



Sosyal Bilimler  
Enstitüsü

T.C.  
MARMARA ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ  
İŞ ANALİTİĞİ ANABİLİM DALI  
İŞ ANALİTİĞİ BİLİM DALI

# KOLONOSKOPİ GÖRÜNTÜLERİNDEKİ POLİPLERİN EVRIŞİMLİ SINIR AĞLARI İLE TESPİTİ

Yüksek Lisans Tezi

ERDEM EZER

İSTANBUL, 2022

T.C.  
MARMARA ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ  
İŞ ANALİTİĞİ ANABİLİM DALI  
İŞ ANALİTİĞİ BİLİM DALI

# KOLONOSKOPİ GÖRÜNTÜLERİNDEKİ POLİPLERİN EVRIŞİMLİ SINIR AĞLARI İLE TESPİTİ

Yüksek Lisans Tezi

ERDEM EZER

Danışman: PROF. DR. MERT ERER

İSTANBUL, 2022

## ÖZET

### KOLONOSKOPİ GÖRÜNTÜLERİNDEKİ POLİPLERİN EVİRİŞİMLİ SİNİR AĞLARI İLE TESPİTİ

Makine öğreniminin bir alt başlığı olan derin öğrenme alanındaki son gelişmeler, kullanım alanının hızla yaygınlaşmasına sebep olmaktadır. Sürücüsüz araçların yolu ve çevredeki nesnelere tespiti, el yazısı ile yazılmış belgelerin tanınması, mobil telefonlarda yüz tanıma gibi geniş bir sahada başarıyla kullanılmaktadır. Sağlık sektöründe ise medikal görüntülerin analizi ile cilt kanserinin erken aşamada teşhisinde, manyetik rezonans görüntülerinden beyin tümörlerinin tespit edilmesinde derin öğrenme yöntemlerinden faydalanılmaktadır.

Kanser, vücudun herhangi bir bölgesindeki hücrelerin kontrolsüz bir şekilde büyümesi ile ortaya çıkan ölümcül bir hastalıktır. Dünya Sağlık Örgütü Uluslararası Kanser Araştırma Merkezi (IARC) 2020 verilerine göre dünya çapında en çok ölüme neden olan ikinci kanser türü kolon kanseridir.

Kolon kanseri erken aşamada fark edildiğinde çoğunlukla tedavisi mümkün olan bir hastalıktır. Premalign (kansere öncesi) aşamada iken tespit edilmesi halinde hastalığın görülme sıklığının ve ölüm oranının azaltılması ve pahalı tedavilerin önlenmesi olasıdır. Bu çalışmada kalın bağırsak içinde anormal şekilde büyüyerek zamanla kansere dönüşebilen poliplerin tespitinde uzman klinisyene yardımcı olmak amacıyla U-Net mimarisine dayalı Evrişimli Sinir Ağı (CNN) modeli önerilmektedir. Modelin eğitiminde öğrenme transferinin, veri artırmanın ve kayıp fonksiyonunun etkisi incelenmiştir.

Kolonoskopi süreci hem hasta hem de doktor açısından zaman alıcı ve yorucudur. Kolonoskopi esnasında bulunması hedeflenen poliplerin CNN ile otomatik tespiti gözden kaçırılan polip sayısını azaltacak, hekimin başka hastalara daha çok zaman ayırabilmesine, kaynakların etkin kullanılmasına imkan verecektir.

**Anahtar Kelimeler:** Kolonoskopi, Kanser, Polip Segmentasyonu, Derin Öğrenme, Evrişimli Sinir Ağları, Öğrenme Transferi, U-NET

## ABSTRACT

### DETECTING POLYPS IN COLONOSCOPY IMAGES USING CONVOLUTIONAL NEURAL NETWORKS

Recent developments in the field of deep learning, which is a sub-title of machine learning, cause the usage area to become widespread rapidly. It is successfully used in a wide range of fields such as driverless vehicles detecting the road and surrounding objects, recognizing handwritten documents, and face recognition in mobile phones. In the health sector, deep learning methods are used in the early diagnosis of skin cancer with the analysis of medical images, and in the detection of brain tumors from magnetic resonance images.

Cancer is a deadly disease that occurs with the uncontrolled growth of cells in any part of the body. According to the World Health Organization International Center for Cancer Research (IARC) 2020 data, colon cancer is the second leading cause of death worldwide.

Colon cancer is a disease that is usually treatable when detected at an early stage. It is possible to reduce the incidence and mortality rate of the disease and prevent expensive treatments if it is detected at the premalignant (pre-cancerous) stage. In this study, a U-Net-based Convolutional Neural Network model is proposed to help detect polyps that can grow abnormally in the large intestine and turn into cancer over time. The effects of learning transfer, data augmentation and loss function in the training of the model were examined.

The colonoscopy process is time-consuming and tiring for both the patient and the doctor. Automatic detection of polyps targeted to be found during colonoscopy with CNN will reduce the number of missed polyps, allow the physician to spare more time for other patients, and enable the efficient use of resources.

**Keywords:** Colonoscopy, Cancer, Polyp Segmentation, Deep Learning, Convolutional Neural Networks, Transfer Learning, U-NET

## ÖNSÖZ

Kolorektal kanser, dünyada en çok ölüme sebep olan ikinci kanser türüdür. Kanserin erken aşamada fark edilerek önleyici tedbirler alınması hastalığın tedavisi için çok kıymetlidir. Bu çalışmada kolorektal kansere neden olabilecek lezyonların tespitinde uzman hekime yardımcı, derin öğrenme mimarisine dayalı bir karar destek sistemi modeli önerilmiştir.

Tez çalışmasının hazırlanması aşamasında bilgi, birikim ve tecrübesiyle desteğini esirgemeyen, yol gösterici olan değerli danışmanım Prof. Dr. Mert ERER'e saygılarımı ve teşekkürlerimi sunarım.

İş ve okul dengesini birlikte yürütmemde büyük desteği olan değerli çalışma arkadaşlarım Adem Altun'a ve İbrahim Kuru'ya, direktörüm Sami Haluk Hüsmen'e şükranlarımı sunarım.

Araştırma sürecinde beni destekleyen, cesaretlendiren biricik eşime, sevgilerini eksik etmeyen kızlarıma teşekkür ederim.

Bu çalışmayı anneme ithaf ediyorum.

Erdem EZER

İSTANBUL, 2022

## İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
ÖNSÖZ.....	iii
İÇİNDEKİLER.....	iv
KISALTMALAR.....	vii
TABLO LİSTESİ.....	ix
GRAFİK LİSTESİ.....	X
ŞEKİL LİSTESİ.....	XI
1.GİRİŞ.....	1
1.1.Tezin Konusu ve Amacı.....	2
1.2.Kaynakların Değerlendirilmesi.....	2
1.3.Tez Çalışma Süreci.....	8
1.4.Tezde Uygulanan Yöntem.....	9
2.YAPAY SİNİR AĞLARI, DERİN ÖĞRENME.....	11
2.1. Yapay Sinir Ağları.....	11
2.1.1. Biyolojik Sinir Hücresi.....	11
2.1.2. Yapay Sinir Hücresi (Perceptron).....	12
2.1.3. Yapay Sinir Hücresi Öğrenmesi.....	13
2.1.4. Çok Katmanlı Algılayıcı (Multi Layer Perceptron - MLP).....	13
2.1.5. Geri Yayımlı Öğrenme.....	14
2.1.6. Aktivasyon Fonksiyonları.....	15
2.1.7. Derin Öğrenme, Makine Öğrenimi, Yapay Zeka İlişkisi.....	17
3. EVRİŞİMLİ SİNİR AĞLARI.....	18
3.1. Evrişimli Sinir Ağı Katmanları.....	19
3.1.1. Giriş Katmanı.....	19
3.1.2. Evrişim Katmanı.....	19
3.1.3. Aktivasyon Katmanı.....	20

3.1.4. Havuzlama Katmanı .....	21
3.1.5. Tam Bağlantı Katmanı .....	21
3.1.6. Seyreltme (Dropout) Katmanı .....	21
3.1.7. Softmax Sınıflandırma Katmanı.....	22
3.2.Hiperparametreler.....	22
3.2.1. Öğrenme Katsayısı (Learning Rate).....	23
3.2.2. Mini-Batch Boyutu.....	23
3.2.3. Eğitim Dönemi (Epoch) Sayısı.....	24
3.3.Kayıp (Loss) Fonksiyonları.....	24
3.3.1. Binary Cross Entropy .....	24
3.3.2. Log-Cosh Dice Loss.....	24
3.4.Evrişimli Sinir Ağı Modelleri.....	25
3.4.1. Lenet-5 .....	25
3.4.2. Alex-Net .....	26
3.4.3. GoogLenet.....	26
3.4.4. Resnet.....	27
3.4.5. InceptionResNetV2 .....	27
3.4.6. Densenet .....	28
3.4.7. EfficientNet .....	29
3.4.8. U-Net.....	29
3.5.Öğrenme Transferi .....	30
3.6.İnce Ayar (Fine Tuning).....	30
4. POLİP SEGMENTASYONU İÇİN U-NET MODELİNİN GELİŞTİRİLMESİ.....	31
4.1. Veriseti .....	31
4.2. Veri Artırma .....	33
4.3. Geliştirme Platformu ve Teknolojiler.....	34
4.3.1 Python.....	34
4.3.2 Google Colab.....	34
4.3.3 NumPy, SciPy .....	35
4.3.5 Keras.....	35
4.4. Performans Ölçütleri .....	35
4.5. Karmaşıklık Matrisi.....	35

4.6. Sınıflandırma Performans Ölçütleri .....	36
4.6.1 Doğruluk (Accuracy):.....	36
4.6.2 Kesinlik (Precision):.....	36
4.6.3 Hassasiyet (Recall):.....	36
4.6.4 F1 Skoru: .....	36
4.6.5 IoU: (Kesişen Bölge - Jaccard İndeksi - Intersection Over Union).....	37
4.6.6 Dice Ölçütü (Dice Co-efficient).....	37
5. BULGULAR .....	39
5.1. Model Eğitiminde Orjinal Veri ve Artırılmış Veri Kullanımının Etkisi .....	39
5.1.1 DenseNet201 Ön Eğitimli Modelinin U-NET Mimarisi İle Kullanılması .....	39
5.1.2 EfficientNetB7 Ön Eğitimli Modelinin U-NET Mimarisi İle Kullanılması.....	40
5.1.3 InceptionResNetV2 Ön Eğitimli Modelinin U-NET Mimarisi İle Kullanılması .....	40
5.2 Kayıp (Loss) Fonksiyonunun Modelin Performasına Etkisi .....	41
5.3 İnce Ayar Uygulamanın Modelin Performasına Etkisi .....	42
5.4 Geliştirilen Modellerin Doğrulama ve Test Performanslarının Karşılaştırılması.....	42
5.5 Önerilen Modele Ait Tahminleme Örnekleri .....	44
5.6 Önerilen Modelin Performans Karşılaştırması .....	45
6 SONUÇ VE ÖNERİLER .....	46
7 KAYNAKLAR.....	48

## KISALTMALAR

<b>ACC</b>	Doğruluk (Accuracy)
<b>CAD</b>	Bilgisayar Destekli Teşhis
<b>CNN</b>	Evrışimli Sinir Ağları
<b>COLAB</b>	Google Colab Platformu
<b>CPU</b>	Merkezi İşlem Birimi
<b>DL</b>	Derin Öğrenme
<b>EKG</b>	Elektrokardiyografi
<b>HSGM</b>	Halk Sağlığı Genel Müdürlüğü
<b>FCL</b>	Tam Bağlantılı Katman
<b>FCN</b>	Tam Bağlantılı Ağ
<b>FP</b>	Yanlış Pozitif (False Positive)
<b>GPU</b>	Grafik İşlem Birimi
<b>IARC</b>	Uluslararası Kanser Araştırma Ajansı
<b>IEEE</b>	Elektrik Elektronik Mühendisleri Enstitüsü
<b>ILSVRC</b>	ImageNet Büyük Ölçekli Görsel Tanıma Zorluğu
<b>LR</b>	Öğrenme Katsayısı
<b>ML</b>	Makine Öğrenimi
<b>MMOD</b>	Maksimum Aralık Nesne Algılama
<b>MICCAI</b>	Tıbbi Görüntü Hesaplama ve Bilgisayar Destekli Müdahale Derneği
<b>MLP</b>	Çok Katmanlı Algılayıcı
<b>MSCOCO</b>	Microsoft Common Objects in Context
<b>PCA</b>	Temel Bileşen Analizi (Principal Component Analysis)
<b>RMSPROP</b>	Ortalama Kök Kare Yayılımı
<b>SVM</b>	Destek Vektör Makinesi (Support Vector Machine)
<b>SMOTE</b>	Sentetik Azınlık Aşırı Örneklem Tekniği
<b>RELU</b>	Doğrultulmuş Doğrusal Birim (Rectified Linear Unit)
<b>RGB</b>	Kırmızı, Yeşil, Mavi Renk Standardı

