinin ÖSA'ya girişini sağlar. Saklı durum katmanı, önceki adımdan gelen bilgiyi saklar ve mevcut adımdaki çıktıyı hesaplamak için kullanılır. Çıktı katmanı ise, ÖSA'nın çıktısını verir.

Bu ağın en önemli özelliği, geri besleme bağlantılarına sahip olmasıdır. Bu geri besleme bağlantıları, önceki adımlardaki çıktıların saklanması ve daha sonra kullanılmasını sağlar. Ağ yapısındaki geri besleme bağlantıları, ağın önceki durumunu ve mevcut durumunu aynı anda modelleyebilmesini sağlar.

Ağ eğitimi, geriye doğru yayılım algoritması (backpropagation through time) kullanılarak yapılır. Eğitim verileri, belirli bir sıraya göre ÖSA'ya verilir ve her adımda ağ tarafından tahmin edilen çıktılar ile gerçek çıktılar arasındaki fark hesaplanarak bir hata hesaplanır. Hatanın geriye doğru yayılmasıyla, ağın ağırlıkları güncellenir ve eğitim verilerine daha iyi uyum sağlaması sağlanır.

ÖSA'nın bazı dezavantajları vardır. Özellikle, uzun zaman serilerinde ve uzun cümlelerde, önceki adımlardaki bilgilerin kaybolması sorunu ortaya çıkabilir. Bu sorunu çözmek için, uzun-kısa süreli bellek ve geçitli özyinelemeli ünite gibi ağ türevleri geliştirilmiştir.

4.8 Çekişmeli Üretici Ağı

ÜÇA (Çekişmeli Üretici Ağı), yüksek kaliteli ve gerçekçi görüntüleri üretmek için kullanılan bir derin öğrenme algoritmasıdır. Tıbbi görüntüleme alanında da kullanılmaktadır. ÜÇA, tıbbi görüntülerin iyileştirilmesi, sentezlenmesi ve analiz edilmesinde önemli bir rol oynayabilir.

Özellikle, bu ağın tıbbi görüntülemeye kullanıldığı alanlar şunları içerir:

Görüntü Sentezi: ÜÇA, tıbbi görüntü sentezinde kullanılarak, veri setindeki yetersiz sayıda görüntü ile gerçekçi görüntüler oluşturabilir. Örneğin, ÜÇA kullanarak, meme kanseri teşhisi için mamografi görüntülerinden sentetik mamografi görüntüleri üretilebilir.

Çekişmeli Üretici Ağı, görüntü sentezi için kullanıldığında, önceden belirlenmiş bir veri seti kullanarak yeni görüntüler üretir.

Ağ iki ayrı derin sinir ağından oluşur: biri "jeneratif ağ" ve diğeri "ayrıştırıcı ağ" olarak adlandırılır. Jeneratif ağ, veri setindeki örneklerin özelliklerini öğrenerek benzer görüntüler üretir. Ayrıştırıcı ağ ise gerçek ve üretilen görüntüler arasındaki farkı belirleyerek jeneratif ağın gelişmesine yardımcı olur. Jeneratif ağın amacı, gerçekçi görüntüler üretmek için ayrıştırıcı ağın kusurlarını tespit ederek kendisini geliştirmektir. Bu şekilde, Çekişmeli Üretici Ağı sürekli olarak gerçekçi görüntüler üretmek için öğrenir ve gelişir.

Görüntü sentezi için, rastgele gürültü vektörleri kullanır ve bu vektörleri jeneratif ağa vererek yeni görüntüler üretir. Bu sayede, veri setindeki örnekleri tamamen kopyalamak yerine, benzer özelliklere sahip ama farklı görüntüler üretebilir. Örneğin, ÜÇA kullanarak, bir köpek görüntüsü verildiğinde, farklı ırklara ait köpeklerin görüntülerini sentezleyebilir.

Görüntü sentezi için, özellikle sanat, moda ve tasarım gibi alanlarda kullanılmaktadır. Ayrıca, tıbbi görüntüleme de kullanılarak, nadir hastalıkların teşhisi için yeterli sayıda görüntüye sahip olunamadığında sentetik görüntüler üretmek için kullanılabilir.

Ancak, ağıın sentezlediği görüntülerin gerçekçiliği ve kalitesi bazen yetersiz olabilir ve daha fazla geliştirme ve iyileştirme çalışması gerektirebilir.

Görüntü Restorasyonu: Tıbbi görüntülerin iyileştirilmesinde de kullanılabilir. Özellikle, düşük dozda radyasyon kullanılarak elde edilen tomografi görüntülerinin iyileştirilmesinde de kullanılarak daha kaliteli görüntüler elde edilebilir.

Tıbbi görüntülerdeki düşük çözünürlük, gürültü ve diğer kalite sorunlarını çözmek için kullanılabilir.

ÜÇA'nın görüntü restorasyonunda kullanılabilmesi için öncelikle, eğitim veri setlerinde yeterli sayıda yüksek kaliteli görüntü bulunması gerekmektedir. Daha sonra, eğitim veri setindeki yüksek kaliteli görüntüleri kullanarak, yeni görüntüler üretirken düşük çözünürlük veya gürültü gibi kalite sorunlarını ortadan kaldırmaya çalışır.

Bu yöntem, tıbbi görüntülerin daha iyi analiz edilmesini sağlar. Örneğin, tıbbi görüntülerdeki düşük çözünürlük veya gürültü, hastalıkların teşhisini ve tedavisini zorlaştırabilir. Ancak, ağ sayesinde, bu görüntüler daha yüksek çözünürlükte veya daha az gürültülü hale getirilerek, hastalıkların daha doğru bir şekilde teşhis edilmesine ve tedavi edilmesine olanak sağlanabilir.

Öte yandan, Çekişmeli Üretici Ağı'n tıbbi görüntü restorasyonunda kullanımı henüz yeni bir alandır ve çalışmalar halen devam etmektedir. Bu nedenle, tıbbi görüntü restorasyonunda kullanılmasıyla ilgili daha fazla araştırma yapılması ve geliştirme çalışmalarının devam etmesi gerekmektedir.

Veri Artırma: Tıbbi görüntü veri setlerinin artırılmasında da kullanılabilir. Özellikle, nadir hastalıkların teşhisi için yeterli sayıda görüntüye sahip olunamadığında, ÜÇA kullanılarak sentetik görüntüler üretilerek veri seti artırılabilir.

Görüntü Sınıflandırma: Medikal görüntülerin otomatik olarak sınıflandırılmasında da kullanılabilir. Özellikle, cilt kanseri gibi teşhis edilmesi zor olan hastalıkların tanısında kullanılarak daha doğru sonuçlar elde edilebilir.

Bu yöntem, tıbbi görüntülerin doğru bir şekilde sınıflandırılmasını ve hastalıkların teşhis edilmesini kolaylaştırabilir.

Sınıflandırıcı olarak kullanılabilmesi için, öncelikle bir eğitim veri setine ihtiyaç vardır. Bu veri setinde, farklı hastalıkların veya sağlıklı durumların görüntüleri bulunmalıdır. Daha sonra, eğitilerek, bu veri setindeki görüntüleri analiz eder ve doğru bir şekilde sınıflandırılmasını öğrenir.

Bu yöntem, tıbbi görüntülerdeki ince detayları algılayarak, hastalıkların daha doğru bir şekilde teşhis edilmesine olanak sağlayabilir. Örneğin, ÜÇA sayesinde, bir röntgen görüntüsündeki kanser lezyonu daha doğru bir şekilde tespit edilebilir ve tedavi süreci daha erken aşamalarda başlayabilir.

Ayrıca, sınıflandırıcı olarak kullanımı, tıbbi görüntülemeye diğer yöntemlere göre daha az eğitim veri seti gerektirir. Bu nedenle, tıbbi görüntülerin doğru bir şekilde sınıflandırılması için özellikle az sayıda veriye sahip durumlarda oldukça faydalı olabilir.

Ancak, ÜÇA'nın tıbbi görüntü sınıflandırmasında kullanımı henüz yeni bir alandır ve çalışmalar halen devam etmektedir. Bu nedenle, tıbbi görüntü sınıflandırmasında kullanılmasıyla ilgili daha fazla araştırma yapılması ve geliştirme çalışmalarının devam etmesi gerekmektedir.

Görüntü Kaydetme: Tıbbi görüntülerin kaydedilmesinde de kullanılabilir. Özellikle, sıkıştırılmış görüntülerin yeniden yapılandırılmasında kullanılarak, kaydedilmiş görüntülerin kalitesi iyileştirilebilir.

Genel olarak, sağlık alanındaki görüntülemeye kullanılarak, daha kaliteli, gerçekçi ve verimli bir teşhis süreci sağlanabilir.

4.8.1 Çekişmeli Üretici Ağı Mimarisi

Çekişmeli Üretici Ağı, iki adet derin öğrenme ağından oluşan bir yapay sinir ağı mimarisidir. Bu iki ağ, birbirine karşı oynayan iki oyuncu gibi davranır: biri üretici olarak adlandırılır ve diğeri ise ayırt edici olarak adlandırılır.

Üretici, rastgele bir gürültü vektöründen başlayarak gerçekçi görünen yeni örnekler (örneğin, resimler) üretmeye çalışır. Ayırt edici, gerçek örnekleri ve üreticinin ürettiği örnekleri ayırt etmeye çalışır.

Ağın ana fikri, bu iki ağın birbirlerine karşı mücadele ederek öğrenmesidir. Üretici, ayırt edicinin yanılttığı gerçekçi örnekler üretmeye çalışırken, ayırt edici de üreticinin yanılttığı sahte örnekleri tespit etmeye çalışır.

Mimarisi, genellikle aşağıdaki adımlarla gerçekleştirilir:

Üreticinin Girişi: Üreticinin girişine rastgele bir gürültü vektörü verilir. Mimarisi üreticinin girişi, genellikle rastgele bir gürültü vektörüdür. Bu gürültü vektörü, normal bir dağılım tarafından oluşturulabilir ve genellikle çok boyutlu bir vektör şeklindedir. Üretici, bu gürültü vektöründen başlayarak gerçekçi görünen örnekler oluşturur. Bu gürültü vektörü, üreticinin oluşturduğu örneklerin farklı olmasını sağlayan bir rastgelelik ögesi sağlar. Örneğin, bir ÜÇA'yı resimler oluşturmak için kullanıyorsanız, gürültü vektörü, her bir örnek için farklı bir resim oluşturur ve bu nedenle her biri farklı görünür. Bu şekilde, üretici, rastgele gürültü vektörlerinden başlayarak, gerçekçi ve çeşitli örnekler oluşturabilir.

Üretici Ağı: Üretici, gürültü vektörünü işleyerek bir resim gibi bir çıktı oluşturur. Bu ağ, rastgele bir gürültü vektöründen gerçekçi görüntüler oluşturmak için kullanılır. Üretici ağı, tipik olarak evrişimli bir sinir ağı olarak tasarlanmıştır ve bir dizi evrişim katmanı ve ters evrişim katmanı içerir. Evrişim katmanları, özellik haritalarını çıkarmak ve görüntü özelliklerini öğrenmek için kullanılır. Ters evrişim katmanları ise, özellik haritalarını yeniden boyutlandırarak gerçekçi görüntüler oluşturmak için kullanılır.

Başlangıçta rastgele bir gürültü vektörünü alır ve ardından bu gürültü vektörünü özellik haritalarına dönüştürmek için bir dizi evrişim katmanı kullanır. Bu

evriřim katmanları, gürültü vektöründen çıkarılan özellikleri, daha sonra ters evriřim katmanları aracılığıyla gerçekçi bir görüntüye dönüřtürür.

Eđitim sırasında diskriminatör ađ tarafından üretilen geri bildirimlerle güncellenir. Bu geri bildirimler, üretici ađın daha gerçekçi görüntüler oluřturmasına yardımcı olur. Eđitim sonunda, üretici ađ, gerçekçi görüntüler üretmek için öđrenilmiş özellikleri kullanabilir.

Ayırt Edici Ađı: Ayırt edici, gerçek resimler ve üretcin oluřturduđu sahte resimler arasındaki farkı belirlemek için, iki ayrı yolla eđitilir: gerçek resimlerin sınıflandırılması ve sahte resimlerin sınıflandırılması. Bu ađ, gerçek görüntülerle üretilen görüntüleri ayırt etmek için kullanılır. Ayırt edici ađı, tipik olarak bir ESA olarak tasarlanmıřtır.