<b>TP</b>	Gerçek Pozitif (True Positive)
<b>YZ</b>	Yapay Zeka
<b>YSA</b>	Yapay Sinir Ağları



## TABLO LİSTESİ

Tablo 1: Literatür Özet Tablosu .....	6
Tablo 2: Tez İş Planı .....	8
Tablo 3: Biyolojik Sinir Sistemi ile Yapay Sinir Sistemi Karşılaştırması .....	12
Tablo 4: Modelin eğitimi, doğrulanması ve testi için kullanılan görüntü sayısı ve oranı .....	32
Tablo 5: Augmentor kütüphanesi ile veri artırma yöntemleri .....	33
Tablo 6: DenseNet201 modeli ile veri artırma öncesi ve sonrası performans değerlendirmesi.....	39
Tablo 7: EfficientNetB7 modeli ile veri artırma öncesi ve sonrası performans değerlendirmesi .....	40
Tablo 8: InceptionResNetV2 modeli ile veri artırma öncesi ve sonrası performans değerlendirmesi ..	41
Tablo 9: EfficientNetB7 modeli ile veri artırma öncesi ve sonrası performans değerlendirmesi .....	41
Tablo 10: DenseNet201 ön eğitilmiş modeliyle ince ayar uygulanması.....	42
Tablo 11: EfficientNetB7 ön eğitilmiş U-NET modelinin doğrulama ve test performansı .....	42
Tablo 12: Başarılı Polip Tespiti Örnekleri .....	44
Tablo 13: Başarısız Polip Tespiti Örnekleri .....	44
Tablo 14: Mevcut Çalışmalarla Karşılaştırma.....	45

## GRAFİK LİSTESİ

Grafik 1: EfficientNet Parametre Sayısı ve ImageNet Veriseti Doğruluk Oranı Grafiği.....	29
Grafik 2:612 adet kesin referans görüntüsü içinde yer alan beyaz pikselin yüzdelerik dağılım grafiği...	32
Grafik 3: DenseNet201 Modeli, focal tversky kayıp fonksiyonu, orijinal eğitim seti ile Doğruluk Grafiği .....	40
Grafik 4: EfficientNetB7 Modeli, focal tversky kayıp fonksiyonu, orijinal eğitim seti ile Doğruluk Grafiği, Kayıp Grafiği .....	40
Grafik 5: InceptionResnetV2 Modeli, focal tversky kayıp fonksiyonu, orijinal eğitim seti ile Doğruluk Grafiği, Kayıp Grafiği .....	41



## ŞEKİL LİSTESİ

Şekil 1:Kalın Bağırsak Polipinin Kansere Dönüşümü .....	2
Şekil 2: Kolonoskopi Görüntülerinde Poliplerin İncelenmesine Yönelik Çalışma Trendi .....	8
Şekil 3:Biyojik Sinir Hücresi .....	11
Şekil 4: Bir sinir hücresinin matematiksel modeli .....	12
Şekil 5: Perceptron Blok Diyagramı .....	13
Şekil 6: Tek gizli katmana sahip yapay sinir ağı modeli .....	13
Şekil 7: Yapay Sinir Ağları Türleri .....	14
Şekil 8: Basamak Fonksiyonu ve Türevi .....	15
Şekil 9: Doğrusal Fonksiyon ve Türevi .....	15
Şekil 10: Doğrusal Fonksiyon ve Türevi .....	15
Şekil 11: Hiperbolik Tanjant Fonksiyonu ve Türevi .....	16
Şekil 12: ReLU Fonksiyonu ve Türevi .....	16
Şekil 13: Aktivasyon Fonksiyonlarının Matematiksel Gösterimleri .....	16
Şekil 14: Yapay Zeka, Makine Öğrenmesi, Derin Öğrenme .....	17
Şekil 15: Evrişimli Sinir Ağları Genel Mimarisi .....	18
Şekil 16: $16 \times 16$ 'lık ızgara ile 256 farklı gri seviyenin gösterimi .....	18
Şekil 17: Doğal Renkli Görüntünün ana renklerle gösterimi .....	19
Şekil 18: Filtrenin matriste gezinmesi .....	19
Şekil 19: $M \times N \times 3$ giriş matrisine $3 \times 3 \times 3$ filtre ile evrişim .....	20
Şekil 20: RELU Katmanının Giriş Görüntüsüne Etkisi .....	20
Şekil 21: Görüntüye uygulanan havuzlamanın etkisi .....	21
Şekil 22: Maksimum Havuzlama .....	21
Şekil 23: Seyreltme (Drop out) İşlemi .....	22
Şekil 24: Sınıflandırma katmanı çıkış değerleri .....	22
Şekil 25: Gradyan iniş algoritmasının, minimum değer için ilk türevi kullanması .....	23
Şekil 26: Farklı öğrenme katsayıları ile gradyan inişi .....	23
Şekil 27: Binary Cross Entropy Fonksiyonu .....	24

Şekil 28:Focal Twersky Loss Fonksiyonu .....	25
Şekil 29:Lenet Ağının Mimarisi.....	25
Şekil 30:Alex-Net Mimarisi .....	26
Şekil 31:Google-Net Mimarisi .....	26
Şekil 32:Ağ içinde Ağ.....	27
Şekil 33:Artık Blok Gösterimi .....	27
Şekil 34:Büyüme oranı $k = 4$ olan 5 katmanlı yoğun bir blok .....	28
Şekil 35:Bitişik iki blok arası geçiş katmanı içeren üç yoğun bloklu DenseNet.....	28
Şekil 37:EfficientNet modelinin genişlik, derinlik, çözünürlük artışı ile gösterimi.....	29
Şekil 38:Orjinal U-net Mimarisi .....	30
Şekil 39: Ön eğitilmiş modelin veriseti ile eğitilecek yeni modelin veriseti arasındaki benzerliğe ve eğitim verisetinin büyüklüğüne göre ince ayar yapılması önerilen katmanlar .....	31
Şekil 40:Polip görüntüsü ve kesin referans görüntüsü .....	32
Şekil 41:29 adet kolonoskopi videosundan elde edilen 612 adet polipli görüntü .....	32
Şekil 42:Eğitim, doğrulama, test veri seti oluşturma artırılmış veri üretme aşamaları .....	34
Şekil 43:Karmaşıklık Matrisi .....	36
Şekil 44:Keşişen Bölge Başarımı Değerlendirmesi .....	37
Şekil 45:Kolonorektal Polip Segmentasyonu Süreci.....	38
Şekil 46:Geliştirilen Modellerin Doğrulama ve Test Veriseti ile Performans Değerlendirmesi.....	43

## 1. GİRİŞ

Yapay zeka (YZ), bilgisayar denetimli bir makinenin insana özgü akıl yürütme, anlam çıkarma, genelleme, geçmiş deneyimlerden öğrenme gibi yeteneklerini taklit ederek problemlerin çözümüne cevap arayan bilim dalıdır. İnsansız hava araçları, otonom sürüş yeteneğine sahip sürücüsüz araçlar görüntü işlemeye dayalı yapay öğrenme modellerini başarılı şekilde kullanmaktadır. Makine öğrenmesinin hastalıkların teşhis edilmesinde kullanılma potansiyeli vardır.

Sağlık alanında YZ destekli uygulamalar, kanser hastalıklarının erken aşamada tespitine, radyolojik görüntülerin analizi ile gereksiz biyopsilerin azaltılmasına, beyin toraks taramalarına tanı konmasına, şüpheli lezyon ve nodül tespitine, diyabetik göz hastalığı teşhisine, dijital patoloji yöntemiyle lenf nodu biyopsisinde meme kanseri tespitine katkı sağlamıştır. (Büyükgoze, S. & Dereli, E. 2019)

Tıbbi görüntüleme analizi alanında derin öğrenme (DL) uygulamaları uzman performansına yakın başarı gösterebilmektedir. Elektrokardiyografi (EKG) ritimlerinden aritmi sınıflandırılması için geliştirilen DL modeli dijital EKG verilerinde doğru ve ölçeklenebilir EKG analizinde ortalama kardiyolog duyarlılığını aşmıştır. (Hannun, Awni Y. vd. 2019.)

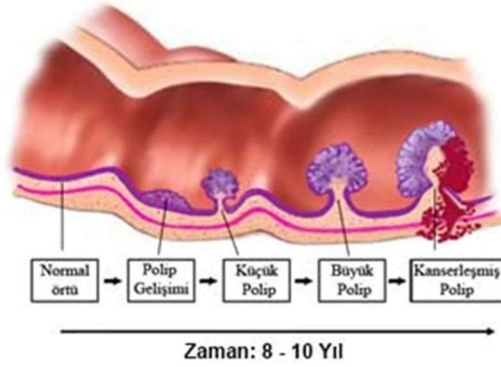
Dünya Sağlık Örgütü'nün Kanser Araştırma Merkezi (International Agency for Research On Cancer, IARC) istatistiklerine göre 2020 yılında 19.292.789 kişiye kanser tanısı konulmuştur. Bunların %10'u (1.931.590) kalın bağırsak kanseri olup, en çok görülen üçüncü kanser türüdür. 2020 yılında dünya çapında kanser nedeniyle ölümlerin %9.4'ü (935.173 kişi) kalın bağırsak kanseri nedeniyle gerçekleşmiştir.

Dünyada vaka sayısı itibarıyla 3. sırada olan bu kanser türü ölüm nedenleri yönüyle 2. sırada yer almaktadır. (IARC, 2020). Türkiye'de kalın bağırsak kanserinin görülme sıklığı tüm kanser türleri arasında üçüncü sırada bulunmaktadır. (Halk Sağlığı Genel Müdürlüğü- HSGM, 2021)

Kolonoskopi sindirim sisteminin sonu olan kalın bağırsakta erken dönemde kolon kanserinin oluşmasını önleyici olabilen endoskopik bir işlemdir. Kolonoskopi, bağırsak iç yüzeyinin ayrıntılı incelenmesini sağlayan optik görüntü kaynağından elde edilen imgelerin monitöre yansıtılması ve eş zamanlı olarak bilgisayara kaydedilmesi ile yapılır. Elde edilen görüntülere göre doktor birçok hastalığın tanısını koyabilir veya şüpheli gördüğü noktada laboratuvar ortamında incelenmesi amacıyla doku parçası olarak biyopsi yapabilir. Kolonoskopi sayesinde erken evrede kanser riskinin tespit edilmesi mümkündür. (Kesici B. 2020)

Kalın bağırsağın, kolon ve rektumun, yüzey kısmını örten mukoza tabakasında anormal şekilde büyüyerek oluşan ve bağırsak içine doğru yerleşen kabartılara polip denmektedir. Polip düzensiz hücre bölünmelerinin sonucunda oluşmaktadır. Kalın bağırsak kanserlerinin %90'ından fazlası polip zemininde gelişmektedir. Her polip kanser demek değildir, bununla birlikte çevresel ve kalıtsal

sebeplerle iyi huylu bir polip yıllar içinde kansere dönüşebilmektedir. Polipin türüne, biçimine, büyüklüğüne, sayısına, yerleşim yerine göre kanser riski değişmektedir. (Kuzu A. 2015)



Şekil 1: Kalın Bağırsak Polipinin Kansere Dönüşümü  
Kaynak: (Kuzu A. 2015)

Bu bölümde tezin konusu ve amacı, kaynakların değerlendirilmesi ile ilgili genel bilgiler verilmektedir.