Ayırt edici ađı, gerçek görüntüler ve üretilen görüntüler arasındaki farklılıkları öđrenmek için eđitilir. Bu ađ, gerçek görüntüler için yüksek deđerler ve üretilen görüntüler için düşük deđerler üretecek řekilde tasarlanır. Böylece, üretici ađ, gerçek görüntülerle aynı gibi görünen görüntüler üretmeye çalışırken, ayırt edici ađ, gerçek ve üretilen görüntüleri ayırt etmek için çalışır.

Başlangıçta gerçek görüntüleri ve üretilen görüntüleri kabul eder. Ardından, bu görüntüleri evriřim katmanları ve tam bađlantılı katmanlar aracılığıyla işler. Evriřim katmanları, özellik haritalarını oluřturmak ve özellikleri çıkarmak için kullanılır. Tam bađlantılı katmanlar, özellik haritalarını işleyerek gerçek veya sahte olduđuna karar vermek için kullanılır.

Eđitim sırasında gerçek ve üretilen görüntüler arasındaki farklılıkları öđrenir. Eđitim sonunda, ayırt edici ađ, gerçek ve üretilen görüntüleri ayırt etmek için öđrenilmiş özellikleri kullanabilir.

Kayıp Fonksiyonu: Kayıp fonksiyonu, üretcin ve ayırt edicinin performansını ölçmek için kullanılır. Üretcin hedefi, ayırt edicinin yanıltılmasını sađlamak, yani sahte resimlerin gerçekçi görünmesini sađlamaktır. Ayırt edicinin hedefi, gerçek resimleri dođru bir řekilde sınıflandırmak ve sahte resimleri yanıltıcı olarak tanımlamaktır.

Geri Besleme Döngüsü: Kayıp fonksiyonu sonucuna göre, geri besleme döngüsü, üreticinin girdi vektöründeki parametreleri ayarlar ve üreteç bir sonraki sefer daha gerçekçi örnekler üretir.

ÜÇA geri besleme döngüsü aşağıdaki adımlardan oluşur:

Üretici ağı, girdi olarak rastgele bir gürültü vektörü alır ve bu gürültü vektöründen gerçekçi görüntüler üretir.

Ayırt edici ağı, gerçek ve sahte görüntüler arasındaki farkı ayırt etmek için tasarlanmıştır. Gerçek ve sahte görüntüleri alır ve bunları gerçek veya sahte olarak sınıflandırmaya çalışır.

Gerçek görüntüleri gerçek, sahte görüntüleri ise sahte olarak doğru bir şekilde sınıflandırabilirse, bu durumda ayırt edici ağı kaybı düşük olacaktır. Ancak, üretici ağı ürettiği sahte görüntüler gerçek görüntülerden ayırt edilemiyorsa, ayırt edici ağı kaybı yüksek olacaktır.

Üretici ağı, ayırt edici ağı geri bildirimine göre sahte görüntülerin gerçekçiliğini artırmak için güncellenir. Üretici ağı kaybı, ayırt edici ağı geri bildirimine dayanarak hesaplanır.

Bu döngü, birkaç kez tekrarlanarak ÜÇA eğitilir ve üretici ağı, gerçek görüntülere benzer sahte görüntüler üretir.

Bu geri besleme döngüsü, üretici ağı daha iyi sahte görüntüler üretmesini ve ayırt edici ağı gerçek ve sahte görüntüleri doğru bir şekilde ayırt etmesini sağlayarak ÜÇA'nın başarısını artırır.

Bu adımlar, ÜÇA'nın öğrenme sürecinde tekrarlanarak, üreticinin daha gerçekçi örnekler oluşturduğu ve ayırt edicinin daha doğru bir şekilde sınıflandırabildiği bir denge noktasına ulaşılır.

5 UNET VE RASTGELE ORMAN ALGORİTMASI

5.1 UNET

Son yıllarda, derin evrişimli ağlar bilgisayar görüşünde çok ilerleme kaydetmiştir (Krizhevsky ve diğerleri, 1106). Konvolüsyonel ağlar uzun süredir var olmasına rağmen, ağların ve veri kümelerinin boyutu nedeniyle başarıları sınırlı kalmıştır (LeCun ve diğerleri, 1989:541). Biyomedikal görüntü işlemede, her piksele bir sınıf etiketi atanmalıdır. 2015 yılında tıbbi görüntüleme konusunda segmentasyon çalışması yapılmıştır. Biyomedikal görüntüler piksel tabanlı olduğu için etiketleme zordur. Büyük bir veri grubu ve donanım gerektiren bu etiketleme işlemi oldukça zaman almaktadır. UNET, piksel tabanlı bölütleme sunar (Ronneberger ve diğerleri, 2015:234).

UNet, görüntü bölümlene görevleri için kullanılan evrişimli bir sinir ağı mimarisidir. Olaf Ronneberger, Philipp Fischer ve Thomas Brox tarafından 2015 tarihli "U-Net: Convolutional Networks for Biomedical Image Segmentation" başlıklı makalelerinde önerildi.

Mimari, adını U şeklindeki tasarımından almıştır. Aralarında darboğaz katmanı olan bir kodlayıcı ağı ve bir kod çözücü ağından oluşur. Kodlayıcı ağı, görüntüyü altörnekleyen ve özellikleri çıkaran bir dizi evrişimli ve havuzlama katmanıdır. Kod çözücü ağı, görüntüyü yeniden oluşturan ve segmentasyon gerçekleştiren bir dizi üst örnekleme ve evrişimli katmandır.

UNet mimarisi, tümörleri ve manyetik rezonans görüntüleri, bilgisayarlı tomografi taramaları ve diğer tıbbi görüntü türlerindeki diğer anormallikleri bölmek gibi çeşitli tıbbi görüntüleme uygulamaları için kullanılmıştır. Ayrıca, tıp alanı dışındaki diğer görüntü bölümlendirme görevleri için de uyarlanmıştır.

UNet mimarisinin temel özelliklerinden biri, bir görüntünün piksel bazında hassas bir şekilde bölümlenmesine izin vermesidir. Bu, kodlayıcı ağdan gelen özellik haritalarının kod çözücü ağdakilerle birleştirilmesiyle elde edilir. Bu, kod çözücü ağının, daha doğru segmentasyon sonuçları oluşturmak için kodlayıcı ağının düşük

seviyeli özellik haritalarını kullanmasına izin verir (Çiçek ve diğerleri, 2016:424, Roth ve diğerleri, 2020, Guo ve diğerleri, 2021:882)

UNet, kara kütlelerini, su kütlelerini ve diğer özellikleri bölümlere ayırmak için kullanılabileceği uydu görüntüleri gibi tıbbi görüntülemenin ötesinde çeşitli uygulamalar için kullanılmıştır. Robotikte, nesne tanıma ve engellerden kaçınma gibi görsel algı görevleri için de kullanılmıştır.

Genel olarak, UNet mimarisinin, özellikle tıbbi görüntüleme alanında, görüntü bölümlendirme görevleri için güçlü ve etkili bir araç olduğu kanıtlanmıştır. Kesin ve doğru segmentasyon sonuçları üretme yeteneği, onu birçok araştırmacı ve uygulayıcı için popüler bir seçim haline getirdi.

UNET'in kodlayıcı kısmı, girdi görüntüsünden özellik haritalarını elde etmek için birkaç evrişim katmanından oluşur. Bu katmanlar, daha yüksek özetlemeler oluşturmak için giderek daha az örnekleme yaparak, biraz daha düşük çözünürlükte özellik haritaları oluşturur.

UNET'in kodlayıcı kısmının son katmanı, girdi görüntüsünden elde edilen en küçük boyuttaki özellik haritasını üretir. Bu özellik haritası, ağız kodlayıcı kısmının tamamının çıktısıdır ve ağız kodlayıcı kısmının çıkışı belirler.

UNET'in kodlayıcı kısmının çıktısı, kodlayıcı kısmının özellik haritalarının tersini alarak bir yeniden örnekleme sürecine sokulur. Bu süreçte, özellik haritaları giderek daha yüksek çözünürlükte hale getirilir ve aynı zamanda özellik haritalarının boyutu da artar. Bu, kodlayıcı kısmında azaltılan ölçekleme faktörlerinin tekrar geri kazanılmasını sağlar.

UNET'in kodlayıcı kısmının sonuna yaklaştıkça, ağız çıkışı da giderek daha yüksek çözünürlükte hale gelir. Bu çıkış, her pikselin ait olduğu sınıfı belirleyen bir etiket haritasıdır. Bu etiket haritası, kodlayıcı kısmının çıktısı ile aynı boyutta olup, her bir pikselin sınıfı hakkında bilgi verir.

UNET, tıbbi görüntülerdeki yapıları segmente etmek için sıklıkla kullanılan bir mimari olmasının yanı sıra, eğitim verilerinin az olduğu durumlarda da başarılı sonuçlar verir. Ayrıca, kodlayıcı ve kod çözücü kısımlarındaki simetrik yapısı

sayesinde, sınırlı sayıda eğitim verisi kullanarak bile iyi sonuçlar elde etmek mümkündür. Bu nedenle, tıbbi görüntüleme alanında sınırlı sayıda eğitim verisi bulunması durumunda UNET, iyi bir seçenek olabilir.

5.1.1 Unet Kod Çözücü

UNET'in kod çözücü kısmı, kodlayıcı kısmının özellik haritalarının tersini alarak bir yeniden örnekleme sürecine sokulur. Bu süreçte, özellik haritaları giderek daha yüksek çözünürlükte hale getirilir ve aynı zamanda özellik haritalarının boyutu da artar. Bu, kodlayıcı kısmında azaltılan ölçekleme faktörlerinin tekrar geri kazanılmasını sağlar.

UNET'in kod çözücü kısmında, özellik haritalarının yeniden örnekleme işlemi ile birlikte, kodlayıcı kısmında kullanılan özellik haritalarının da eklenmesi gerekir. Bu işlem, kod çözücü kısmının her özellik haritasında detaylı bölütleme yapmasına olanak tanır.

Kod çözücü kısmındaki ilk katman, kodlayıcı kısmındaki son özellik haritasını alır ve bir evrişim katmanı kullanarak daha yüksek çözünürlükteki bir özellik haritasına dönüştürür. Bu işlem, her bir özellik haritası için tekrarlanır ve kod çözücü kısmı, kodlayıcı kısmında azaltılan ölçekleme faktörlerinin tekrar kazanılması için kullanılır.

UNET'in kod çözücü kısmında, özellik haritaları giderek daha yüksek çözünürlükte hale getirilir ve bu işlem, detaylı segmentasyon yapmak için kullanılır. Kod çözücü kısmındaki her bir özellik haritası, kodlayıcı kısmında kullanılan özellik haritalarının aynısını içerir ve bu özellik haritaları, segmentasyon işlemi için kullanılır.

UNET'in kod çözücü kısmı, tıbbi görüntülerdeki yapıların segmentasyonu için önemlidir. Bu bölüm, özellik haritalarının yeniden boyutlandırılması ve kodlayıcı kısmında kullanılan özellik haritalarının birleştirilmesi gibi işlemleri yaparak detaylı segmentasyonu sağlar.

5.1.2 Unet Atlama Bağlantıları

UNET'in en önemli özelliklerinden biri, kodlayıcı kısmında kullanılan özellik haritalarının kod çözücü kısmındaki ilgili özellik haritalarına direkt olarak iletilmesini sağlayan atlama bağlantılarıdır.

UNET'in atlama bağlantıları, kodlayıcı ve kod çözücü kısımlarını birleştirerek derin ağın sonuçlarını iyileştirir. Atlama bağlantıları, kodlayıcı kısmındaki özellik haritalarının kod çözücü kısmındaki ilgili özellik haritalarıyla birleştirilmesini sağlar.


Atlama bağlantıları, kodlayıcı kısmında seçilen özellik haritalarının doğrudan kod çözücü kısmındaki ilgili özellik haritalarına aktarılmasıyla gerçekleştirilir. Bu, kod çözücü kısmının her özellik haritasında detaylı bölümlene yapmasına olanak tanır.

Atlama bağlantıları, özellik haritalarının geçişinde kaybedilen detayları geri kazanır ve daha doğru bir segmentasyon sonucu elde edilmesini sağlar. Bu bağlantılar, UNET'in segmentasyon performansını önemli ölçüde artırır.

UNET'in atlama bağlantıları, tıbbi görüntülerdeki yapıların segmentasyonu için önemlidir. Bu bağlantılar, özellik haritalarının doğrudan kod çözücü kısmındaki ilgili özellik haritalarıyla birleştirilmesini sağlar ve detaylı segmentasyon yaparak daha doğru sonuçlar elde edilmesini sağlar.

5.1.3 UNET Mimarisi

Şekil 5-1'de görüldüğü gibi UNET adını U harfini andıran görünümünden almıştır. Giriş görüntüleri çıkışta parçalı görüntüler olarak alınır. Ağın bağlı katmanı yoktur. Yalnızca evrişim katmanı kullanılır. Tıbbi görüntünün çevresine simetrik olarak sınır bölgesindeki pikseller eklenerek görüntü tamamen bölümlere ayrılır. 32x32 çözünürlüğe sahip piksel için bir örnektir. Mavi kutular, çok kanallı özelliği olan haritalara karşılık gelir. Kanal numaraları kutunun üzerinde gösterilir. Oklar farklı süreçleri temsil eder. UNET, kodlayıcı ve kod çözücü olmak üzere iki bölümden oluşur.



Şekil 5.1 UNET Mimarisi (Ronneberger ve diğerleri, 2015)

UNet mimarisi iki ana bölümden oluşur: bir kodlayıcı ağı ve bir kod çözücü ağı. Kodlayıcı ağı, giriş görüntüsünden özellikleri çıkarmak için tasarlanırken, kod çözücü ağı, bölümlenmiş görüntüyü yeniden oluşturmak için tasarlanmıştır.

Kodlayıcı ağı, giriş görüntüsünden özellikleri çıkarmak için kullanılan birkaç evrişimli katmandan oluşur. Her evrişimli katmanı, özellik haritalarının boyutunu azaltan ve giriş görüntüsü hakkında daha fazla küresel bilgi yakalamaya yardımcı olan bir maksimum havuzlama katmanı izler. Özellik haritalarının alt örnekleme, ağın giriş görüntüsünden üst düzey özellikleri öğrenmesini sağlar (Zeiler ve Fergus, 2014:818).

Kod çözücü ağı, kodlayıcı ağı tarafından çıkarılan özelliklere dayalı olarak bölümlere ayrılmış görüntüyü yeniden oluşturmak için tasarlanmıştır. Kod çözücü ağı, özellik haritalarının boyutunu artırmak için kullanılan birkaç üst örnekleme katmanından oluşur. Her üst örnekleme katmanını, özellik haritalarını iyileştirmek ve segmentasyon maskesini oluşturmak için kullanılan evrişimli bir katman izler (Ronneberger ve diğerleri, 2015:234).

UNet mimarisi, kodlayıcı ve kod çözücü ağlarına ek olarak, kodlayıcı ve kod çözücü ağlarındaki karşılık gelen katmanlar arasındaki atlama bağlantılarını da içerir. Bu atlama bağlantıları, kodlayıcı ağındaki özellik haritalarını, kod çözücü ağındaki karşılık gelen katmandaki özellik haritalarıyla birleştirmek için kullanılır. Bu, kod çözücü ağının hem düşük seviyeli hem de yüksek seviyeli özelliklere erişmesine izin vererek daha doğru segmentasyon sonuçları oluşturmaya yardımcı olabilir.

UNet'in mimarisi, benzer sayıda katmana sahip kodlayıcı ve kod çözücü ağları ile simetrik olacak şekilde tasarlanmıştır. Ağın ortası, en az sayıda özellik haritasına sahip olan bir darboğaz katmanıdır. Bu darboğaz katmanı, ağdaki parametre sayısını azaltmaya ve fazla uydurmayı önlemeye yardımcı olur.

Genel olarak, UNet mimarisi, giriş görüntüsünden özellikleri çıkarmak, doğru segmentasyon maskeleri oluşturmak ve ağ genelinde uzamsal bilgileri korumak için tasarlanmıştır. Etkinliği, özellikle tıbbi görüntüleme alanında olmak üzere çeşitli görüntü bölümlendirme görevlerinde kanıtlanmıştır.

5.2 Rastgele Orman Algoritması

Rastgele Orman Algoritması (ROA), hem sınıflandırma hem de regresyon görevleri için kullanılan popüler bir makine öğrenimi algoritmasıdır. Tahminin genel doğruluğunu ve sağlamlığını geliştirmek için birden fazla modeli birleştiren topluluk öğrenme yöntemleri ailesine aittir. Bir Rastgele Ormanda, çok sayıda karar ağacı oluşturulur ve tüm ağaçların toplu sonuçlarına dayalı olarak nihai tahmin yapılır (Breiman, 2001:5, Cutler ve diğerleri, 2007:157, Liaw ve Wiener, 2002:18).

Rastgele Orman Algoritmasında yer alan temel adımlar aşağıdaki gibidir:

Veri hazırlama: Giriş verileri, algoritmada kullanıma uygun olduğundan emin olmak için önceden işlenir. Bu, normalleştirme, özellik seçimi ve eksik değerlerin işlenmesi gibi görevleri içerebilir.

Özelliklerin rastgele seçimi: Oluşturulan her ağaç için, mevcut özelliklerin rastgele bir alt kümesi seçilir. Bu, aşırı uyumu önlemeye yardımcı olur ve her ağacın farklı olmasını sağlar.

Karar ağaçlarının oluşturulması: Özyinelemeli bir bölümlendirme işlemi kullanılarak her özellik alt kümesi için bir karar ağacı oluşturulur. Algoritma her adımda, bilgi kazancına veya Gini safsızlık kriterine göre en iyi ayrımı seçer.

Tahminlerin toplanması: Tüm karar ağaçları oluşturulduktan sonra, tüm ağaçların tahminleri toplanarak nihai tahmin yapılır. Sınıflandırma görevleri için bu,

çoğunluk oyu kullanmayı içerebilirken, gerileme görevleri için tahmin edilen değerlerin ortalamasını veya ortancasını almayı içerebilir.

Rastgele Orman Algoritmasının en önemli avantajlarından biri, yüksek boyutlu verileri ve değişkenler arasındaki doğrusal olmayan ilişkileri işleme yeteneğidir. Ayrıca girdi verilerindeki gürültü ve aykırı değerlere karşı dayanıklıdır ve bu da onu gerçek dünya uygulamaları için çok uygun hale getirir.

Genel olarak, hem sınıflandırma hem de regresyon görevleri için güçlü ve yaygın olarak kullanılan bir yöntemdir. Doğru ve güvenilir tahminler üretmek için çoklu karar ağaçlarının güçlü yönlerini birleştirir ve finans, sağlık ve doğal dil işleme gibi alanlarda yaygın olarak kullanılır.

Rastgele ormanlar, birçok veri kümesi için yüksek doğruluk sağlar. Çok sayıda özelliğe sahip verileri, özelliğin zayıf olduğu yerlerde az bilgi ile işleyebilirler. Karışık değişken türleri, eksik veriler, aykırı değerler için sağlam ve hızlıdır (Breiman, 2001: 5, Breiman ve Cutler, bt). Belirli bir etiketleme için oy sağlayan karar ağaçlarından oluşur. Çok sayıda ağacın ormanda rasgele birleştirilmesi güvenilir sonuçlar verebilirken, tek bir ağaç verilere gereğinden fazla uyum sağlayabilir (Borra ve Suykens, 2018:52085, Liang ve diğerleri, 2020:1912).

Ormandaki her ağaç, her girişi kendi sınıf etiketine ve oylarına atar. Hızlıdır ve gürültüye duyarlıdır ve verilerdeki doğrusal olmayan kalıpları algılayabilir. Sayısal ve kategorik verileri kolaylıkla işleyebilir (Titapiccolo ve diğerleri, 2013:4679). Fazla takılma sorunu bulunmamaktadır.

5.2.1 Rastgele Orman Algoritması Mimarisi

Rastgele Orman Algoritmasının mimarisi, her biri girdi özelliklerinin ve eğitim verilerinin farklı bir alt kümesinde eğitilen bir karar ağaçları topluluğuna dayanır. Algoritma aşağıdaki adımlarda ilerler:

Rastgele örnekleme: Algoritmanın her yinelemesinde, değiştirilerek girdi verilerinin rastgele bir örneği seçilir. Bu örnek, önyükleme örneği olarak bilinir ve bir karar ağacını eğitmek için kullanılır.

Özellik seçimi: Karar ağacının her düğümünde, girdi özelliklerinin rastgele bir alt kümesi seçilir ve verileri Gini safsızlığı veya bilgi kazancı gibi bir kritere göre bölmek için en iyi özellik seçilir.

Ağaç yapısı: Karar ağacı, seçilen özelliğe dayalı olarak her bir düğümdeki verileri bölerek yinelemeli olarak oluşturulur. İşlem, maksimum ağaç derinliğine veya yaprak başına minimum numune sayısına ulaşmak gibi bir durdurma kriteri karşılanana kadar devam eder.

Toplu öğrenme: Bir dizi karar ağacı eğitildikten sonra, her ağacın tahminleri nihai bir tahmin oluşturmak için toplanır. Regresyon görevleri için, nihai tahmin, tüm ağaçların tahminlerinin ortalaması veya medyanı olabilirken, sınıflandırma görevleri için nihai tahmin, mod veya çoğunluk oyu olabilir.

ROA'nın en önemli avantajlarından biri, hem kategorik hem de sürekli girdi özelliklerini işleyebilmesi ve eksik verileri ve aykırı değerleri otomatik olarak işleyebilmesidir. Rastgele özellik seçimi ve örnekleme, ağaçlar arasındaki korelasyonu azaltmaya ve genelleme yeteneklerini geliştirmeye yardımcı olduğundan, fazla uydurmaya karşı da dirençlidir (Çetin ve Öztürk, 2018:138).

Genel olarak, algoritmanın mimarisi, girdi verilerinin ve özelliklerinin farklı alt kümelerinde eğitilen ve doğru ve sağlam bir tahmin üretmek için birleştirilen bir karar ağaçları topluluğuna dayanır.

Yukarıda açıklanan adımlara ek olarak, Rastgele Orman algoritmasının mimarisinin etkinliğine katkıda bulunan birkaç başka önemli yönü daha vardır:

Hiperparametre ayarı: Rastgele Orman algoritmasının performansı, ağaç sayısı, her ağacın maksimum derinliği ve her bölmede dikkate alınması gereken özellik sayısı gibi bir dizi hiperparametreye bağlıdır. Bu hiperparametreler, belirli bir görevde algoritmanın performansını optimize etmek için çapraz doğrulama gibi teknikler kullanılarak ayarlanabilir.

Torba dışı hata tahmini: Rastgele Ormandaki her ağaç, verilerin farklı bir önyükleme örneği üzerinde eğitildiğinden, eğitime dahil edilmemiş örnekleri kullanarak algoritmanın görünmeyen veriler üzerindeki performansını tahmin etmek

mümkündür. Her ağacın, çantanın dışında, hata tahmini olarak bilinir ve ayrı bir doğrulama setine ihtiyaç duymadan Rastgele Ormanın doğruluğunu değerlendirmek için kullanılabilir.

Özelliğin önemi: Tahminlerde bulunmak için her girdi özelliğinin önemini tahmin etmek için de kullanılabilir. Bu, belirli bir özellik ağaç oluşturma sürecinden çıkarıldığında Gini kirliliğindeki azalma veya bilgi kazancı ölçülerek yapılır.

Algoritma mimarisinin bu yönleri, çok çeşitli makine öğrenimi görevleri için doğru ve sağlam tahminler üretme yeteneğine katkıda bulunur. Algoritma, görüntü sınıflandırma, doğal dil işleme ve tahmine dayalı analitik dahil olmak üzere çeşitli uygulamalarda başarıyla kullanılmıştır.

5.2.1.1 Rastgele Orman Algoritması Rastgele Süreklilik

Bu algoritmanın rastgele sürekliliği, karar ağacı oluşturulurken kullanılan özelliklerin rastgele seçilmesi ve kullanılması anlamına gelir.