### 1.1. Tezin Konusu ve Amacı

Hollanda Utrecht'te yapılan bir araştırmada 406 hastadan alınan kolonoskopi görüntüleri incelendiğinde 611 polipten 461 tanesinin tespit edildiği, %25 oranında (150 adet) polipin ise gözden kaçtığı ifade edilmektedir. Yapılan araştırmalarda gözden kaçan kötü huylu poliplerin 3 yılın ardından kansere dönüşebildiği vurgulanmaktadır. (Leufkens, A. M.vd. ,2012)

Lee J. ve arkadaşları tarafından 2017 yılında yayınlanan retrospektif gözlemsel bir çalışmada 659 hasta arasından kolorektal polipleri gözden kaçırma oranının %17.24 (2158 polipten 372'si) olduğu belirtilmektedir. Hastaların %38.69'unda (659 hastanın 255'i) en az 1 adet polip tespit edilememiş, gözden kaçmıştır. (Lee J. vd. 2017)

Bu tez çalışmasında hedeflenen kolonoskopi cihazı ucunda bulunan kamera ile elde edilen görüntülerin derin öğrenme algoritmasına sahip yazılım ile işlenerek yapay zeka tabanlı bir karar destek sistemi oluşturmaktır. Yapay sinir ağı modeli olan Evrişimli Sinir Ağları (Convolutional Neural Network , CNN) görüntü işleme alanında yüksek performans gösterdiğinden sıklıkla kullanılmaktadır. Derin öğrenme yaklaşımlarının bilgisayarlı görüdeki başarısı ile polip tespiti, lokalizasyonu ve segmentasyonu için önerilen yöntemlerin sayısında artış gözlenmiştir. Bu sebeple bu çalışmada CNN mimarisine dayalı bir derin öğrenme modeli geliştirilerek polip segmentasyonu yapılacaktır.

### 1.2. Kaynakların Değerlendirilmesi

Sağlık alanında yapay zekaya (YZ) dayalı karar destek sistemlerinin (CAD) kullanım alanı gün geçtikçe genişlemekte ve önemi artmaktadır. CNN ile görüntü işleme alanında yapılan çeşitli çalışmalar bulunmaktadır.

Tajbakhsh vd. doğal görüntülerle eğitilmiş bir derin öğrenme modeline ait katmanların öğrenme transferi yoluyla kolonoskopi görüntüsünde polip tespiti, BT anjiyografisi ile pulmoner emboli tespiti, koroner arter hastalarında ise karotis intima media kalınlığının (KİMK) ultrasonografi görüntü segmentasyonu için çalışma yapmışlardır. Polip tespiti amacıyla yapılan araştırmada kolonoskopi videolarından elde edilen 5700 polipli, 13700 polipsiz kolonoskopi görüntüsü önceden eğitilmiş

AlexNet CNN modelinde kullanılmıştır. AlexNet modelinin tüm katmanlarının tamamen eğitilmesi, ince ayar yapılarak ağırlıklı katmanlarının eğitilmesi ile oluşan modellerin performansı FROC analizi ile karşılaştırılmıştır. Oluşan CNN modellerinin eğitiminde orijinal verisi %100, %50, %25 oranında kullanılarak eğitim verisi azaltılmış, verisetinin boyutu küçüldüğünde ince ayar yapılan modellerin sıfırdan eğitilen modellerden daha başarılı olduğu görülmüştür. (Tajbakhsh N. Vd. 2016)

Yuan, Z. vd 2017 çalışmasında Mayo Clinic Arizona'dan alınan ASU MAYO kolonoskopi verisetini ve önceden eğitilmiş AlexNet CNN modelini kullanmıştır. ASU MAYO kolonoskopi veritabanı, Arizona Mayo Clinic Gastroenteroloji departmanında toplanan kolonoskopi video görüntülerinden oluşmaktadır. Bu veritabanındaki videolardan elde edilmiş her bir görüntüye karşılık polip bölgesini gösteren bir kesin referans (ground truth) görüntüsü de yer almaktadır. ASU MAYO veritabanında 10 polip içeren video 10 adet ise polip içermeyen video bulunmasına rağmen çalışma kapsamında 4 hastanın polip görüntüsü içeren kolonoskopi video görüntüsü ile 2 farklı hastanın polip içermeyen kolonoskopi görüntüleri kullanılmıştır. 3 adet polip içeren video ile 1 adet polip içermeyen video kaynağından elde edilmiş orijinal görüntüyü imge kopartma (patch-based) yöntemiyle sağa sola çevirme, yakınlaştırma, yukarı aşağı çevirme aşamalarından geçirek eğitim verisetini büyütmüşlerdir. Bu sayede 37196 adet polip içeren, 35985 adet polip içermeyen görüntü elde etmişlerdir. Test aşamasında ise 7102 adet polipsiz görüntüden % 97.03' ünü (6891 adet), 4772 adet polipli görüntüden % 91.47 sini (4365 adet) % 91.76 hassasiyet (sensitivity) ile doğru sınıflandırmıştır.

Mohammed A.K. ve arkadaşları U-NET modelinden esinlenerek kolon poliplerinin lokalizasyonu için 2 adet kodlayıcı (encoder) ve bir adet kod çözücüden (decoder) oluşan Y-Net adını verdikleri CNN modeli geliştirmişlerdir. Kodlayıcı bloğunda 2 adet önceden eğitilmiş VGG19 CNN modeli farklı öğrenme katsayısı (learning rate) ile ince ayar yapılarak kullanılırken, kod çözücü kısmı ise sıfırdan eğitilmiştir. Çalışmada ASU MAYO verisetinden elde edilen görüntülere döndürme, yakınlaştırma ve x-y ekseninde hareket ettirme yöntemiyle veri artırma teknikleri uygulanmıştır. Eğitim verisetinde 4278 polipli görüntü test verisetinde ise 4300 adet polipli görüntü yer almaktadır. %87.4 precision, %84.4 recall, %85.9 F1 skoru elde edilmiştir. (Mohammed, A.K vd. 2018)

Shin vd. 2018 otomatik bölgesel kolon polip tespiti için 90 farklı kategoriden 112000 görsel içeren Microsoft (MS) COCO (Common Objects in Context) veriseti ile önceden eğitilmiş Inception Resnet-v2 CNN modelinden faydalanmıştır. Kolonoskopi sırasında ışığın yansımaları sebebiyle polip olmayan bir alan CNN modelinin yanlış alarm vermesi sebebiyle başarımını düşürmektedir. Bu sorunu çözmek için CVC Clinic DB ile eğitilmiş Inception ResNet V2 modeline ASU MAYO veritabanı içinde sağlıklı bireylere ait polip içermeyen görüntüleri kullanarak %99 eşik değerini aşan, polipli olarak tahminlenen 654 adet yanlış pozitif görüntü elde etmişlerdir. Elde edilen 654 adet görüntüyü veri artırma teknikleri ile 3922 adede çıkarmışlardır. Polip tespiti için kullanılacak eğitim verisinin az olması nedeniyle veri artırma teknikleri uygulanmıştır. Görüntü bulanıklaştırma, 90 derece çevirme, %10 yakınlaştırma, %30 uzaklaştırma, rengi koyulaştırma, parlaklaştırma, x ve y ekseninde döndürme yöntemleri ile orijinal verisetini büyütürken 2 farklı eğitim seti oluşturmuşlardır. Faster R-CNN modeli orijinal eğitim verisi ile %33.7 recall, %27.1 precision model zayıf bir performans göstermiştir. 18594 adet görüntü içeren Aug-I veriseti ile eğittiklerinde %86.5 precision, %80.3 recall ve %83.3 F1 skoruna ulaşmışlardır. 28600 adet görüntü içeren Aug-II veriseti ile model eğitildiğinde ise %91.4 precision, %71.2 recall ve %80 F1 skoruna erişilmiştir.

Akbari, Mojtaba vd. (2018) çalışmalarında CNN mimarisine dayalı polip tespit yöntemi önermişlerdir. Özellik çıkarımı ve sınıflandırma için sırasıyla dört evrişim ve havuzlama katmanının ardından iki tam bağlantılı katman kullanmışlardır. Ayrıca önerilen ağırlık boyutunu küçültmek için ağırlıkları ve filtreleri ikili (binary) hale getirmişlerdir. Ağırlıkların ve filtrelerin ikili hale getirilmesi, ağırlık boyutunun küçülmesine ve hesaplama hızının artmasına yardımcı olmuştur. Asu Mayo Test klinik veri tabanında hem kayan nokta hem de ikili ağırlıklar sayısal olarak değerlendirilmiştir. Önerdikleri CNN modeli %90.28 doğruluk, %71.20 Dice skoru, %68.32 recall, %74.34 precision metrikleri ile başarı göstermiştir.

Wichakam vd. C-FCN adını verdikleri tam bağlantılı evrişimli sinir ağı modelini geliştirmişlerdir. Modelin katmanlarındaki ağırlıklar ImageNet ile eğitilmiş VGG16 modelinden öğrenme transferi yoluyla alınmıştır. Geleceksel olarak Dice ölçütü hesaplanırken hem polipli hem de polipsiz piksel sınıfları dikkate alınmaktadır, önerilen modelde ise özelleştirilmiş kayıp (loss) fonksiyonu sadece polip sınıfına ait piksel değerleri ile formüle edilmektedir. Yaptıkları deneysel çalışmada bu kayıp (loss) fonksiyonu ile derin sinir ağını polip alanlarını öğrenmeye zorlamışlardır. Araştırmada CVC-ColonDB den 500x574 çözünürlükte 300 görüntü , CVC-ClinicDB 384x288 çözünürlükte 612 adet görüntü kullanılmıştır. Verisetinde yer alan 912 kare görüntünün 547 adedi (%60) eğitim için, 183 adedi (%20) doğrulama, 182 adedi (%20) ise test için ayrılmıştır. Modelin eğitilmesinde rassal olarak ağırlıklar verildiğinde hesaplanan IoU değeri %30.14 iken transfer öğrenmesi ile gelen ağırlıklar kullanıldığında %69.67 luk IoU skoru elde edilmiştir. FCN modelinde yer alan 2 adet evrişim (convoluiton) katmanını kaldırarak hesaplanması gereken parametre sayısını azaltmışlar bu sayede modelin tahmin hızı her bir video karesi için 8 ms'ye inmiştir. Öndecen eğitilmiş modelin ağırlıkları kullanıldığında %69.67 IoU, %95.99 Dice, %88.09 precision ve %53.1 recall skorları elde edilmiştir. (Wichakam vd. 2018)

Nguyen ve Lee FCN8 tam bağlantılı evrişimli sinir ağı ve özellik haritalarının çıkarılmasında DeepLabV3 kod çözücü modeli ile polip segmentasyonu yaptıkları çalışmada ETIS-LARIB ve CVC Clinic verisetini kullanmışlardır. Eğitim verisetini büyütmek için polip sınırlarını aşmayacak şekilde polip merkezinden en yakın pikseli yarıçap kabul ederek çizdikleri dairesel alanları eklemişlerdir. Dairesel şeklin piksel değerlerini siyah renkle doldurarak derin öğrenme modeline polipin tamamı yerine sınırlarını öğretmeyi amaçlamışlardır. Modeli eğitirken çözünürlüğü 500x375 olan görüntülerle eğitilen model küçük poliplerin tespitinde zayıf kalmıştır. Bu sebeple 280x180 piksellik görüntülerle eğitilen Model 1, 384x288 piksellik veriseti ile eğitilen Model 2, 500x375 lik veriseti ile eğitilen Model 3'ü oluşturmuşlardır. Test aşamasında eğitilen bu 3 modelden hangisi en yüksek olasılık değerini veriyorsa onun tahminini kullanılmıştır. EtisLarib veritabanında %97.5 doğruluk, %82.9 Dice skoru, %84.25 IoU değeri elde edilmiştir. Önerilen model CVC Clinic DB verisetinde ise %98.4 doğruluk, %88.9 dice skoru, %89.35 IoU değeri ile başarı göstermiştir. (Nyugen, Lee 2018)

Wickstrøm vd. (2018) araştırmasında 36 farklı hastadan elde edilen 912 adet renkli kolonoskopi görüntüsü içeren EndoScene verisetini kullanmıştır. Eğitim veriseti 20 hastaya ait 547 görüntüden, doğrulama veriseti 8 hastaya ait 183 görüntüden, test veriseti ise 8 hastaya ait 182 adet kolonoskopi görüntüsünden oluşmaktadır. Modelin eğitiminde doğrulama yapılırken IoU skoru 30 kez aynı değerde kalırsa erken durdurma (early-stopping) uygulanmıştır. FCN-8 modelini kullanarak piksel seviyesinde polip segmentasyonu yaparak %76.7 Mean IoU, %94.7 doğruluk (accuracy) değerleri elde etmişlerdir.