Rastgele süreklilik, her bir ağaç için özellik seçiminin rastgele yapılmasını sağlar. Bu, her bir ağacın farklı bir özellik kümesiyle oluşturulmasına neden olur. Özellik seçimi, özelliklerin önem sıralamasına göre yapılır. Bu sayede, özellikler arasındaki korelasyonları azaltarak daha iyi bir performans elde edilir.

Rastgele süreklilik, ayrıca modelin aşırı öğrenme yapmasını engeller. Eğer aynı özellikler sürekli olarak seçilirse, model özellikler arasındaki korelasyonları öğrenir ve bu da aşırı öğrenmeye neden olabilir. Ancak, rastgele süreklilik kullanılarak, her bir ağaç farklı bir özellik kümesiyle oluşturulduğundan, modelin daha iyi genelleme yapması sağlanır.

Rastgele Orman Algoritması'nda, her bir ağaç rastgele seçilen özelliklerin bir alt kümesini kullanarak oluşturulur. Bu süreç, özellikler arasındaki korelasyonları azaltarak ve aşırı öğrenmeyi önleyerek daha iyi bir model performansı sağlar. Bu nedenle, rastgele süreklilik, Rastgele Orman Algoritması'nın en önemli özelliklerinden biridir.

5.2.1.2 Rastgele Orman Algoritması Özellik Seçimi

Özellik seçiminde iki farklı yöntem kullanır: rastgele özellik seçimi ve özellik önem sıralamasına göre özellik seçimi.

Rastgele özellik seçimi yöntemi, her bir ağaç için rastgele özelliklerin bir alt kümesini seçer ve bu özellikler üzerinden ağaç oluşturur. Bu yöntem, özellikler arasındaki korelasyonu azaltarak ağaçların çeşitliliğini artırır. Ancak, bazen önemli özelliklerin seçilmemesine neden olabilir.

Özellik önem sıralamasına göre özellik seçimi ise, özelliklerin sınıflandırma veya regresyon probleminin çözümüne katkısına göre sıralanmasını kullanır. Bu yöntem, en önemli özelliklerin seçilmesini sağlar ve modelin performansını artırır. Ancak, özellikler arasındaki korelasyonları dikkate almaz ve bazı önemli özelliklerin gözden kaçmasına neden olabilir.

Rastgele Orman Algoritması, her ağacın rastgele seçilen özelliklerin bir alt kümesi üzerinden oluşturulmasını sağlayarak özellikler arasındaki korelasyonu azaltır ve aşırı uyum sorununu önler. Ayrıca, rastgele özellik seçimi ve özellik önem sıralamasına göre özellik seçimi yöntemlerini kullanarak, en iyi performansı elde etmek için uygun özellikleri seçer.

5.2.1.3 Rastgele Orman Algoritması Ağaç Yapısı

Her bir ağaç, özelliklerin rastgele seçildiği ve her bir düğümde en iyi özelliklerin kullanıldığı bir karar ağacıdır.

Her bir ağaç, sınıflandırma problemleri için yaprak düğümlerinde sınıf etiketleri ve regresyon problemleri için sayısal tahminler üretir. Ağaç yapısında, her düğüm bir özellik değerlendirmesi yapar ve buna göre iki alt düğüme ayrılır. Özellik değerlendirmesi, düğümün sahip olduğu veri kümesindeki özelliklerin değerlerinin karşılaştırılması yoluyla yapılır. Her bir alt düğüm, aynı özelliklerin kullanıldığı ancak farklı bir alt kümesine sahip veri noktalarını içerir.

Algoritma, ağaçların çeşitliliğini arttırmak için Bootstrap yöntemi kullanarak rastgele örneklem alma yapar. Bu yöntem, veri kümesinden rastgele örnekler alarak

ağaçların farklı veri örnekleri üzerinde eğitilmesini sağlar. Ayrıca, ağaçların rastgele özelliklerin bir alt kümesi üzerinde eğitilmesi de ağaçların çeşitliliğini artırır.

Rastgele Orman Algoritması, birden fazla karar ağacının bir araya gelmesiyle oluşan bir ansambl'dir. Her bir ağaç, rastgele özelliklerin bir alt kümesi üzerinde ve farklı veri örnekleri üzerinde eğitilir. Ağaçlar, sınıflandırma problemleri için yaprak düğümlerinde sınıf etiketleri ve regresyon problemleri için sayısal tahminler üretir.

5.2.1.4 Rastgele Orman Algoritması Toplu Öğrenme

Toplu öğrenme, birden fazla öğrenme modelinin bir araya gelerek bir sorunu çözmek için birlikte çalıştığı bir öğrenme yöntemidir. Rastgele Orman Algoritması, birden fazla karar ağacının bir araya gelerek bir sınıflandırma veya regresyon problemi çözmek için birlikte çalıştığı bir toplu öğrenme yöntemidir.

Toplu öğrenme, bir sorunun çözümünde tek bir öğrenme modelinden daha iyi sonuçlar verebilir ve toplu öğrenmenin avantajlarından yararlanarak, birden fazla karar ağacının bir araya gelerek daha iyi bir sınıflandırma veya regresyon modeli oluşturmasını sağlar.

Birden fazla karar ağacının eş zamanlı olarak eğitilmesiyle oluşur. Her bir ağaç, özellikleri rastgele seçilen ve rastgele örneklerden oluşan bir alt kümede eğitilir. Bu sayede ağaçlar, farklı özellikler üzerinde ve farklı veri örnekleri üzerinde eğitilir. Bu, ağaçların çeşitliliğini artırır ve modelin genellemesini iyileştirir.

Toplu öğrenme yöntemleri genellikle tek bir öğrenme modelinden daha iyi sonuçlar verirken, eğitim süreleri daha uzun olabilir. Ancak, Rastgele Orman Algoritması, paralel işlem yapabilme özelliği sayesinde eğitim süresini azaltır. Bu sayede Rastgele Orman Algoritması, büyük veri setleri üzerinde de etkili bir şekilde kullanılabilir.

5.2.1.5 Hiperparametre Ayarı

Rastgele Orman Algoritması, birçok hiperparametreye sahip olduğu için, bu parametreleri uygun bir şekilde ayarlamak, modelin başarısını ve performansını artırmak için önemlidir.

Hiperparametreler, modelin yapılandırmasını ve nasıl eğitileceğini belirleyen parametrelerdir. Rastgele Orman Algoritması'nın en önemli hiperparametreleri arasında ağaç sayısı, özellik sayısı, örneklem sayısı ve düğüm derinliği yer alır.

Ağaç sayısı: ROA'da kaç tane ağacın kullanılacağı belirlenir. Daha fazla ağaç kullanmak, modelin doğruluğunu artırabilir, ancak aynı zamanda eğitim süresini de uzatabilir. Ağaç sayısı, genellikle çapraz doğrulama yöntemi ile belirlenir.

Özellik sayısı: Her bir ağaç için kullanılacak özellik sayısı belirlenir. Bu sayı, veri kümesindeki toplam özellik sayısından daha az olmalıdır. Özellik sayısı artırıldığında, ağaçlar arasındaki farklılıklar azalır ve modelin doğruluğu azalabilir.

Örneklem sayısı: Her bir ağaç için kullanılacak örneklem sayısı belirlenir. Bu sayı, veri kümesindeki toplam örnek sayısından daha az olmalıdır. Örneklem sayısı artırıldığında, modelin doğruluğu artabilir, ancak aynı zamanda eğitim süresi de artabilir.

Düğüm derinliği: Ağaçların maksimum düğüm derinliği belirlenir. Daha derin ağaçlar, daha fazla öğrenme kapasitesi ile birlikte daha fazla ezberleme eğilimi gösterir. Düğüm derinliği arttıkça, ağaçların daha fazla özelleştiği ve genelleştirme yeteneklerinin azaldığı gözlemlenebilir.

Hiperparametre ayarı, genellikle çapraz doğrulama yöntemi ile gerçekleştirilir. Bu yöntemde, veri kümesi birden fazla bölüme ayrılır ve her bir bölüm sırayla test verisi olarak kullanılırken diğer bölümler eğitim verisi olarak kullanılır. Bu sayede, farklı hiperparametre değerleri ile modeller eğitilir ve performansları ölçülerek en iyi hiperparametreler belirlenir.

5.2.1.6 Torba Dışı Hata

Rastgele Orman Algoritması'nın temelinde, birden fazla karar ağacının toplanması yatar. Her bir karar ağacı, öğrenme verilerinin farklı bir alt kümesi üzerinde eğitilir. Bu alt kümeler, verilerin yinelenen seçimleri ile oluşturulur. Bu yöntem, torbalama olarak bilinir.

Bir karar ağacı, bir alt kümedeki verileri kullanarak eğitildiği için, diğer alt kümelerden farklı bir görüşe sahip olabilir. Bu nedenle, bir alt kümedeki bir veri örneğinin tahmini, diğer alt kümelerdeki karar ağaçlarının tahminleri ile farklılık gösterebilir. Bu farklılık, torba dışı hatası olarak adlandırılır.

Torba dışı hata, Rastgele Orman Algoritması'nın bir performans ölçütüdür. Daha düşük torba dışı hatası, algoritmanın daha yüksek doğruluk sağladığı anlamına gelir. Bu nedenle, Rastgele Orman Algoritması'nın hiperparametreleri, torba dışı hatasını minimize etmek için ayarlanır.

5.3 Kernel Destek Vektor Makineleri

Kernel DVM (Destek Vektor Makineleri), sınıflandırma problemleri için kullanılan bir makine öğrenmesi algoritmasıdır. DVM, bir hipotez sınıflandırıcısını (bir doğru veya eğri) bulmak için kullanılan bir öğrenme algoritmasıdır.

Sınıflandırma problemlerini çözmek için doğrusal olmayan bir yöntemdir. Doğrusal bir yöntem olan geleneksel DVM'den farklı olarak, verileri bir doğru veya eğri ile sınıflandırmak yerine, daha karmaşık karar sınırlarını modellemek için çekirdek işlevlerini kullanır.

Çekirdek işlevleri, verilerin yüksek boyutlu uzayda gösterilmesine izin verir ve böylece doğrusal olarak ayrılabilir olmayan verilerin de sınıflandırılmasına olanak tanır. Kernel DVM, genellikle doğrusal olmayan veriler için daha iyi sonuçlar verir.

Ana avantajlarından biri, overfitting riskini azaltmak için kullanılan C ve gamma parametrelerinin ayarlanabilmesidir. C parametresi, DVM'nin yanlış sınıflandırma hatalarına ne kadar tolerans göstereceğini belirlerken, gamma parametresi, çekirdek işlevinin esnekliğini kontrol eder.

Sınıflandırma problemlerinde başarılı sonuçlar veren bir algoritma olmasına rağmen, yüksek boyutlu verilerde hesaplama gücü açısından zorlayıcı olabilir. Bu nedenle, verilerin boyutunu azaltmak için boyut azaltma teknikleri veya rastgele özellik seçimi gibi yöntemler kullanılabilir.

Kernel DVM, tıbbi görüntülemelerde sınıflandırma problemlerini çözmek için kullanılabilir. Örneğin, kanser tespiti gibi bir sınıflandırma problemi, kernel DVM ile çözülebilir.

Kernel DVM'nin tıbbi görüntülemelerde kullanımı, genellikle bir özellik vektörü oluşturarak başlar. Bu vektör, görüntüden çıkarılan özelliklerin bir listesidir. Özellikler, görüntünün parlaklık, kontrast, kenarlar ve diğer özelliklerine dayalı olarak hesaplanabilir.

Daha sonra, özellik vektörleri eğitim ve test veri setleri olarak ayrılır. Eğitim veri seti, DVM modelinin öğrenmesi için kullanılırken, test veri seti, modelin performansının değerlendirilmesi için kullanılır.

Eğitim veri setindeki özellik vektörlerini kullanarak bir sınıflandırma modeli oluşturur. Bu model, test veri setindeki özellik vektörlerini kullanarak sınıflandırma yapar.

Tıbbi görüntülemelerde, kanser tespiti ve benzeri sınıflandırma problemleri için kullanılabilir. Özellikle, tıbbi görüntülerdeki anormallikleri tespit etmek için kullanılabilir. Örneğin, bir meme kanseri taraması sırasında alınan mamografi görüntüleri, kernel SVM ile sınıflandırılabilir ve kanserli bölgeler tespit edilebilir.