Cengiz E. çalışmasında Kütahya Sağlık Bilimleri Üniversitesi Genel Cerrahi Anabilim Dalı, Evliya Çelebi Eğitim ve Araştırma Hastanesi Genel Cerrahi Endoskopisi Ünitesinden alınan 54 arşiv kaydına ait

93 adet polipli 216 polipsiz görüntünün 2/3 ü model eğitiminde 1/3 ü ise modelin test edilmesi için ayırarak endoskopi görüntülerini incelemiştir. Araştırmada 48 farklı CNN modeli oluşturulmuş, çeşitli aktivasyon fonksiyonları ve optimizasyon teknikleri denenmiş ara katmanda 32 nöron ve RELU aktivasyon fonksiyonu ile %98 doğruluk ile sınıflandırma yapılmıştır. (Cengiz. E, 2020)

İnce bağırsak poliplerinin saptanması için yapılan bir başka tez çalışmasında görüntü önileme için unsharp filtreleme yöntemi kullanılmış, polip içeren görüntülerin sınıflandırılması için dört farklı öğrenme algoritması kullanılmıştır. Destek vektör makinesi algoritması (SVM - support vector machine), rassal orman algoritması (Random Forest), Karar Ağacı (Decision Tree) ve Naive Bayes algoritmaları ile sınıflandırmada sırasıyla %70, %71, %63, %67 başarı elde edilmiştir. Doğruluk oranını artırabilmek için makine öğrenmesinde kullanılan bir yöntem olarak PCA özellik çıkarımına başvurulmuştur. Ayrıca bu çalışmada polip içeren ve içermeyen görüntüler veri seti içinde dengesiz bir şekilde olduğundan SMOTE yöntemi ile az sayıda olan polipli sınıftan sentetik olarak oluşturulan verilerle veri kümesi dengeli hale getirilmiş ve modeller yeniden eğitilmiştir. Dengeli veriseti ile sınıflandırmadaki başarı oranları %79, %76, %72 ve %68 olarak değişmiştir. Akalın F. (2020)

Ucuşal H. (2020) araştırmasında 300 görüntüden oluşan açık kaynaklı kvasir veriseti kullanılmıştır. Modelleme için CNN mimarisi ve maksimum aralık nesne algılama (MMOD) metodu kullanılarak çapraz geçerlilik yöntemi ile model eğitilmiştir. Veri seti %80 eğitim, %20 test olmak üzere ikiye ayrılmıştır. Eğitim ve test için kullanılacak görüntülerde yer alan polipler Imglab programı aracılığıyla elle etiketlenmiş, sınırlayıcı kutular (bounding box) çizilmiştir. Birçok katmanlı sinir ağına sahip Lenet CNN mimarisi kullanılmış, %98 kesinlik , %90 duyarlılık değerleri elde edilmiştir.

Kutlu H. (2020) bağırsak imgelerindeki poliplerin sınıflandırılmasını yaptığı çalışmasında halka açık veri seti olan ColonoscopicDataset'i kullanmıştır. Sınıfı yanlış tespit edilip gerçekte öyle olmayan görüntüleri ayırt etmek için Ayrık Dalgacık Dönüşümü (ADD) ile alt örnekleme yapılarak öznetelik boyutu indirgenmiş, destek vektör makineleri kullanılmıştır. Bu şekilde FP (false positive) oranı azaltılarak modelin başarısı artırılmıştır. CNN özneteliklerine genetik algoritma, arı kolonisi optimizasyonu, parçacık sürü optimizasyonu, gri kurt optimizasyonu yöntemleri uygulanarak öznetelik vektörü indirgenmiştir. Polip türlerinden Adenoma, Hyperplastic, Serrated ve bağırsak (lümen) için daha önceden eğitilmiş CNN algoritmalarını kullanarak %94.8 doğrulukla sınıflandırma yapılmıştır. Araştırma esnasında derin öğrenme algoritmalarından AlexNet, Resnet18, SqueezerNET CNN modelleri veri seti üzerinde uygulanmıştır.

Branch M. ve Carvalho A. tarafından U-NET mimarisi ile geliştirilen MobileNetV2 tabanlı derin öğrenme modelinde Kvasir-SEG veritabanı ile çalışılmıştır. 1000 adet polipli görüntüden oluşan veriseti %80 eğitim, %10 doğrulama ve %10 ise test için olmak üzere üç parçaya ayrılmıştır. 0 ile 255 değeri arasında yer alan gri görüntü 0 ile 1 arasında normalize edilmiştir. Veri artırma için yatay, dikey döndürme, görüntü merkezinden imge kopartma, görüntü bükme (grid distortion), yukarıdan aşağıya ve soldan sağa ayna görüntüsü alma teknikleri uygulanmıştır. Modelin geliştirilmesinde Tensorflow ve Keras çerçevesinden yararlanılmıştır. Öğrenme katsayısı olarak 0.0001, batch boyutu ise 16 olarak seçilmiş, Adadelta en iyileycisi kullanılarak model 100 eğitim dönemi boyunca eğitilmiş, 76 eğitim dönemi sonunda erken durdurma tekniği ile eğitim sonlandırılmıştır. Tahminlenen pikselin siyah veya beyaz olduğuna 0.5 eşik değerine göre karar verilmiştir. %89.71'lik dice katsayısı ve %81.64'lük IoU değeri elde edilmiştir.

**Tablo 1:Literatür Özet Tablosu**


<b>Çalışma</b>	<b>Amaç</b>	<b>Öğrenme Modeli</b>	<b>Veri Kaynağı / Yöntem</b>	<b>Model Performansı</b>	<b>Yıl</b>
<b>Tajbakhsh, Shin vd.</b>	Öğrenme Transferi ve İnce Ayar ile Polip Algılama	AlexNet CNN	ASU MAYO/ İmge Kopartma	Sens: %70	2016
<b>Yuan, Izadyyazdanabadi vd.</b>	Kolonokopi Videolarında Otomatik Polip Algılama	AlexNet CNN	ASU MAYO	Acc: %91.47 Rec: %91.76	2017
<b>Mohammed, Yayılğan vd.</b>	Evrişimli Sinir Ağları ile Kolon Poliplerinin Lokalizasyonu	Y-Net (VGG19 tabanlı)	ASU MAYO	Prec: %87.4 Rec: %84.4 F1: %85.9	2018
<b>Shin, Younghak vd.</b>	Kolon Poliplerinin Sınırlayıcı Kutu ile Lokalizasyonu	Faster R-CNN (Inception Resnet V2)	CVC-VideoClinic, ETIS-LARIB, ASU MAYO, CVC-Clinic	Prec: %91.4 Rec: %80.3 F1: % 83.3 F2: %81.5	2018
<b>Akbari, Mojtaba vd.</b>	Kolonoskopi videolarındaki görüntülerin sınıflandırılması	4 evrişim ve havuzlama 2 tam bağlantılı CNN	Asu Mayo	Acc: %90.28 Dice:%71.20 Rec: %68.32 Prec:%74.34	2018
<b>Nguyen, Lee</b>	Kolonoskopi Görüntülerinin Kodlayıcı- Kod Çözücü Modelle Segmentasyonu	DeepLabV3, FCN8 (Fully Connected Network)	ETIS-LARIB, CVC Clinic	Acc: %98.4 Dice: %88.9 IoU: %89.35	2018
<b>Wichakam, Panboonyuen vd.</b>	Kolonoskopi Videolarında Gerçek Zamanlı Polip Segmentasyonu	C-FCN (Compressed Fully Connected Network)	CVC-ClinicDB, CVC-ColonDB	IoU: %69.67 Dice:%95.99 Prec:%88.09 Recal:%53.1	2018
<b>Wickstrøm, Kristoffer vd.</b>	Kolorektal Poliplerin Semantik Segmentasyonu	FCN-8 (Fully Connected Network)	EndoScene	IoU: %76.7 Acc: %94.9	2018

<b>Cengiz E.</b>	Endoskopi Görüntülerinde Derin Öğrenme ile Poliplerin İncelenmesi, Polipli Görüntüyü Algılama	CNN (Convolutional Neural Network)	Evliya Çelebi Eğitim ve Araştırma Hastanesi Genel Cerrahi Endoskopi Ünitesi VeriSeti	Acc: %98	2020
<b>Akahn F.</b>	Kapsül Endoskopi ile İnce bağırsak poliplerinin saptanması, Polip Algılama	Random Forest, Karar Ağacı, Naive Bayes, SVM	Kid ATLAS	Acc: %79, Acc: %76, Acc: %72 Acc: %68	2020
<b>Ucuza H.</b>	Endoskopi Görüntülerinin ImgLab ile Etiketlenmesi, Polip Lokalizasyonu	Lenet	Kvasir	Acc:%98 Duy:%90	2020
<b>Kutlu H.</b>	Derin Öğrenme ile Kalın Bağırsak Poliplerinin Tespiti, Takibi, Sınıflandırılması	AlexNet, Resnet18, SqueezerNET	ColonoscopicDataset	Acc: %94.8	2020
<b>Branch M., Carvalho A.</b>	Kalın Bağırsak Poliplerinin Segmentasyonu	MobileNetV2	Kvasir	Dice:%89.71 IoU:%81.64	2021

Literatür araştırmaları sonucunda polip tespitinin dört ana grup altında yapılabildiğini söylemek mümkündür.

- **Algılama:** Tıbbi görüntü içinde polip olup olmadığı bilgisini verir, ancak polipin görüntü içindeki yeri belli değildir.
- **Sınıflandırma:** Tıbbi görüntü içinde polipin hangi türden olduğu bilgisini verir, ancak polipin görüntü içindeki yeri belli değildir.
- **Lokalizasyon:** Tıbbi görüntü içinde polipin konumunu veren ancak tam olarak şekil bilgisini veremeyen yöntemdir.

- **Segmentasyon:** Tıbbi görüntüde polipin tam olarak şeklini ve sınırlarını belirler.



Şekil 2: Kolonoskopi Görüntülerinde Poliplerin İncelenmesine Yönelik Çalışma Trendi  
Kaynak: Sánchez-Peralta, Luisa F. vd. 2020

### 1.3. Tez Çalışma Süreci

Tez çalışmasının tamamlanması için 6 aylık bir iş planı hazırlanmış olup, iş paketleri ve çalışma takvimi aşağıdaki tabloda yer aldığı şekilde gerçekleşmiştir.

**Tablo 2: Tez İş Planı**

		İş – Zaman Çizelgesi					
İş No	Yapılacak İşler	Aylar					
		1	2	3	4	5	6
1	Literatür Taraması	X	X	X			
2	Veri Toplama Araçlarının Geliştirilmesi			X			
3	Veri Toplama			X			
4	Veri Analizi				X	X	
5	Tezin Yazılması			X	X	X	X

1 nolu iş paketi olan literatür taramasında ulusal tez merkezinin <https://tez.yok.gov.tr/UlusalTezMerkezi/> web sitesinden ülkemizde yapılmış çalışmalar derin öğrenme, medikal görüntüleme, görüntü analizi, görüntü bölütleme, polip, bağırsak, endoskopi gibi anahtar kelimeleriyle taranmıştır. 2020 yılında yayınlanmış endoskopi/kolonoskopi görüntülerinde polip tespiti ile ilgili 3 adet yüksek lisans tezi ve 1 adet doktora tez çalışması bulunmuştur. Yapay sinir ağlarının çalışma prensibini ve temel kavramlarını öğrenmek için Türkçe yazılmış kitaplardan faydalanılmıştır (Nabiyev 2016, Öztemel 2020). Stanford Üniversitesinin CS231N kodlu Evrişimli Sinir Ağları ile Görüntü Tanıma ders notlarına erişilmiştir. TÜBİTAK ULAKBİM çatısı altında faaliyet gösteren DergiPark'ta yer alan akademik makalelerden görüntü işlemenin tıpta kullanımı, derin öğrenme ile görüntü analizi, transfer öğrenmesi araştırılmıştır. Birçok bilimsel makalenin yer aldığı açık ve ücretsiz kaynak olan

ArXiv sisteminden tez konusuyla ilgili derin öğrenme, semantik segmentasyon, U-Net, medikal görüntü analizi hakkında tarama yapılmıştır. Bilimsel ve akademik sosyal ağı olarak tanımlanan Researchgate, Elektrik ve Elektronik Mühendisleri Enstitüsü (IEEE), Google Scholar, Nature dergisinin makaleleri incelenmiştir. Zotero programı aracılığıyla taranan kaynaklar kayıt altına alınarak ihtiyaç halinde kaynaklara kolay ve hızlı erişim sağlanmıştır.