Tıbbi görüntülemelerde kullanımı, doğru özellik seçimi ve DVM parametrelerinin doğru ayarlanması gerektirdiği için uzmanlık gerektirir. Ayrıca, özellik vektörleri genellikle büyük olduğundan, hesaplama gücü açısından zorlayıcı olabilir. Bu nedenle, verilerin boyutunu azaltmak için boyut azaltma teknikleri veya rastgele özellik seçimi gibi yöntemler kullanılabilir.

5.3.1 Kernel Destek Vektor Makineleri Mimarisi

Kernel DVM, çeşitli sınıflar arasında ayırım yapmak için kullanılan bir sınıflandırma algoritmasıdır. Temel olarak, sınıflandırma problemi, verilerin bir uzayda belirli sınıflara ayrılmasıdır. Ancak, veriler doğrusal olarak ayrılamadığında devreye girer.

Mimarisi, öncelikle eğitim verilerinin belirli bir özellik uzayına göre temsil edilmesi ile başlar. Bu özellik uzayı, verilerin sınıflara göre ayrılmasını kolaylaştıracak şekilde seçilir.

Daha sonra, bu özellik uzayında bir hipers düzlem oluşturur, böylece farklı sınıfların veri noktaları arasında bir boşluk bırakır. DVM, bu boşluğun maksimum olduğu yerde bir karar sınırı oluşturur ve böylece farklı sınıfları ayırmak için bir yöntem sağlar.

Ancak, veriler doğrusal olarak ayıramadığında, kernel fonksiyonları kullanılır. Bu fonksiyonlar, verileri yüksek boyutlu bir özellik uzayına yansıtır, böylece veriler doğrusal olarak ayrılabilir hale gelir. Kernel fonksiyonları, polinomiye, Gauss, sigmoid vb. gibi çeşitli şekillerde tanımlanabilir.

Eğitim verilerinin özellik uzayında bir hipers düzlem oluşturur ve test verilerini bu hipers düzleme yansıtır. Test verileri, hipers düzlemin hangi tarafında yer alırsa, o sınıfa ait olarak sınıflandırılır.

Kernel DVM'nin mimarisi, doğru kernel fonksiyonunun ve parametrelerinin seçilmesi ile ilgilidir. Bu nedenle, birçok farklı kernel fonksiyonu ve parametrelerin denendiği hiperparametre optimizasyonu gerektirir.

5.4 Lojistik Regresyon

Lojistik regresyon (LR), sınıflandırma problemleri için kullanılan bir makine öğrenimi algoritmasıdır. Özellikle, girdi verilerinin (bağımsız değişkenler) bir sınıfa ait olup olmadığını (bağımlı değişken) tahmin etmek için kullanılır.

Lineer regresyon yöntemine dayanır, ancak lineer regresyondan farklı olarak çıktı değeri sürekli değil, kategoriktir ve girdi verilerinin lineer bir kombinasyonunu hesaplar ve bu kombinasyonu belirli bir fonksiyona (sigmoid fonksiyonu olarak adlandırılır) sokar. Bu işlem sonucunda, bir olasılık değeri elde edilir ve bu değer, girdi verilerinin sınıfa ait olma olasılığını temsil eder.

Amacı, verilerin belirli bir sınıfa ait olma olasılığını en iyi şekilde tahmin etmek için optimal parametreleri bulmaktır. Bu parametreler, girdi verilerinin lineer

kombinasyonunu hesaplarırken kullanılan katsayılardır. Verilerin etiketleri ile gerçekleştirilen eğitim verileri üzerinde öğrenir ve ardından test verilerinin sınıflandırmasını yapar.

Ayrıca bu algoritma sınıflandırma problemlerinde kullanılan birçok algoritmadan biridir. Bu algoritma, bağımsız değişkenler ve bağımlı değişken arasındaki ilişkiyi modellemek için kullanılır. Bağımsız değişkenlerin değerleri, bağımlı değişkenin hangi sınıfa ait olacağını belirler.

Bir tür doğrusal sınıflandırma algoritması da denebilir. Girdi verileri (bağımsız değişkenler) üzerinde hesaplama yapar ve sonuç olarak sınıflara ait olma olasılıklarını tahmin eder. Bu olasılıklar, sigmoid fonksiyonu adı verilen bir fonksiyondan geçirilerek elde edilir. Sigmoid fonksiyonu, çıktı değerinin 0 ile 1 arasında kalmasını sağlar ve bu değerler, sınıflara ait olma olasılıklarını temsil eder.

LR, eğitim verileri üzerinde çalışır ve sınıflar arasındaki ayrımı en iyi şekilde yapabilmek için optimal parametreleri öğrenir. Bu parametreler, girdi verilerinin lineer kombinasyonunu hesaplarırken kullanılan katsayılardır. Lojistik regresyon, sınıflar arasındaki sınırın doğrusal olmadığı durumlarda da kullanılabilir. Bu durumda yöntem, girdi verilerinin bazı işlevleri (örneğin, polinomlar) kullanılarak dönüştürülmesi yoluyla uyarlanabilir.

Algoritma, sınıflandırma problemleri için yaygın bir algoritma olmasının yanı sıra, tıbbi araştırmalardan finansal tahminlere kadar çeşitli uygulama alanlarına sahiptir. Örneğin, kanser teşhisinde kullanılan tıbbi verilerin sınıflandırılması gibi önemli bir tıbbi uygulama alanı vardır.

5.4.1 Lojistik Regresyon Mimarisi

Lojistik regresyon, makine öğrenmesi ve istatistikte sınıflandırma problemleri için kullanılan bir modeldir. Özellikle ikili sınıflandırma (binary classification) problemlerinde yaygın olarak kullanılır. Örneğin, bir tıbbi teşhis sistemi, bir hastalığın olup olmadığını belirlemek için lojistik regresyon kullanabilir.

Temel amacı, bağımsız değişkenler (x) ile bir bağımlı değişken (y) arasındaki ilişkiyi modellerlemektir. Bağımlı değişken (y), iki olası değere sahiptir (örneğin,

hasta veya sağlıklı gibi): 1 ve 0. Bu nedenle, lojistik regresyonunun çıktısı, bir olasılık değeri (0 ile 1 arasında) veya bir sınıf tahmini olacaktır.

Matematiksel formülasyonu, sigmoid fonksiyonu ile tanımlanır. Sigmoid fonksiyonu, bir sayıyı 0 ile 1 arasında bir değere dönüştürür. Bu değer, bir olasılık değeri olarak yorumlanabilir. Lojistik regresyonun temel hedefi, verilen girdileri (x) kullanarak bağımlı değişkenin (y) olasılık değerini hesaplamaktır.


Mimarisi, girdileri (x) alarak bir ağırlık matrisi ile çarpım yapar. Bu çarpım sonucu, bir aktivasyon fonksiyonuna (genellikle sigmoid fonksiyonuna) uygulanır. Bu, tahmin edilen sınıfın olasılık değerini üretir.

Lojistik regresyonun eğitimi, en uygun ağırlık değerlerini bulmak için gerçek etiket değerleri (y) ile tahmin edilen değerler arasındaki farkı minimize etmeye çalışır. Bu, bir kayıp fonksiyonu kullanılarak yapılır. En yaygın kullanılan kayıp fonksiyonu, çapraz-entropi kaybıdır. Bu kayıp fonksiyonu, doğru sınıf tahminlerinin olasılık değerleri ile gerçek sınıf etiketlerinin kullanımını hesaba katar.


6 ARAŞTIRMA VE TARTIŞMA

Bu çalışmada kullanılan algoritmalar ve hesaplamalar PYTHON ortamında yapılmıştır. UNET ve Random Forest Algoritmaları kullanılarak BT karın görüntülerinde böbrek kistleri araştırıldı.

UNET ile python ortamında semantik bölütleme yapılmıştır. Sadece böbrek ve böbrek kistleri üzerinde durulduğu için sistemi yormamak ve hızlı sonuç alabilmek için semantik bölütleme yapılmıştır. Eşleme için giriş maskeleme örnekleri Şekil 6-1 ve Şekil 6-2' de gösterilmiştir.




Şekil 6.1 Eşleme için giriş maskeleme örneği-1




Şekil 6.2 Eşleme için giriş maskeleme örneği-2

Semantik bölütleme sonucunda elde edilen görüntüler aşağıda Şekil 6-3 ve Şekil 6-4'de paylaşılmıştır.




Şekil 6.3 Semantik Bölütleme -1



Şekil 6.4 Semantik Bölütleme -2

Böbrek kisti tespiti için elde edilen maskeleme sonucunun örnek çıktıları Şekil 6-5'de gösterilmektedir.



Şekil 6.5 Böbrek Kisti İçin Maskeleme Sonucu

UNET ile yapılan çalışmanın ekran çıktısı Şekil 6-6’da görülmektedir.

	precision	recall	f1-score
0.0	0.56	1.00	0.72
1.0	1.00	0.87	0.93
accuracy			0.89
macro avg	0.78	0.93	0.83
weighted avg	0.94	0.89	0.90
Confusion Matrix:			
[[35 0]			
[27 180]]			
Accuracy: 0.888430			

Şekil 6.6 UNET Sonuçları

Doğruluk değeri, modeldeki doğru tahmin edilen alanların toplam veri setine oranıdır.

Doğruluk, bir sınıflandırma modelinin girdileri kendi kategorilerinde doğru bir şekilde sınıflandırma yeteneğini değerlendirmek için derin öğrenme ve makine öğreniminde yaygın olarak kullanılan bir performans ölçüsüdür. Spesifik olarak,

doğruluk, pozitif veya negatif olup olmamalarına bakılmaksızın, model tarafından yapılan doğru olan tüm tahminlerin yüzdesini ölçer.

Girdileri iki kategoriden birine sınıflandırmak için bir modelin eğitildiği ikili sınıflandırmada, doğruluk şu şekilde hesaplanabilir:

$$\text{Doğruluk} = (\text{Gerçek Pozitifler} + \text{Gerçek Negatifler}) / (\text{Gerçek Pozitifler} + \text{Yanlış Pozitifler} + \text{Gerçek Negatifler} + \text{Yanlış Negatifler})$$

Gerçek Pozitifler, modelin doğru bir şekilde pozitif olarak tanımladığı gerçek pozitif vakaların sayısıdır, Gerçek Negatifler, modelin doğru şekilde negatif olarak tanımladığı gerçek negatif vakaların sayısıdır, Yanlış Pozitifler, modelin yanlış olarak tanımladığı gerçek negatif vakaların sayısıdır. pozitif ve Yanlış Negatifler, modelin yanlışlıkla negatif olarak tanımladığı gerçek pozitif vakaların sayısıdır.

Yüksek bir doğruluk, modelin girdileri ilgili kategorilerine doğru bir şekilde sınıflandırmada etkili olduğunu gösterir. Ancak, özellikle veri kümesi dengesiz olduğunda veya yanlış pozitif ve yanlış negatiflerin maliyeti eşit olmadığında, doğruluk tek başına her durumda kullanılacak en iyi performans ölçütü olmayabilir. Bu gibi durumlarda, kesinlik, hatırlama ve F1 puanı gibi diğer performans ölçütleri, modelin performansının daha dengeli bir şekilde değerlendirilmesini sağlayabilir.

Genel olarak doğruluk, özellikle veri kümesi dengeli olduğunda ve yanlış pozitif ve yanlış negatiflerin maliyeti eşit olduğunda, derin öğrenmede sınıflandırma modellerinin performansını değerlendirmek için yararlı bir ölçümdür. Araştırmacıların ve uygulayıcıların modellerinin etkinliğini belirlemelerine yardımcı olabilecek, modelin girdileri ilgili kategorilerinde doğru bir şekilde sınıflandırma yeteneğinin basit ve sezgisel bir ölçüsünü sağlar.

Bir modelin başarısını ölçmek için yaygın olarak kullanılan ancak yeterli olmayan bir değerdir. Böyle bir durumda kistlerin ve teşhis edilmemiş verilerin olması istenmez. Bu nedenle diğer değerler de değerlendirilmelidir. Bu değerler F1 puanı, kesinlik ve hatırlamadır.

Geri çağırma, pozitif olarak tahmin edilmesi gereken işlemlerden ne kadarının pozitif olarak tahmin edildiğinin değeridir. Kist olmadığı düşünölen ancak içinde kist bulunan veriler de tahminde yardımcı olur. Ne kadar yüksekse o kadar sağlıklıdır.