2 ve 3 nolu iş paketinde kullanılan veri kaynağı <https://polyp.grand-challenge.org/CVCCLinicDB/> adresinden alınmış olup, CVC-ClinicDB, Computer Vision Center Barcelona ve Hospital Clinic Barcelona işbirliği ile hazırlanmıştır. Bilimsel araştırma ve eğitim amacıyla kullanılmak kaydıyla halka açıktır. CVC-ClinicDB veritabanı içinde endoskopi videolarından alınan polip görüntüleri ve polip tarafından kaplanan alanın uzman klinisyenler tarafından elle oluşturulmuş kesin referans görüntüleri yer almaktadır (Bernal, J. vd. 2015).

4 nolu iş paketinde ise 3 nolu paketle elde edilen veri kaynağı, python dili, keras ve tensorflow kütüphaneleri kullanılarak yazılım geliştirilmiş ve analiz edilmiştir. Tez çalışmasında kullanılan masaüstü bilgisayarın grafik işleme arabiriminin (GPU) belleği geliştirilen CNN modeli için yetersiz kalması halinde daha güçlü GPU sunan Google Colab platformu (COLAB) kullanılmıştır.

5 nolu iş paketine gelindiğinde literatür taraması, veri analizi ve yapılan araştırmalar sonucu elde edilen veriler akademik olarak polip segmentasyonu alanında çalışmanın dolduracağı boşluk dikkate alınarak tez yazılmıştır. Yerli kaynaklarda polip tespiti amacıyla sınıflandırma ve lokalizasyon sahasında araştırma yapıldığından segmentasyon için yabancı kaynaklardan faydalanılmıştır.

#### **1.4. Tezde Uygulanan Yöntem**

Tıbbi görüntü analizi alanında derin öğrenme uygulamalarının uzman performansına yakın başarı gösterebildiği, elektokardiyografi (EKG) ritimlerinden aritmi sınıflandırılması için geliştirilen derin öğrenme modelinin ortalama kardiyolog duyarlılığını aştığı görülmüştür. (Hannun, Awni Y. vd. 2019.)

Tez konusuna karar vermeden önce yapılan araştırmalar neticesinde kolorektal kanserin medikal görüntü analizi ile tespitinde ülkemizde yapılan akademik tez çalışmalarının bulunduğu, ancak kansere neden olabilecek lezyonların şekil ve lokasyon bilgisini net olarak veren derin öğrenme modelinin olmadığı gözlenmiştir.

Tez çalışmasında gerçekleştirilen evrişimli sinir ağı modeli geliştirilirken biyomedikal görüntü segmentasyonunda başarılı olan, Ronneberger ve arkadaşları tarafından 2015 yılında sunulan U-Net CNN mimarisi esas alınmıştır. U-Net CNN modelinin temel hedefi görüntüye ait her bir piksel sınıfını tahmin ederek biyomedikal görüntüleri bölütmektir. Geleneksel U-NET modeline InceptionResNetV2, EfficientNetB7, DenseNet201 ile önceden eğitilmiş katmanlar transfer edilmiştir. Yosinski ve arkadaşları CNN mimarisinde girişe yakın katmanların genel özellikleri, çıkışa yakın katmanların ise girişe özgü spesifik özellikleri ortaya çıkardığına göre ağ içinde bir aşamada genel özelliklerden özele bir geçiş olduğunu ifade etmektedir (Yosinski vd. 2014). Tajbakhsh ve ekibi veriseti küçükken öğrenme transferi ile ağırlıkların korunmasının ağı tamamen eğitilmesine göre daha iyi sonuçlar verdiğini, veriseti büyütüldüğünde ise ağı bütününün eğitilmesine yakın performans verdiğini söylemektedir (Tajbakhsh N. vd. 2016). U-NET modelinin kodlayıcı ve kod çözücü katmanları yeniden eğitildiğinde, kodlayıcı kısmı eğitilmeden transfer edilen ağırlıklar kullanıldığında, darboğaz kısmı

dondurulup kodlayıcı ve kod çözücü kısımlar eğitildiğinde elde edilen sonuçlar incelenmiştir. Önerilen modelde veri artırma tekniği uygulandığında modelin performansındaki değişim sunulmuştur.

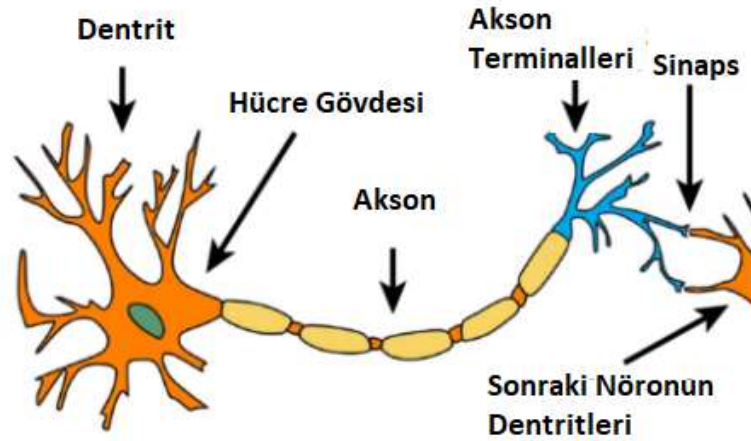


## 2. YAPAY SİNİR AĞLARI, DERİN ÖĞRENME

### 2.1. Yapay Sinir Ağları

Yapay sinir ağları (YSA), biyolojik sinir sisteminin çalışma prensiplerinden ilham alınarak tasarlanmıştır. İnsan beyninin yeni bilgi türetme, oluşturma ve keşfetme gibi yeteneklerini dışarıdan yardım almaksızın gerçekleştirebilen bilgisayar sistemleridir. YSA, insanın deneyerek veya yaşayarak edindiği öğrenmeyi örneklerden elde etmektedir. YSA dan beklenen temel fonksiyon, benzer olaylara karşılık benzer karar vererek makine öğrenmesini gerçekleştirmesidir. YSA'nın bir olayla ilgili örneklerle eğitildiğinde genelleme yapabilecek adaptif öğrenme yeteneğine sahip olması gerekir. YSA'nın güvenli bir şekilde çalıştırılabilmesi eğitim sürecinin tamamlanması, her bir örnek verinin ağa tanıtılması ile örnekle olay arasındaki ilişkilerin bulunması gerekmektedir. Öztemel, E. (2020)

#### 2.1.1. Biyolojik Sinir Hücresi



Şekil 3: Biyolojik Sinir Hücresi (Kaynak: Bagheri R., 2020)

Merkezi sinir sisteminin en önemli ögesi olan beynin işlevini yerine getirmesi hücreler arası iletişim ile olmaktadır. Bir sinir hücresi akson, dendritler ve soma (hücre gövdesi) olmak üzere üç ana kısımdan meydana gelir. Ersoy, E. & Karal, Ö. (2012)

Bu bölgelerin her biri bilgilerin girişinde ve iletilmesinde çeşitli görevler üstlenmektedir. Hücre gövdesi (soma) hücreyi denetler ve hücre etkinliklerini yönetir. Somadan dendrit ve akson adı verilen iki farklı uzantı çıkmaktadır: Dendrit hücre gövdesinden çıkan ağaç dalları şeklindedir. Dendritler hücreye gelen girişleri diğer nöronların iletim hatlarından toplayarak hücre gövdesine taşımakla sorumludur. Aksonlar ise gövdede üretilen çıkışı diğer nöronlara iletmektedir. Akson, sinaptik terminaller adı verilen ağaç dallarına benzer yuvarlak uçlu yapılarla sonlanır. Bir nöron diğer bir sinir hücresi ile doğrudan temas etmemekte, akson terminalleri ile diğer hücre dendritleri arasında sinaps adı verilen aralıklar bulunmaktadır. Akson boyunca iletilen dürtü sinaptik terminallere geldiğinde nörotransmitter adı verilen kimyasal maddeler boşluğa yayılarak sonraki sinir hücresinin dendritlerinde elektriksel bir itki oluşturur.

Her bir sinir hücresi on bin sinaps aracılığıyla diğer nöronlarla haberleşir. Akson ve dentritlerin arasında yer alan sinapsların bilginin uzun süreli saklandığı yer olduğu düşünülmektedir. NabiyeV, V.V. (2016)


**Tablo 3: Biyolojik Sinir Sistemi ile Yapay Sinir Sistemi Karşılaştırması**

Biyolojik (Fiziksel) Sinirler	Yapay Sinirler
Hücre	Nöron
Sinir eklemi	Bağlantı Ağırlıkları
Destekleyici (excitatory) Giriş	Pozitif Bağlantı Ağırlığı
Yasaklayıcı (Inhibitory) Giriş	Negatif Bağlantı Ağırlığı
Değişken uyarı girişi	DC uyarı seviyesi
Hücre fiziği ile sınırlı aktifleme aralığı	İşlemciye özgü sınırlı aktifleme aralığı

Kaynak: NabiyeV, V.V. (2016)

### 2.1.2. Yapay Sinir Hücresi (Perceptron)

1958 de ilk defa Frank Rozenblatt (Rosenblatt, F. (1958)) tarafından ortaya atılan perceptron modeli gelişmiş öğrenme modellerinin temelini oluşturmaktadır.

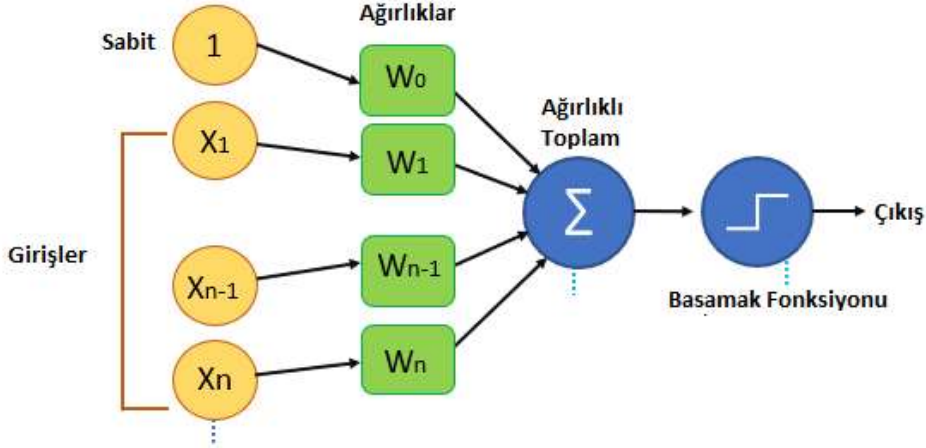


Şekil 4: Bir sinir hücresinin matematiksel modeli (Özcan A. 2020)

- **Giriş:** Nörona dış dünyadan, başka bir nöronun veya kendisinden gelen bilgidir, hesaplanması için hücre çekirdeğine yollanır.
- **Ağırlık:** Yapay sinir hücresine giren değerlerin ağırlığını ve çıktıya olan katkısını gösterir. Negatif, pozitif veya sıfır değeri olabilir.
- **Toplam Fonksiyonu:** Yapay sinir hücresinde ağırlıklı toplama, hücrenin net girdisini hesaplayan fonksiyondur.
- **Aktivasyon Fonksiyonu:** Hücreye gelen net değeri kullanarak çıkış değerini belirler.
- **Çıkış:** Aktivasyon fonksiyonu ile belirlenmiş çıktı değeridir. Bu değer bir sonraki sinir hücresine giriş değeri ya da dış dünyaya çıktı olarak sunulabilir.

### 2.1.3. Yapay Sinir Hücresi Öğrenmesi

Perceptron algoritması danışmanlı (supervised) makine öğrenmesi kapsamında olup, sınıflandırma için kullanılmaktadır. Veri kümesi düz bir doğru aracılığıyla iki farklı sınıfa ayrılır, bu doğruya doğrusal ikili sınıflandırıcı denir. Perceptron öğrenmesi, istenen çıkış değerleri elde edilene kadar her bir giriş değerinin ağırlık katsayılarının geri beslemelerle güncellenmesi ile gerçekleşir. (Nabiyev, V.V. (2016))



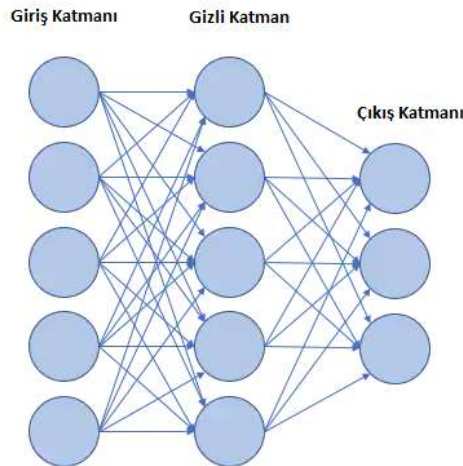
Şekil 5: Perceptron Blok Diyagramı

Kaynak: <https://www.educba.com/perceptron-learning-algorithm/>

Birim basamak fonksiyonu yapısı gereği 0 veya 1 değerini üretir. Kompleks problemlerin çözümünde lineer olmayan (non-linear) aktivasyon fonksiyonlu sigmoid nöron modeli kullanılmaktadır. (Ölmez E. (2020))

### 2.1.4. Çok Katmanlı Algılayıcı (Multi Layer Perceptron - MLP)

Yapay sinir ağlarında doğrusal olmayan ilişkilerin çözümünde basit algılayıcıları kullanmak mümkün değildir. Bu tür durumlarda daha karmaşık bir yapıya sahip olan çok katmanlı algılayıcı (MLP) modeli kullanılması gerekmektedir. Mantıksal bir fonksiyon olan XOR probleminin çözümü yapay sinir ağlarında önemli bir dönüm noktası olarak görülmekte olup, bu kapsamda yapılan çalışmalar neticesinde çok katmanlı algılayıcı modeli geliştirilmiştir.