Geri çağırma, bir sınıflandırma modelinin pozitif vakaları doğru bir şekilde belirleme yeteneğini değerlendirmek için derin öğrenme ve makine öğreniminde kullanılan bir performans ölçümüdür. Hatırlama özellikle, tüm gerçek pozitif vakalar arasından model tarafından doğru bir şekilde tanımlanan gerçek pozitif vakaların yüzdesini ölçer.

Girdileri iki kategoriden birine sınıflandırmak için bir modelin eğitildiğı ikili sınıflandırmada, hatırlama şu şekilde hesaplanabilir:

$$\text{Hatırlama} = \frac{\text{Gerçek Pozitifler}}{(\text{Gerçek Pozitifler} + \text{Yanlış Negatifler})}$$
 (İşeri ve Yıldız, 2019:61).

burada Gerçek Pozitifler, modelin doğru bir şekilde pozitif olarak tanımladığı gerçek pozitif vakaların sayısıdır ve Yanlış Negatifler, modelin yanlışlıkla negatif olarak tanımladığı gerçek pozitif vakaların sayısıdır.

Yüksek hatırlama, modelin pozitif vakaları belirlemede ve yanlış negatifleri en aza indirmede etkili olduğunu gösterir. Örneğın, bir tıbbi teşhis görevinde yüksek hatırlama, modelin belirli bir durumu olan hastaları doğru bir şekilde tanımlamada iyi olduğu anlamına gelir, bu bazı sağlıklı hastaların da pozitif olarak tanımlandığı anlamına gelse bile (yani, bazı yanlış pozitifler kabul edilir).

Bununla birlikte, yüksek bir geri çağırma, modelin çok fazla yanlış pozitif kabul ettiğı (yani, bazı sağlıklı hastaları yanlışlıkla pozitif olarak tanımladığı) anlamına da gelebilir ve bu da tüm pozitifler arasında gerçek pozitif vakaların oranını değerlendiren başka bir performans ölçütü olan düşük kesinliğe yol açar. model tarafından yapılan tahminler. Bu nedenle, derin öğrenmede bir sınıflandırma modelinin performansını değerlendirirken hem hatırlama hem de kesinlik dikkate alınmalıdır.

Kesinlik, pozitif olarak tahmin edilen değerlerden kaçının gerçekten pozitif olduğunu gösterir. Yanlış pozitif tahminin maliyetinin yüksek olduğu durumlarda

önemlidir. Model anomalili böbreği anomali değil olarak işaretlerse yanlış pozitif olacaktır. Bir kayıp verme sürecidir ve yüksek değer algoritma seçiminde önemlidir.

Derin öğrenmede kesinlik, tüm pozitif tahminler içinde gerçek pozitif tahminlerin oranını tahmin eden bir sınıflandırma modelinin doğruluğunun bir ölçüsüdür. Başka bir deyişle, modelin pozitif sınıfı ne kadar doğru tanımladığını ölçer.

Kesinlik, gerçek pozitiflerin sayısının (yani doğru tanımlanmış pozitif örneklerin sayısı), hem doğru pozitifleri hem de yanlış pozitifleri içeren model tarafından yapılan pozitif tahminlerin toplam sayısına bölünmesiyle hesaplanır.

Kesinlik matematiksel olarak şu şekilde ifade edilebilir:

$$\text{Kesinlik} = \text{Gerçek Pozitifler} / (\text{Gerçek Pozitifler} + \text{Yanlış Pozitifler}) \text{ (İşeri ve Yıldız, 2019:61).}$$

Yüksek bir kesinlik değeri, modelin pozitif durumları tahmin etmede çok iyi olduğunu ve yanlış pozitif oranının düşük olduğunu gösterir. Tersine, düşük bir kesinlik değeri, modelin pozitif örnekleri tahmin etmede iyi olmadığını ve yüksek bir yanlış pozitif oranına sahip olduğunu gösterir.

Bir derin öğrenme modelinin performansını değerlendirmek için kesinliğin tek başına yeterli bir ölçüm olmadığına dikkat etmek önemlidir. Modelin performansını daha kapsamlı bir şekilde anlamak için hatırlama, F1 puanı ve doğruluk gibi diğer değerlendirme ölçütleriyle birlikte kullanılmalıdır.

F1 puanı, kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. Ekstrem durumları göz ardı etmemek için harmonik ortalama kullanılır. Doğruluk yerine F1 puanının kullanılmasının en büyük sebebi eşit dağılmayan veri setlerinde yanlış bir algoritma seçilmemesidir. F1 puanı önemlidir, çünkü sadece yanlış negatif veya yanlış pozitif değil, aynı zamanda tüm hata değerlerini içeren bir değere ihtiyaç vardır.

F1 puanı, bir sınıflandırma modelinin performansını değerlendirmek için derin öğrenme ve makine öğreniminde yaygın olarak kullanılan bir ölçüdür. Hem kesinliği hem de hatırlamayı hesaba katan bir modelin doğruluğunun bir ölçüsüdür.

Kesinlik, model tarafından yapılan tüm pozitif tahminler içindeki doğru pozitif tahminlerin yüzdesidir, geri çağırma ise tüm gerçek pozitif vakalar içindeki doğru pozitif tahminlerin yüzdesidir. F1 puanı, kesinlik ve geri çağırmanın harmonik ortalamasıdır ve modelin performansının daha dengeli bir değerlendirmesini vermek için hem kesinliği hem de geri çağırmayı hesaba katar.


Derin öğrenmede, F1 puanı genellikle modellerin görüntü sınıflandırma, duyarlılık analizi ve metin sınıflandırma gibi görevlerdeki performansını değerlendirmek için kullanılır. Yararlı bir ölçümdür, çünkü hem modelin pozitif vakaları doğru bir şekilde tanımlama yeteneğini hem de yanlış pozitiflerden kaçınma kabiliyetini dikkate alır. Yüksek bir F1 puanı, yüksek hassasiyete ve yüksek hatırlamaya sahip bir modeli gösterir; bu, yanlış pozitifleri en aza indirirken pozitif vakaları doğru bir şekilde tanımlayabileceği anlamına gelir (Wu ve diğerleri, 2021:1493).

F1 puanı, 0 ile 1 arasında bir değerdir; burada 1 puanı mükemmel kesinliği ve hatırlamayı, 0 puanı ise kötü performansı temsil eder. F1 puanı 0,5 olan bir modelin orta düzeyde performansa sahip olduğu kabul edilirken, 0,7 veya daha yüksek bir puan genellikle iyi olarak kabul edilir (İşik ve Aydın, 2019:2873).

F1 puanının bir sınırlaması, yalnızca pozitif vakalara dayanmasıdır; bu, veri kümesi dengesiz olduğunda veya yanlış pozitif ve yanlış negatiflerin maliyeti eşit olmadığında kullanılacak en iyi metrik olmayabileceği anlamına gelir. Bu gibi durumlarda, alıcı çalışma karakteristik eğrisinin altındaki alan veya kesinlik-geri çağırma eğrisinin altındaki alan gibi diğer ölçütler daha uygun olabilir.

Genel olarak, F1 puanı, özellikle veri kümesi dengeli olduğunda ve yanlış pozitif ve yanlış negatiflerin maliyeti eşit olduğunda, derin öğrenmede sınıflandırma modellerinin performansını değerlendirmek için yararlı bir ölçümdür. Araştırmacıların ve uygulayıcıların modelleri için en uygun hiperparametreleri, mimarileri ve optimizasyon algoritmalarını belirlemelerine yardımcı olabilecek bir modelin kesinliği ve geri çağırmasının dengeli bir değerlendirmesini sağlar.

Çalışılan bir diğer algoritma olan ROA'nın sonuç çıktısı Şekil 6-7' de yer almaktadır. ROA sonucu %99,2 olmuştur.



Şekil 6.7 Rastgele Orman Algoritması Sonuçları


Kernel DVM için ekran çıktısı Şekil 6-8’de gösterilmiştir. DVM için doğruluk tahmini %98,11’dir.

```
In [63]: print("SVM Doğruluk Oranı:", metrics.accuracy_score(ytest, ypred))
...: print("SVM Tahmin Oranı:", metrics.precision_score(ytest, ypred))
...: print("SVM Tekrarlama Oranı:", metrics.recall_score(ytest, ypred))
SVM Doğruluk Oranı: 0.9649122807017544
SVM Tahmin Oranı: 0.9811320754716981
SVM Tekrarlama Oranı: 0.9629629629629629

In [64]:
```


Şekil 6.8 Kernel DVM Doğruluk Tahmini Oranı

Hataları yapılan yer değerlendirmeleri ve sınıflandırma sorunları için oluşan durum matrisi Şekil 6-9’da gösterilmiştir.



Şekil 6.9 Durum Matrisi

Şekil 6-10'da positif olarak çıktısı alınan böbrek kisti resmi gösterilmiştir.




Şekil 6.10 Pozitif Böbrek Kistleri

Lojistik Regresyon ekran çıktısı Şekil 6-11'de gösterilmiştir. Sonuç %96,49'dur. Homojen dağılım çıktıları Şekil 6-12'de gösterilmiştir.

```
...: acc = accuracy_score(y_test, y_pred)
...: print("Logistic Regression model accuracy (in %):", acc*100)
Logistic Regression model accuracy (in %): 96.49122807017544
In [78]:
```

Şekil 6.11 Lojistik Regresyon Doğruluk Oranı



Şekil 6.12 Lojistik Regresyon Homojen Dağılımı

7 SONUÇ

Bu çalışmada 65900 BT karın görüntüleri kullanıldı. Toplam görüntünün %80'i eğitim seti için ve %20'si test amaçlı kullanılmıştır. Görüntüler böbrek kisti ve böbreklere odaklandı.

Görüntü bölütleme, görüntü işlemenin en önemli konusu haline gelmiştir. İç anatomiye araştırmakla daha da fazla ilgilenen klinisyenler sayesinde tıbbi uygulamalarda çok önemli bir yere sahiptir (Saba ve diğerleri, 2012:2639). Kesitsel çekimler için bilgisayarlı tomografi gibi birçok uygulama geliştirilmektedir (Norouzi ve diğerleri, 2012:202, Maintz ve Viergever, 1998:1). Bu uygulamalar MRG ve BT gibi cihazlarda farklı çekim algoritmaları olarak karşımıza çıkıyor.

Makine öğrenimi çalışmalarında kistler ve tümörler araştırılır ve hem hasta hem de klinisyen tarafından vakit kaybetmeden tedaviye başlanabilir.

Literatür taramasında, böbrek tümörleri derin öğrenme algoritmaları kullanılarak araştırılmıştır (Turk, 2021). Ancak makine öğrenimi alanında böbrek kistleri ile ilgili bir çalışmaya rastlanmadı.

Bu çalışmada makine öğrenme algoritmaları olan UNET ve Rastgele Orman Algoritması kullanılarak böbrek kistleri üzerine bir araştırma yapılmıştır. UNET algoritmasında başarı oranı %92 iken Rastgele Orman Algoritması başarı oranı %99,2'dir. Kernel DVM ile başarı oranı %98,11 ve Lojistik Regresyon ile bu oran %96,49'dir.

BT sistemlerine algoritmalar entegre edilerek, MRG sistemlerinde kullanılan görüntü restorasyonu için derin öğrenme uygulamalarına ek olarak, bu algoritmalar böbreklerdeki kistleri tespit etmeye yönelik uygulamalar olarak cihazlara eklenebilir. Ayrıca iş istasyonlarına eklenebilir ve klinisyenlerin görüntüleri uzaktan incelemesine yardımcı olur. Piksel boyutunda bir çalışma olduğu için gözden kaçabilecek unsurlar bu çalışma sayesinde tespit edilebilmektedir.