Şekil 6: Tek gizli katmana sahip yapay sinir ağı modeli  
Kaynak: (www.ibm.com)

- **Giriş Katmanı:** Dış dünyadan gelen girdilerin her hangi bir işleme tabi tutulmadan bir sonraki katmana iletiildiği yerdir. Giriş katmanında yer alan her bir giriş sonraki katmandaki her bir nörona tam bağlıdır.
- **Ara (Gizli) Katman:** Giriş katmanından aldığı bilgileri işleyerek bir sonraki katmana gönderir, tek başına bir sinir ağı gibi çalışır. Ara katmanda yer alan her bir nöron bir sonraki katmanda yer alan nörona tam bağlıdır.
- **Çıkış Katmanı:** Gizli katmandan almış olduğu girdileri işleyerek dış dünyaya çıktı üretir. Çıkış katmanında birden fazla nöron bulunabilir, her bir nöronun tek bir çıkış değeri vardır.

Çok katmanlı yapay sinir ağları gözetimli öğrenme yöntemini kullanır. Ağın kendisine verilen örneklerle birlikte beklenen çıktı değerlerini de kullanması, genelleştirme yapması ve daha önce gösterilmemiş örneklere çözüm üretmesi gerekir. (Öztemel, E. (2020))

YSA mimarileri nöronlar arası bağlantıların yönüne bağlı olarak ileri beslemeli (feed forward) ve geri beslemeli (feed backward) olmak üzere iki gruba ayrılır. Ataseven, B. (2013).



Şekil 7:Yapay Sinir Ağları Türleri (Abiodun vd. 2018)

### 2.1.5. Geri Yayılımlı Öğrenme

Çok katmanlı ağ modellerinde öğrenme türlerinden biri de geri yayılımlı (back propagation) öğrenmedir. Perceptron öğrenmesinden farklı olarak aktivasyon fonksiyonu olarak 0 ile 1 değerleri arasında reel bir sayı üreten sigmoid fonksiyonunu kullanır. Geri yayılımda öğrenme süreci rassal olarak belirlenen ağırlık katsayıları ile başlar, en uygun ağırlık değerlerinin bulunması için ağ defalarca eğitilir. Giriş katmanından öğretilmesi istenen vektörler karışık olarak verilir, gizli katman ise ağın zekasını temsil eder. Gizli katmanda nöron sayısı çok fazla olursa ağ ezberlemeye meyyleder. Gizli katmanda nöron sayısının belirlenmesi ağın öğrenme performansını etkileyen bir unsur olduğundan, başlangıçta 2,3 nöronla başlanarak 5,10,20 nöronla gizli katmanı oluşturup başarı değerlendirmesi tavsiye edilmektedir. (Nabiyev, V.V. (2016))

Geril Yayılım Algoritması İşlem Adımları

1. Girişteki ve gizli katmandaki nöronlara ilk değer olarak (-0.1,0.1) arasında ağırlıklar verilir.
2. Modele öğretilcek değer vektör olarak giriş verilir.


3. Lineer olmayan sigmoid fonksiyonu ile giriş katmanından gizli katmana oradan da yine sigmoid fonksiyon ile çıkış katmanına ulaşır.
4. Modele eğitim için verilen gerçek çıkış ile o an hesaplanan çıkış değeri karşılaştırılır ve hata hesaplanır. Hata değeri belirlenmiş olan eşik değerini geçtiğinde çıkış katmanından gizli katmana, gizli katmandan giriş katmanına doğru geriye yayılır.
5. Ağırlık katsayıları hataya göre yeniden hesaplanarak 2. adıma dönülür.

### 2.1.6. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları yapay sinir ağlarında kritik bir öneme sahiptir. Sinir ağının karmaşık problemlere çözüm üretebilmesi için doğrusal olmayan ilişkileri de öğrenebilmesi gerekmektedir.

- **Basamak Fonksiyonu**


İkili sınımlandırıcı olarak 0 veya 1 değeri üretir, sinir ağının çıkış katmanında kullanılır.



Şekil 8: Basamak Fonksiyonu ve Türevi

- **Doğrusal (Linear) Fonksiyon**


Çıkış değeri basamak fonksiyonu gibi ikili değer değil, sürekli değer üretir. Türevi sabittir.



Şekil 9: Doğrusal Fonksiyon ve Türevi

- **Sigmoid Fonksiyon**

Çıkış değerlerini 0 ve 1 arasında sürekli değer olarak üretir, en sık kullanılan aktivasyon fonksiyonudur. Dezavantajı ise x giriş değerinin değişimine karşılık y çıkışının çok az değişmesine neden olmasıdır.




Şekil 10: Sigmoid Fonksiyon ve Türevi

Giriş değeri büyüdükçe türev çok küçülür ve 0'a yakınsar buna kaybolan eğim (vanishing gradient) denir, bu noktada öğrenme minimumdur. (Kızrak, A. 2020)

- **Hiperbolik Tanjant Fonksiyonu**


Sigmoid fonksiyonuna benzemekle birlikte çıkış değerlerini (-1,1) aralığında sürekli olarak üretir.



Şekil 11: Hiperbolik Tanjant Fonksiyonu ve Türevi

- **RELU (Rectified Linear Unit)**

Hesaplama hızına olan katkısından dolayı sigmoid ve hiperbolik tanjant fonksiyonuna göre daha sık tercih edilmektedir. Fonksiyon 0 dan küçük giriş değerleri için sıfır değerini üretirken 0 dan büyük değerler için lineer bir fonksiyon gibi davranmaktadır. Agarap, A. F. (2018) tarafından yapılan bir araştırmada çıkış katmanında sınıflandırma için softmax fonksiyonu yerine RELU fonksiyonu kullanılmış, MNIST veri seti ile softmax fonksiyonuna yakın doğrulukla sınıflandırma yapılmıştır.



Şekil 12: ReLU Fonksiyonu ve Türevi

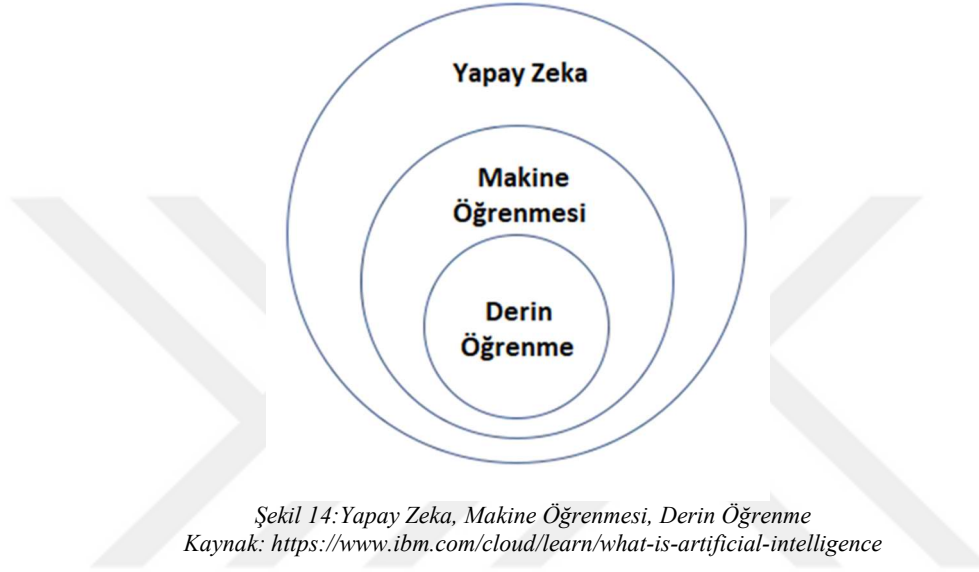
AKTİVASYON FONKSİYON	DENKLEM	ARALIK
Doğrusal Fonksiyon	$f(x) = x$	$(-\infty, \infty)$
Basamak Fonksiyonu	$f(x) = \begin{cases} 0 & \text{için } x < 0 \\ 1 & \text{için } x \geq 0 \end{cases}$	$\{0, 1\}$
Sigmoid Fonksiyon	$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$	$(0, 1)$
Hiperbolik Tanjant Fonksiyonu	$f(x) = \tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$	$(-1, 1)$
ReLU	$f(x) = \begin{cases} 0 & \text{için } x < 0 \\ x & \text{için } x \geq 0 \end{cases}$	$[0, \infty)$

Şekil 13: Aktivasyon Fonksiyonlarının Matematiksel Gösterimleri Kaynak: Kızrak, A. 2020

### 2.1.7. Derin Öğrenme, Makine Öğrenimi, Yapay Zeka İlişkisi

Bilgisayar biliminde yapay zeka terimi, bir bilgisayar veya başka bir makine tarafından sergilenen insan benzeri zekayı ifade eder. Yapay zeka, bir bilgisayarın veya makinenin insan zihninin yeteneklerini taklit etme, örneklerden ve deneyimlerden öğrenme, nesnelere tanıma, dili anlama ve yanıt verme, karar verme, problem çözme yeteneğini belirtir.

Yapay zekanın karar verme ve tahminleme süreçleri makine öğrenmesi ile olmaktadır. Makine öğrenmesi danışmanlı, danışmansız öğrenme yöntemlerini kullanarak sınıflandırma ve kümeleme işlemlerini yapar.



Şekil 14: Yapay Zeka, Makine Öğrenmesi, Derin Öğrenme  
Kaynak: <https://www.ibm.com/cloud/learn/what-is-artificial-intelligence>

Makine öğrenimi, yapay zekanın bir alt alanıdır. Makine öğreniminde, algoritmalar, yeni verilere dayalı kararlar ve tahminler yapmak için verideki kalıpları ve özellikleri bulmak üzere eğitilir. Algoritma ne kadar iyi olursa, daha çok veri ile beslendikçe ürettiği tahminler o kadar doğru olur.

Bir makine öğrenimi modeli oluşturmanın dört temel adımı vardır:


- Eğitim için veri setinin hazırlanması
- Eğitim veri setinde çalıştırılacak algoritmanın seçilmesi
- Modeli oluşturmak için algoritmanın eğitilmesi
- Modelin performansının test edilmesi, kullanılması ve geliştirilmesi

Derin öğrenme ise makine öğreniminin bir alt kümesi olmakla birlikte derin öğrenme algoritmalarının omurgasını yapay sinir ağları oluşturur. Derin öğrenmedeki "derin" kelimesi bir sinir ağındaki katmanların derinliğinden gelir. Üçten fazla katmandan oluşan, girdileri ve çıktıları içeren bir YSA, derin öğrenme algoritması olarak düşünülebilir.

### 3. EVRİŞİMLİ SİNİR AĞLARI


Evrışimli Sinir Ağları (Convolutional Neural Network - CNN) biyolojik görme merkezinin yapısından hareketle tasarlanmış, çok sayıda katmandan oluşan derin öğrenme yöntemidir. Beynin görme merkezinde yer alan nöronların görme işlevinin gerçekleşmesinde farklı görevleri bulunmaktadır. Örneğin bazı nöronlar çizgilerin yatay olmasına göre tepki verirken, bir kısmı dikey çizgiler algılandığında, diğer bir grup nöron ise çapraz çizgilerle aktivasyona geçmektedir. Nöron gruplarının farklı fonksiyonları yerine getirmesi düşüncesi CNN'nin temelini teşkil etmektedir. (Wani vd. 2020)

CNN nesne tespiti, sesin tanınması, görüntü sınıflandırma, medikal görüntü analizi, doğal dil işleme gibi birçok alanda olağanüstü başarı göstermiştir. Kendiliğinden sürüş yeteneğine sahip araçlar, insansız hava araçları CNN' nin kullanıldığı uygulama alanlarından birkaçıdır. CNN'de temel hedef giriş katmanında görüntü gibi bir girdiden lokal özelliklerin çıkarılması ve alt katmanlarda bu özelliklerin birleştirilerek yeni öz niteliklerin oluşturulmasıdır. CNN'lerin çok katmanlı yapısı nedeniyle büyük veri kümeleri ile çalışıldığında yüksek hesaplama kapasitesine sahip bilgisayarlara ihtiyaç duyulmaktadır. Bu sebeple merkezi işlem birimi (CPU) ile günlerce devam edecek eğitim süreci için güçlü grafik işlemci birimine (GPU) sahip makineler tercih edilmektedir. Özcan A. R. (2020)



Şekil 15: Evrışimli Sinir Ağları Genel Mimarisi (Saha, S. 2018)

Görüntü sayısallaştırılırken her bir piksele ait değerlerin sahip olduğu parlaklık seviyesi 0 ile 255 arasında değer alacak şekilde kodlanır. 0 değeri siyah renge karşılık gelirken 255 ise beyaz rengi temsil etmektedir.

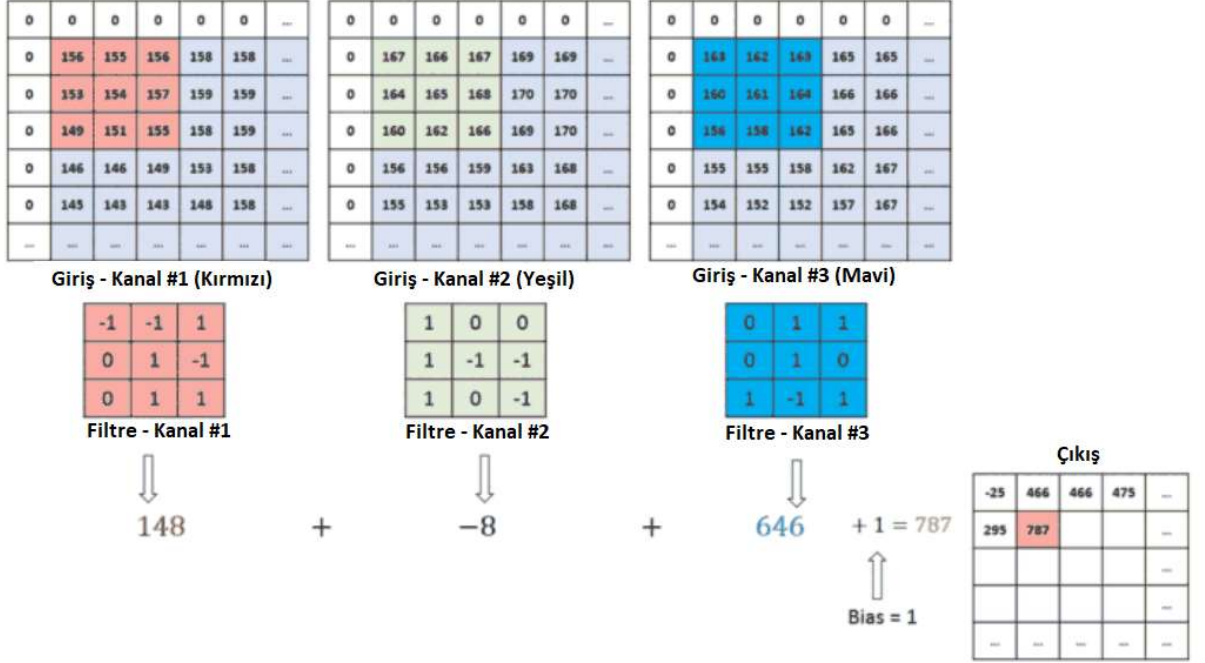


Şekil 16: 16 x 16 'lık ızgara ile 256 farklı gri seviyenin gösterimi.

(Kaynak: [http://www.ibrahimcayiroglu.com/Dokumanlar/GoruntuIsleme/Goruntu\\_Isleme\\_Ders\\_Notlari-1.Hafta.pdf](http://www.ibrahimcayiroglu.com/Dokumanlar/GoruntuIsleme/Goruntu_Isleme_Ders_Notlari-1.Hafta.pdf))



renk kanalına sahip bir görüntüde her bir kanal için hesaplanan değer toplanır, çıkış değeri oluşturulur. (İnik, Ö, Erkan Ü. 2017)



Şekil 19:  $M \times N \times 3$  giriş matrisine  $3 \times 3 \times 3$  filtre ile evrişim (Saha S. 2018)

### 3.1.3. Aktivasyon Katmanı

CNN da evrişim katmanının peşinden devreye giren kısım düzleştirici katmandır. En sık kullanılan aktivasyon fonksiyonu ise RELU dur. Aktivasyon katmanının girişinde veri doğrusal haldeyken bu katmanın çıkışında doğrusal olmayan bir hale gelir. RELU matematiksel olarak negatif değerleri sıfıra çekerken pozitif değerler için doğrusal davranmaktadır.

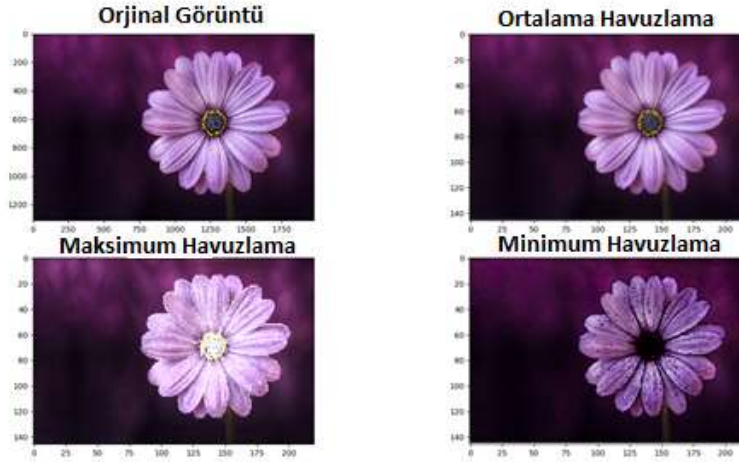
$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (1)$$



Şekil 20: RELU Katmanının Giriş Görüntüsüne Etkisi (İnik, Ö, Erkan Ü. 2017)


### 3.1.4. Havuzlama Katmanı

Havuzlama katmanına gelen veriye uygulanan filtreye karşılık gelen pikseller üzerinde yaygın olarak kullanılan üç tür havuzlama yöntemi vardır.



Şekil 21: Görüntüye uygulanan havuzlamanın etkisi (Basavarajaiah, M. 2019)

- Maksimum Havuzlama: Filtreye karşılık gelen matristeki en büyük değer
- Ortalama Havuzlama: Filtreye karşılık gelen matristeki değerlerin ortalaması
- Minimum Havuzlama: Filtreye karşılık gelen matristeki en küçük değer



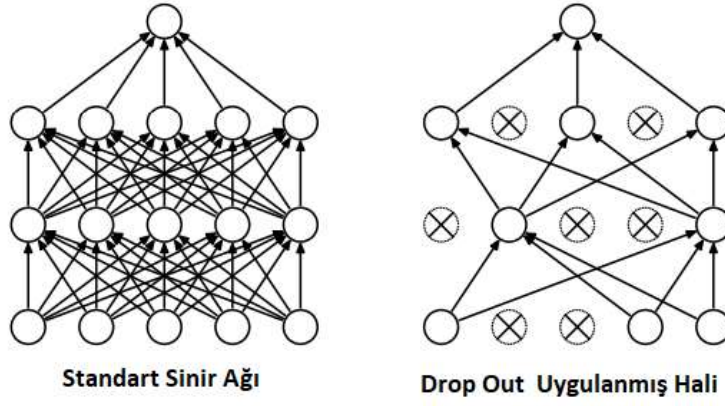
Şekil 22: Maksimum Havuzlama (Ergin, T. 2018)

### 3.1.5. Tam Bağlantı Katmanı

CNN mimarisinde giriş görüntüsü evrişim katmanı, aktivasyon (RELU) katmanı, havuzlama katmanlarından geçerek tam bağlantılı katmana gelir. Bu katmanda yer alan her bir nöron bir önceki katmanın tüm nöronlarına bağlıdır.

### 3.1.6. Seyreltme (Dropout) Katmanı


Yapay sinir ağı eğitiminde modelin belirli bir aşamadan sonra eğitim verisini ezberlemeye yöneldiği görülebilmektedir. Bu problemi ortadan kaldırmak için seyreltme (drop out) yöntemi kullanılmaktadır. Drop out işlemi katmanda yer alan sinir hücrelerinin bir kısmının geçici olarak ağdan çıkarılması ile yapılır. Bu aşamada bu nöronlara giren ve o nöronlardan çıkan bağlantıların tamamı ortadan kaldırılır. Hangi nöronların modelden geçici olarak çıkarılacağı rastgele olarak seçilir. (Srivastava vd. 2014)



Şekil 23: Seyreltme (Drop out) İşlemi (Srivastava vd. 2014)

### 3.1.7. Softmax Sınıflandırma Katmanı

Tam bağlantılı katmanın ardından gelen bu katman sınıflandırma yapmaktadır. Katmanın çıkış sayısı sınıflandırması yapılmak istenen nesne sayısı kadardır. Örneğin el yazısı ile yazılmış rakamları tanıyan bir CNN için çıkış katmanında her bir sınıf (0,1,2,3,4,5,6,7,8,9) için (0,1) arasında olasılık belirten bir çıkış değeri üretilir. Örneğin şekil 20 de gösterilen rakam 4 için en yüksek olasılığı verirken 7 veya 9 rakamlarına da benzediğinden 4 rakamına yakın olasılık değerleri üretilmiştir.



Şekil 24: Sınıflandırma katmanı çıkış değerleri  
(Kaynak <https://github.com/Kulbear/deep-learning-nano-foundation>)

## 3.2.Hiperparametreler

Veriden öğrenme yöntemine dayanan YSA modeli tasarlanırken karar verilmesi gereken bazı değişkenler bulunmaktadır. Örneğin derin sinir ağlarında kullanılacak seyreltme (drop out) değeri, gizli katman sayısı, her bir katmanda yer alacak nöron sayısı gibi değerler bir parametredir. Modeli tasarlayan kişinin çözülmek istenen probleme, veri setine göre karar verdiği bu değerlere hiper parametre denmektedir.

Modelin en başarılı olduğu optimum hiper parametre değerlerinin bulunması çözümlenmesi gereken önemli sorunlardan biridir. Hiper parametrelerin seçimi tasarımcının tecrübesine, veri setinin büyüklüğüne, güncel yaklaşımlara göre değişmektedir. Veri kümesinin büyüklüğü modelin eğitimi için harcanan süreyi, eğitim sırasında kullanılacak bellek ve işlemci gücünü etkileyecektir.


Veri setinin büyüklüğü kadar verinin çeşitliliği de önemlidir, veri seti büyüdükçe genel olarak başarı oranı yükselse de bir aşamadan sonra öğrenme iyice azalmaya başlayacaktır. (Çarkacı, N. 2018)

### 3.2.1. Öğrenme Katsayısı (Learning Rate)

Öğrenme katsayısı derin öğrenmenin her bir yinelenmesinde ağırlıkların güncellenmesi için kullanılır. Optimizasyon işlemi maliyet (cost) fonksiyonunu en az değere indirecek yerel veya global minimum değerini bulmakla olur. Gradyan iniş (gradient descent) en çok bilinen optimizasyon algoritmalarından biridir, sınır ağındaki parametrelerin değerlerinin güncellenmesinde birinci dereceden türev kullanılmaktadır.


w ağırlık katsayısı ve b sapma değerini göstermek üzere iki parametrenin değerini bulmaya çalıştığımızı düşünelim.

- Ağırlık değeri olan w ve sapma b değerine rastgele ilk değer atanır.
- Öğrenme katsayısı olan  $\alpha$  için bir değer seçilir. Her bir yinelenmede parametrelerin yeni değerinin belirlenmesinde  $\alpha$  katsayısı kullanılır. Öğrenme katsayısı çok küçükse hesaplama uzun sürebilir, çok büyükse minimum değer atlanabilir.
- Her yinelenmede maliyet fonksiyonu olan  $J(w)$ ' nin her bir parametre için kısmi türevi alınır, türevin sıfır olduğu noktaya ulaşılmaya çalışılır.