8 KAYNAKLAR

- Priya, E., & Srinivasan, S. (2015). Automated Identification of Tuberculosis Objects in Digital Images Using Neural Network and Neuro Fuzzy Inference Systems. *Journal of Medical Imaging and Health Informatics*, 5, 506–512.
- Priya, E., Srinivasan, S. & Ramakrishnan, S. (2014). Retrospective Non-Uniform Illumination Correction Techniques in Microscopic Digital TB Images. *Microscopy and Microanalysis*, 20(5), 1382–1391.
- Akay, B. (2013). A Study on Particle Swarm Optimization and Artificial Bee Colony Algorithms for Multilevel Thresholding. *Applied Soft Computing Journal*, 13(6), 3066–3091.
- Çalışkan, A., & Türker, M. (2016). Anomali Bölgelerinin Görüntülerden Çıkarılması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 4(2), 126-133
- Liu, S., Cai, W., Pujol, S., Kikinis, R., Feng, D.(2014). Early Diagnosis of Alzheimer's Disease with Deep Learning. In Biomedical Imaging (ISBI), *IEEE 11th International Symposium*. 1015-1018.
- Wang, G., Li, W., Zuluaga, M. A., Pratt, R., Patel, P. A., Aertsen, M., Vercauteren, T.(2018) Interactive Medical Image Segmentation Using Deep Learning with Image-Specific Fine-Tuning. *IEEE Transactions on Medical Imaging*, 37 (7), 1562-1573.
- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., & Adeli, H.(2018). Deep Convolutional Neural Network for the Automated Detection and Diagnosis of Seizure Using EEG Signals. *Computers in Biology and Medicine*, 100, 270-278
- Larie SM, Abukmeil SS.(1998). Brain Abnormality in Schizophrenia: A Systematic and Quantitative Review of Volumetric Magnetic Resonance Imaging Studies. *J. Psychol.* 172:110–20
- Gonzalez, R. C., Woods, R. E. (2008). Digital image processing (3rd ed.). Pearson Education, 3
- Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A., Greer, T. Zuiderveld, K. (1987). Adaptive Histogram Equalization and Its Variations. *Computer Vision, Graphics, and Image Processing*, 39(3), 355-368.
- Gordillo, N., Montseny, E., Sobrevilla, P. (2013). State of the Art Survey on MRI Brain Tumor Segmentation. *Magnetic Resonance Imaging*, 31(8), 1426-1438.
- Li, H., Yan, J., Chen, Z. (2018). Otsu Thresholding-Based Medical Image Segmentation Using Electromagnetic-like Mechanism Optimization. *Information Sciences*, 459, 223-240.

Yen, J. C., Chang, F. J. (1995). Adaptive Thresholding Using the Integral Image. *Journal of Pattern Recognition*, 28(10), 1657-1664.

Krishnaveni, V., Sivanandam, S. N. (2012). A Novel Approach for Medical Image Denoising Using Adaptive Gaussian Filter. *Journal of Medical Systems*. 36(5), 3045-3054.

Agrawal, R. K. (2018). An Efficient and Accurate Medical Image Segmentation Using Modified Local Entropy Thresholding and Sharpening Filter. *Biocybernetics and Biomedical Engineering*, 38(2), 386-402.

J. Tian, X. Jia, S. Wang, (2016), Binary Filter Based on Image Gradient and Spatial Distance. *Journal of Medical Imaging and Health Informatics*,

Zhang B., Zhang L., and Chen Y. (2016) Total Variation-Based Denoising in Medical Imaging, *IEEE Transactions on Biomedical Engineering*, vol. 63, no. 7. 1425-1435.

Cui, S., Chen, L., Liu, Y., Wang, Y. (2019). A Review of Total Variation-Based Denoising Methods for Medical Images. *Journal of X-Ray Science and Technology*. 27(1), 39-50

Qu, X., Sun, L. (2017). Total Variation Regularization for Medical Image Restoration. *Computational and Mathematical Methods in Medicine*, Article ID 7020809, 12.

Manjusha, S., Unnikrishnan, A., & Sreedevi, A. T. (2016). A Comparative Study of Total Variation-Based Denoising Techniques for Medical Images. *International Journal of Computer Science and Information Technologies*, 7(2), 767-771

Zhang, X., Lu, Y., & Wang, X. (2018). A novel total variation-based denoising method for medical images using bilateral filter. *Computer Methods and Programs in Biomedicine*, 164, 79-89

Yeung V, Willis GR, Taglauer E, Mitsialis SA, Kourembanas S. (2019). Paving the Road for Mesenchymal Stem Cell-Derived Exosome Therapy in Bronchopulmonary Dysplasia and Pulmonary Hypertension. *Stem Cell-Based Therapy for Lung Disease*. 7:131–52. doi: 10.1007/978-3-030-29403-8_8. PMID: PMC7122497.

Akram, M., Ali, S. M., Hussain, A. (2019). A Comparative Study of Median Filter and Mean Filter for Image Denoising. *International Journal of Advanced Computer Science and Applications*.

Kaur, H., & Singh, R. (2020). Medical Image Denoising using Median Filter and Adaptive Thresholding. *International Journal of Scientific Research in Computer Science and Engineering*.

Ataş, A., Ünal, S. (2019). Evaluation of Median Filter Performance on Different Types of Noise for Medical Image Analysis. *Journal of Medical Systems*.

- Zhou, Y., Zheng, C. (2018). Threshold Selection Methods for Medical Image Segmentation Using Multi-Level Otsu Algorithm: A review. *Biomedical Signal Processing and Control*, 43, 1-14. doi: 10.1016/j.bspc.2018.02.023
- Taylor P. (1995). Invited Review: Computer Aids for Decision-Making in Diagnostic Radiology—*A Literature Review*. *Br. J. Radiol.* 68:945–57
- Zijdenbos AP, Dawant BM. (1994). Brain Segmentation and White Matter Lesion Detection in MR Images. *Crit. Rev. Biomed. Eng.* 22:401–65
- Worth AJ, Makris N, Caviness VS, Kennedy DN. (1997). Neuroanatomical Segmentation in MRI: Technological Objectives. *Int. J. Pattern Recognit. Artif. Intell.* 11:1161–87
- Khoo VS, Dearnaley DP, Finnigan DJ, Padhani A, Tanner SF, Leach MO. (1997). Magnetic Resonance Imaging (MRI): Considerations and Applications in Radiotherapy Treatment Planning. *Radiother. Oncol.* 42:1–15
- Grimson WEL, Ettinger GJ, Kapur T, Leventon ME, Wells WM, et al. (1997). Utilizing segmented MRI data in image-guided surgery. *Int. J. Pattern Recognit. Artif. Intell.* 11:1367–97
- Kaur, H., Alam, M.A., Jameel, R. et al. (2018). A Proposed Solution and Future Direction for Blockchain-Based Heterogeneous Medicare Data in Cloud Environment. *Journal of Medical Systems*, 42(8), 156.
- Suri J.S., Wilson D.L., Laxminarayan S.(2005) Handbook of Biomedical Image Analysis. *Kluwer Academic. Plenum Publishers* 495
- Li-ping, Y., Huan-ling, T., & Zhi-yong, A. (2014). Domain adaptation for pedestrian detection based on prediction consistency. *ScientificWorld Journal*. 2014, 280382. <https://doi.org/10.1155/2014/280382>
- Chan, K.C.G., Ling, H.K., Sit, T., & Yam, S.C.P. (2018). Estimation of a Monotone Density in S-Sample Biased Sampling Models. *Annals of Statistics*, 46(5), 2125-2152. <https://doi.org/10.1214/17-AOS1614>
- Hesamian, M.H., Jia, W., He, X. (2019). Deep Learning Techniques for Medical Image Segmentation. *Achievements and Challenges. J Digit Imaging* 32, 582–596 .
- Ronneberger, O., Fischer, P., & 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).
- Vardhanabhuti, V., & Venkatesh, S. K. (2019). Magnetic Resonance Imaging in the Evaluation of Polycystic Kidney Disease. *Topics in Magnetic Resonance Imaging*, 28(6), 329-337.
- Glass, D., Cortés, E., Ben-Jaber, S., Brick, T., Peveler, W. J., Blackman, C. S., Howle, C. R., Quesada-Cabrera, R., Parkin, I. P., Maier, S. A. (2019). Surface Oxygen Vacancies: Dynamics of Photo-Induced Surface Oxygen Vacancies in

Metal-Oxide Semiconductors Studied Under Ambient Conditions *Advanced Science*, 6(22), 1970132.

Fathima Shabnam, Manivannan, M. (2021). A Comprehensive Review of Computer-Aided Diagnosis Using Medical Imaging. *Journal of Ambient Intelligence and Humanized Computing*. <https://doi.org/10.1007/s12652-021-03267-1>

E. National Academies of Sciences, Medicine, (2015). Improving Diagnosis in Health Care. *National Academies Press*.

Reis, B. Y. , Kohane I. S. , Mandl. K. D. (2009). Longitudinal Histories as Predictors of Future Diagnoses of Domestic Abuse: Modelling Study. *Bmj* 339.

A. Rajkomar, J. W. L. Yim, K. Grumbach, and A. Parekh. (2016). Weighting Primary Care Patient Panel Size: A Novel Electronic Health Record-Derived Measure Using Machine Learning. *JMIR medical informatics* 4.4.

A. L. Beam and I. S. Kohane. (2018). Big data and machine learning in health care. *In: Jama* 319.13. 1317-1318.

L. Li, L. Qin, Z. Xu, Y. Yin, X. Wang, B. Kong, J. Bai, Y. Lu, Z. Fang, Q. Song, (2020). Using Artificial Intelligence to Detect COVID-19 and Community-acquired Pneumonia Based on Pulmonary CT. *Evaluation of the Diagnostic Accuracy. In: Radiology* 296.2 (2020), E65-E71.

Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level Classification of Skin Cancer with Deep Neural Networks. *Nature*, 542(7639), 115-1

Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C., Liang, H., Baxter, S. L., McKeown, A., Yang, G., Wu, X., Yan, F. (2018). Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning. *Cell*, 172(5), 1122-1131.

B lanc-Durand, P., Campedel, L., Mule, S., Jegou, S., Luciani, A., Pigneur, F., Itti, E. (2020). Prognostic Value of Anthropometric Measures Extracted from Whole-Body CT Using Deep Learning in Patients with Non-small-cell Lung Cancer. *European Radiology*. 1-10.

X u, Y., Hosny, A., Zeleznik, R., Parmar, C., Coroller, T., Franco, I., Mak, R. H., Aerts, H. J. (2019). Deep Learning Predicts Lung Cancer Treatment Response from Serial Medical Imaging. *Clinical Cancer Research*. 25(11), 3266-3275.

T ang, Z., Xu, Y., Jin, L., Aibaidula, A., Lu, J., Jiao, Z., Wu, J., Zhang, H., Shen, D. (2020). Deep Learning of Imaging Phenotype and Genotype for Predicting Overall Survival Time of Glioblastoma Patients. *IEEE Transactions on Medical Imaging*. 39(6), 2100-2109.

Peng, H., Dong, D., Fang, M. J., Li, L., Tang, L. L., Chen, L., Li, W. F., Mao, Y. P., Fan, W., Liu, L. Z. (2019). Prognostic Value of Deep Learning PET/CT-

Based Radiomics: Potential Role for Future Individual Induction Chemotherapy in Advanced Nasopharyngeal Carcinoma. *Clinical Cancer Research*. 25(14), 4271-4279.

Havaei, M., Davy, A., Warde-Farley, D., Biard, A., Courville, A., Bengio, Y., & Pal, C. (2017). Deep Learning-Based Synthesis of 3D Multi-Contrast MR Images for Brain Tumor Segmentation. *IEEE Transactions on Medical Imaging*. 36(6), 1114-1123.

Mohammed, Z., & Hamarneh, G. (2019). A Review of Generative Adversarial Networks for Image Synthesis in Medical Imaging. *Journal of Healthcare Engineering*, 2019, 1-15.

Wei, D., Zhao, S., Liu, X., Yang, Y., Cui, G., & Shi, F. (2018). Deep Learning-Based Synthetic Computed Tomography Generation for Magnetic Resonance Imaging-Only Radiotherapy Planning: A Comparison of Multiple Architectural and Learning Parameters. *Physics in Medicine and Biology*, 63(13), 5405-5423.

Ercan, A. F., & Kalkan, H. (2020). Watershed Algorithm and Its Modifications in Image Segmentation: A Comprehensive Study. *Signal, Image and Video Processing*, 14(1), 159-177

Ersin, S., Karaman, S. (2017). Watershed and Distance Transformation Watershed Algorithms for Image Segmentation. *Signal, Image and Video Processing*. 11(6), 967-974.

Kelleher, J. D., & Tierney, B. (2018). Data Science and Machine Learning: An Introduction to Principles and Techniques. Boca Raton, FL: CRC Press.

Bishop, C. M. (2006). Pattern recognition and machine learning (Vol. 4). New York: Springer

Kaelbling, L. P., Littman, M. L., Moore, A. W. (1996). Reinforcement Learning: A survey. *Journal of Artificial Intelligence Research*, 4, 237-285.

Özgüven, E., & Çakır, M. (2019). Yapay Sinir Ağlarının Performansını Etkileyen Faktörlerin Analizi. *Uluslararası İleri Teknoloji Araştırmaları Dergisi*. 5(13), 83-93. doi: 10.17148/IJITR.2019.51309

Öztürk, S., Güneş, S., Kaynak, O. (2021). A Comparative Study on Activation Functions in Artificial Neural Networks. *Neural Computing and Applications*. 33(12), 5665-5679. doi: 10.1007/s00521-021-06207-4

Maltarollo, V. G., Honório, K. M., Da Silva, A. B. F. (2013). Applications of Artificial Neural Networks in Chemical Problems. London: Intechopen.

Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15(1), 1929-1958. doi: 10.5555/2627435.2670313

Zhang, H., Cisse, M., Dauphin, Y. N., Lopez-Paz, D. (2019). Mixup: Beyond Empirical Risk Minimization. *In Proceedings of the 36th International Conference on Machine Learning (ICML)* (Vol. 97, pp. 5666-5675). doi: 10.5555/3294996.3295078

Zeng, Z., Yu, K. (2018). Understanding Convolutional Neural Networks with A Mathematical Model.

Zhang, Y., & LeCun, Y. (2015). Text understanding from scratch.

Rumelhart, D. E., Hinton, G. E., Williams, R. J. (1986). Learning Representations by Back-Propagating Errors. *Nature*, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>

LeCun, Y., Bengio, Y., Hinton, G. (2015). Deep Learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>

Goodfellow, I., Bengio, Y., Courville, A. (2016). Deep Learning. *MIT Press*. <https://doi.org/10.1016/j.patrec.2014.12.013>

Bishop, C. M. (1995). Neural Networks for Pattern Recognition. Oxford University Press.

Schmidhuber, J. (2015). Deep Learning in Neural Networks: An Overview. *Neural Networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>.

Efendigil, T., Önüt, S., & Kahraman, C. (2009). A Decision Support System for Demand Forecasting with Artificial Neural Networks and Neuro-fuzzy Models: A Comparative Analysis. *Expert Systems with Applications*, 36, 6697-6707.

Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet Classification with Deep Convolutional Neural Networks. *In Advances in Neural Information Processing Systems*. 1097-1105.

Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-scale Image Recognition.

Zhang, Y., & Wallace, B. (2017). A Sensitivity Analysis of (and Practitioners' Guide to) Convolutional Neural Networks for Sentence Classification.

Cengil, E. Çinar, A., Güler, Z.(2017). A GPU-Based Convolutional Neural Network Approach for Image Classification. *Artificial Intelligence and Data Processing Symposium (IDAP)*.

Karaatlı, M., Helvacıoğlu, Ö., Ömürbek, N., Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi İle Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*. 8(17), 87-100.

Gao, X., Li, W., Loomes, M., Wang, L.(2017) A Fused Deep Learning Architecture for Viewpoint Classification of Echocardiography. *Information Fusion*. 36, 103–113.

Gao, X. W., Hui, R., Tian, Z.(2017) Classification of CT Brain Images Based on Deep Learning Networks. *Computer Methods and Programs in Biomedicine*. 138, 49–56.

Ari, B., Sengur, A., Ari, A., Hanbay D.(2016) Apricot Plant Classification Based On Leaf Recognition by Using Convolutional Neural Networks. *International Conference on Natural Science and Engineering*

He K., Zhang X., Ren S., Sun J.(2016) Deep Residual Learning for Image Recognition, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* 770-778.

Yamashita R., Nishio M., Do R.K., Togashi K.(2018) Convolutional Neural Networks: An Overview and application in Radiology. *Insights into Imaging*, 9, 611- 629,

Xu, H., Zhang, C., Zhang, J., Liu, Y. (2020). A Survey on Convolutional Neural Networks: Analysis, Design, and Optimization. *Journal of Signal Processing Systems*. 92(4), 495-508. doi: 10.1007/s11265-020-01589-7

Zhang, X., Zhou, X., Lin, M., & Sun, J. (2018). Shufflenet: An Extremely Efficient Convolutional Neural Network for Mobile Devices. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 6848-6856. doi: 10.1109/CVPR.2018.00718

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Mobilenetv2: Inverted Residuals and Linear Bottlenecks. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 4510-4520). doi: 10.1109/CVPR.2018.00474

Meunier, L. C. V., & Chandy, D. A.(2019) Design of Convolution Neural Network for Facial Emotion Recognition. *International Conference on Signal Processing and Communication (ICSPC)*. 376-379.

Umer, M., Ashraf, I., Ullah, S., Mehmood, A., Choi, G. S. (2021). COVINet: A Convolutional Neural Network Approach for Predicting COVID-19 from Chest X-ray Images. *Journal of Ambient Intelligence and Humanized Computing*. 1-13.

Jeong, J. (2021). The Most Intuitive and Easiest Guide for CNN. Towards Data Science. <https://towardsdatascience.com/the-most-intuitive-and-easiest-guide-for-convolutional-neural-network-3607be47480>

S. Han et al. (2020). Deep Learning for Mobile Multimedia: A Survey. *IEEE Transactions on Multimedia*. 22(1), 6-29. <https://doi.org/10.1109/TMM.2019.2948255>

D. C. Ciresan et al. (2012). Multi-column deep neural network for traffic sign classification. *Neural Networks*. 32, 333-338. <https://doi.org/10.1016/j.neunet.2012.02.023>

L. Gao et al. (2019). Deep Learning for Health Informatics. *IEEE Journal of Biomedical and Health Informatics*. 23(3), 1223-1239. <https://doi.org/10.1109/JBHI.2018.2837366>

Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., Fei-Fei, L. (2009). ImageNet: A Large-Scale Hierarchical Image Database. *IEEE Conference on Computer Vision and Pattern Recognition*. 248–255. <https://doi.org/10.1109/CVPR.2009.5206848>

Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., & Fei-Fei, L. (2015). ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, 115(3), 211–252. <https://doi.org/10.1007/s11263-015-0816-y>

Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., Torralba, A. (2016). Learning Deep Features for Discriminative Localization. 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2921–2929. <https://doi.org/10.1109/CVPR.2016.319>

Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv.1409.1556*.

Girshick, R., Donahue, J., Darrell, T., Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *In Proceedings of the IEEE conference on computer vision and pattern recognition*. 580-587.

Jégou, S., Drozdal, M., Vazquez, D., Romero, A., & Bengio, Y. (2017). The one hundred layers tiramisu: Fully convolutional densenets for semantic segmentation. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. 11-19.

Huang, G., Liu, Z., Weinberger, K. Q., van der Maaten, L. (2018). CondenseNet: An efficient densenet using learned group convolutions. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2752-2761.

İşler, H., & Torresani, L. (2017). Learning to Learn by Backpropagating Errors. *In Proceedings of the IEEE International Conference on Computer Vision*. 3981-3990.

Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 4700-4708.

Krizhevsky, A., Sutskever, I., Hinton, G.E. (2012) Imagenet Classification with Deep Convolutional Neural Networks. *In: NIPS*. 1106–1114.

LeCun, Y., Boser, B., Denker, J.S., Henderson, D., Howard, R.E., Hubbard, W., Jackel, L.D. (1989) Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation* 1(4), 541–551.

Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T., & Ronneberger, O. (2016). 3D U-Net: Learning dense volumetric segmentation from sparse annotation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 424-432). Springer, Cham. https://doi.org/10.1007/978-3-319-46723-8_49

Roth, H. R., Oda, H., Zhou, X., Shimizu, N., Yang, X., & Oda, M. (2020). U-Net segmentation of COVID-19 CT lung scans: A retrospective study. *PloS one*, 15(12), e0243705. <https://doi.org/10.1371/journal.pone.0243705>.

Guo, X., Wang, Y., Wu, Z., Wang, Z., Yang, C., & Liu, H. (2021). U-Net with pseudo label and consistency training for histopathological image segmentation. *IEEE Transactions on Medical Imaging*, 40(3), 882-893. <https://doi.org/10.1109/TMI.2020.3036943>.

Zeiler, M. D., & Fergus, R. (2014). Visualizing and Understanding Convolutional Networks. In *European conference on computer vision* (pp. 818-833). Springer, Cham

Breiman, L. (2001). Random forests. *Machine Learning*. 45(1), 5-32.

Cutler, A., Cutler, D. R., Stevens, J. R. (2007). Random Forests. Ensemble Machine Learning. *Methods and Applications*, 157-175

Liaw, A., & Wiener, M. (2002). Classification and regression by random forest. *R news*. 2(3), 18-22

Breiman, L.(2001) Random Forests. Mach. Learn. 45, 5–32

Breiman, L., Cutler, A.(2001) Random Forests, <http://www.stat.berkeley.edu/>

Borra, S., & Suykens, J. A. (2018). Random Forests: Versatile Machine Learning Algorithm for Big Data Analytics. *IEEE Access*, 6, 52085-52103. <https://doi.org/10.1109/ACCESS.2018.2874065>

Liang, Y., Zhang, J., Liu, L., & Wang, S. (2020). A hybrid method based on random forest and support vector machine for classification of oil spills using multi-source remote sensing data. *Journal of Oceanology and Limnology*. 38(6), 1912-1925. <https://doi.org/10.1007/s00343-020-0211-1>

Titapiccolo JI, Ferrario M, Cerutti S, Barbieri C, Mari F, Gatti E, Signorini MG. (2013) Artificial intelligence models to stratify cardiovascular risk in incident hemodialysis patients. *Expert Syst Appl* .40(11):4679–86

Çetin, Ş., & Öztürk, C. (2018). An implementation of random forest algorithm in predicting health status. *European Journal of Science and Technology*. 8(16), 138-143

İşeri, E., & Yıldız, R. (2019). Assessment of classification performance measures for prediction models in machine learning: Precision, recall, and F1 score. *Journal of Education and Future*. 14, 61-71.

Wu, S. L., Chen, C. M., Chen, Y. Y., & Yeh, C. C. (2021). The Application of Machine Learning Techniques in Fault Diagnosis of Induction Motors. *Applied Sciences*. 11(4), 1493.

İşik, O., & Aydin, M. A. (2019). An investigation of deep learning methods for sentiment analysis of Turkish tweets. *Journal of Intelligent & Fuzzy Systems*. 36(3), 2873-2883.

Saba T., Alzorani S., Rehman A.(2012) Expert system for offline clinical guidance and treatment, *Life Sci. J.*, Vol. 9, no. 4, pp. 2639-2658, 2012.

Norouzi A., Rahman A., Shafry M., Saba T.(2012). Visualization and segmentation, *Int. J. Acad. Res.*, Vol. 4, no. 2, pp. 202-208.

Maintz J., Viergever M. (1998). A survey of medical image registration, *Med. Image Anal.*, Vol. 2, no. 1, pp. 1-36, 1998.

Türk F. (2021), Segmentation of Kidney Tumors by Deep Learning. Graduate School of Natural and Applied Sciences (Phd Thesis, Kirikkale University, Turkey)

9 ÖZGEÇMİŞ

Adı Soyadı : Aziz İlyas Öztürk
Doğum Yeri ve Tarihi : -
Elektronik posta : -
İletişim Adresi : -
ORCID Numarası : 0000-0003-2350-5880

Öğrenim Durumu

1994 – 2001 Lisans: Fırat Üniversitesi– Elektrik-Elektronik Mühendisliği
2016 – 2018 Yüksek Lisans: İstanbul Arel Üniversitesi – Elektrik-Elektronik Mühendisliği
2018 – 2023 Doktora: İstanbul Arel Üniversitesi – Elektrik-Elektronik Mühendisliği

Yayın Listesi:

Öztürk, A. İ. , Yıldırım, O. , Ateş, Y. & Kuru, A. (2022). Böbrek Görüntülerinde Filtreleme Tekniği Kullanarak Kist Belirlenmesi . Avrupa Bilim ve Teknoloji Dergisi , (38) , 198-204

Aziz İlyas Öztürk, Osman Yıldırım, Ali Kuru. (2022). Cyst Segmentation Using Filtering Technique in Computed Tomography Abdominal Kidney Images. Mathematical Statistician and Engineering Applications, 71(4), 6828–6838.