Şekil 25: Gradyan iniş algoritmasının, minimum değer için ilk türevi kullanması. (Dabbura, I. 2019)

Öğrenme katsayısının seçimine göre eğitim döneminin sayısı ve maliyet fonksiyonun minimum değerine ulaşma durumu değişkenlik gösterir. En sık kullanılan öğrenme katsayıları 0.001, 0.003, 0.01, 0.03, 0.1 ve 0.3 değerleridir.



Şekil 26: Farklı öğrenme katsayıları ile gradyan iniş (Karpathy A. (2021, 6 Şubat))

### 3.2.2. Mini-Batch Boyutu

Derin öğrenmede verisetindeki tüm verileri aynı anda işlemek bellek, işlemci, zaman açısından maliyet oluşturur. Bu sebeple veri seti küçük parçalara ayrılarak öğrenme işlemi daha küçük veri setleri üzerinde yapılır. Modelin aynı anda kaç veriyi işleyeceği mini-batch parametresinin değeri ile belirlenir. Batch

boyutu 1 ile verisetindeki kayıt sayısı arasında olmalı, değeri belirlenirken 2 ve 2'nin katları olarak seçilebilir. Mini batch boyutu CNN modellerinin başarısı etkileyen faktörlerdendir.

### 3.2.3. Eğitim Dönemi (Epoch) Sayısı

Derin öğrenme modelinin giriş katmanından giren verinin eğitim aşamasında geriye yayılım yöntemi ile ağırlıklarının güncellendiği her bir tura eğitim dönemi (epoch) denmektedir. Problemi çözmek için ağırlık değerlerinin belirlendiği ilk turlarda başarımlar düşük olacak, tur sayısı arttıkça başarı oranı da yükselecektir. Belirli bir adım sayısından sonra ise öğrenme iyice azalacaktır. Bu aşamadan sonra eğitimi sonlandırmak uygun olur. (Çarkacı, N. 2018)


### 3.3.Kayıp (Loss) Fonksiyonları

Görüntü segmentasyonu amacıyla geliştirilen derin öğrenme modellerinde kullanılacak kayıp fonksiyonunun seçimi algoritmanın öğrenme süreci için çok önemlidir.

#### 3.3.1. Binary Cross Entropy

$$L_{BCE}(y, \hat{y}) = -(y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})) \quad (2)$$

Piksel seviyesinde ikili sınıflandırma için yaygın olarak kullanılır. Dengeli verisetleri için daha başarılı sonuçlar verir.



Şekil 27: Binary Cross Entropy Fonksiyonu: X eksenli olasılık değeri, Y eksenli Entropi

#### 3.3.2. Log-Cosh Dice Loss

Jadon, S. (2020) ve arkadaşları tarafından önerilen bu kayıp fonksiyonu Dice Loss fonksiyonunun özelleştirilmiş hali olup, 3 nolu formül dice fonksiyonunu 4 nolu denklem ise log cosh dice loss fonksiyonunu göstermektedir

$$L_{dice} = \frac{2 * \sum p_{true} * p_{pred}}{\sum p_{true}^2 * p_{pred}^2 + \epsilon} \quad (3)$$

$$L_{lc-d} = \log(\cosh(L_{dice})) \quad (4)$$


#### 3.3.3 Focal Twersky Loss

Dengesiz (imbalanced) verisetleri ile başarılı bir şekilde çalışmaktadır. Twersky indeksi 5 nolu formülle hesaplanır.

$$TI = TP / (TP + \alpha FN + \beta FP) \quad (5)$$

Focal Twersky Loss ise 6 nolu formülle hesaplanır.

$$FTL = \sum_c (1 - TI_c)^\gamma \quad (6)$$




Şekil 28: Focal Twersky Loss Fonksiyonu

(Kaynak: <https://towardsdatascience.com/dealing-with-class-imbalanced-image-datasets-1cbd17de76b5>)

### 3.4. Evrişimli Sinir Ağı Modelleri

#### 3.4.1. Lenet-5

LENET-5 mimarisi Yann LeCun ve arkadaşları tarafından 1998 yılında ortaya atılan evrişimli sinir ağı modelidir. Posta numaraları ve banka çekleri üzerindeki sayıların tanınması amacıyla geliştirilmiştir. Modelin eğitimi ve testi için MNIST (Modified National Institute of Standards and Technology) veritabanı kullanılmıştır. MNIST veritabanı içinde el yazısı ile yazılmış 60000 adet eğitim ve 10000 adet test verisinden oluşan 70000 adet rakam bulunmaktadır.




Şekil 29: Lenet Ağının Mimarisi (Lecun, Y. Vd. 1998)

Lenet-5 ağı giriş katmanı, peş peşe konmuş evrişim (konvolüsyon) katmanı, ortalama havuzlama katmanı, evrişim katmanı, tam bağlantılı katman ve çıkış katmanından oluşmaktadır. Aktivasyon fonksiyonu olarak sigmoid ve hiperbolik tanjant fonksiyonu kullanılmaktadır. Model girdi katmanından aldığı rakamı 0 ile 9 aralığında bir sonuç olarak tahmin edeceğinden sınıflandırma katmanı 10 adet çıkışa sahiptir. (Lecun, Y. Vd. 1998)

### 3.4.2. Alex-Net

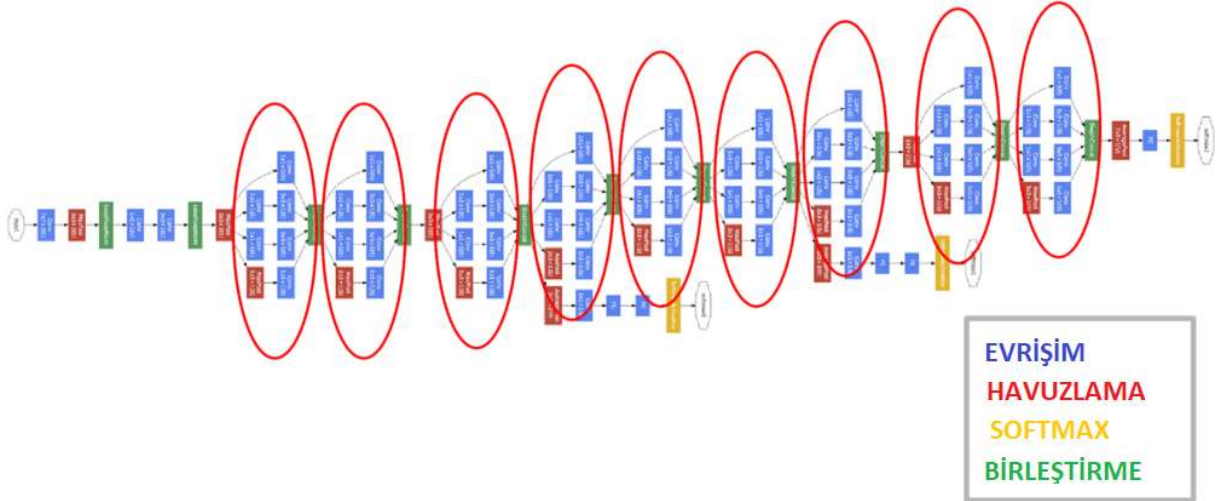
AlexNet, Alex Krizhevsky ve ekibi tarafından 2012 yılında gerçekleştirilen ILSVRC-2012 görüntü sınıflandırma yarışmasını kazanan evrişimli sinir ağı modelidir. Model ilk 5 katmanı evrişim katmanı, son 3 katmanı ise tam bağlantılı katman olmak üzere 8 katmandan oluşmaktadır. Katmanlar arası havuzlama ve aktivasyon katmanları bulunmaktadır. Çıkış katmanı 1000 farklı görüntüyü sınıflandırmak üzere tasarlanmış ve nesne tanımlamada sınıflandırma başarı oranını %74.3 den %83.6 ya çıkarmıştır. Aktivasyon fonksiyonu olarak RELU fonksiyonu kullanılmıştır, birbirine paralel olarak çalışan iki farklı GPU üzerinde eğitilmektedir. Model 224x224 boyutunda görüntüyü girdi olarak kabul etmektedir. (Understanding AlexNet | Learn OpenCV, 2018)



Şekil 30: Alex-Net Mimarisi (Krizhevsky A. vd. 2012)


### 3.4.3. GoogLeNet

GoogLeNet 2014 yılında Google çalışanı Christian Szegedy ve ekibi tarafından ortaya atılan CNN modelidir. Hata oranını % 7' nin altına düşürerek ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) 2014 yarışmasını kazanmıştır. GoogLeNet mimarisi 22 katmandan oluşmaktadır. Bu katmanlar toplam 9 adet başlangıç (inception) modülünden oluşur.



Şekil 31: GoogLe-Net Mimarisi (Szegedy, Liu et al. 2015)

Her bir inception modülü çeşitli boyutlardaki filtrelerden oluşan evrişim katmanı ve maksimum havuzlama katmanından oluşmaktadır. Örneğin  $28 \times 28 \times 192$  boyutundaki bir girdiye uygulanan  $5 \times 5$  lik evrişim işleminde  $28 \times 28 \times 32$  lik bir çıktı elde edilmektedir. Sadece bu evrişim katmanında hesaplanması gereken parametre sayısı  $(28 \times 28 \times 192) \times (5 \times 5 \times 16) = 120$  milyon civarındadır. C. Szegedy ve ekibi 'Ağ içinde Ağ' makalesine atıfla her bir evrişim katmanından önce  $1 \times 1$  lik evrişim katmanı ekleyerek hesaplama maliyetini optimize etmeyi amaçlamışlardır.

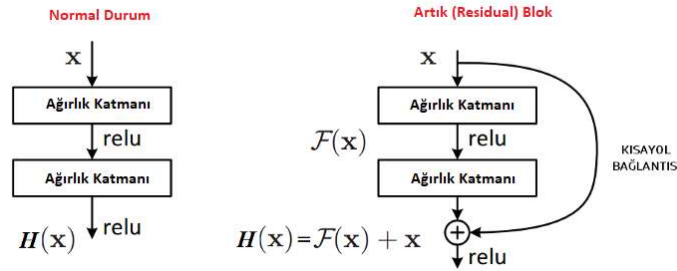


Şekil 32: Ağ içinde Ağ (Kızrak, A. 2020)

Ağ içinde Ağ yöntemi ile  $(28 \times 28 \times 16) \times (1 \times 1 \times 192) = 2,4$  milyon ve  $5 \times 5$  evrişim katmanında ise  $(28 \times 28 \times 32) \times (5 \times 5 \times 16) = 10$  milyon parametre ile toplam 12.4 milyon parametrenin hesaplanması gerekmektedir. Naive Inception modeline göre hesaplanacak parametre sayısı 10 kat azalmıştır.

### 3.4.4. Resnet


ResNet, 2015 yılında Microsoft'tan Kaiming He ve ekibi tarafından ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda hata oranını %3.6'lık orana düşürerek birinci olmuştur. ResNet mimarisi öncesinde CNN modellerinde katman sayısı arttıkça başarı oranının da artacağı düşünülüyordu. He ve ekibi yaptığı araştırmada katman sayısı arttıkça ağ derinleştiğinden daha fazla hata vermesinin nedeninin modelin aşırı uyum (overfitting) probleminden kaynaklanmadığını gösterdi. Derin ağlarda geriye yayılım ilk katmanlara gelene kadar çarpanların etkisi oldukça küçük oluyor ve neredeyse sıfıra yaklaşıyordu. (Feng, V. 2017) Artık (Residual) blok yapısı ile ağırlık katmanından çok küçük bir değer bile gelse  $x$  girdi değeri bir veya birkaç adım sonraki katmanların çıkış değerine etki etmektedir.



Şekil 33: Artık Blok Gösterimi (Akbayir, A. 2021)

### 3.4.5. InceptionResNetV2


Inception ve Resnet mimarilerinin bir araya getirilmesiyle oluşturulmuş bir evrişimli sinir ağı modelidir. Evrişimli sinir ağı modelinin genişliğinin ve derinliğinin optimum olması önemlidir. Performans için modüllerde kullanılan filtrelerin doğru ayarlanması gerekir. Genişlik ve derinlikle birlikte hesaplanacak parametre sayısı da artacaktır.



Şekil 34: InceptionResnetV2 Mimarisi (Kaynak: Özgür, S.N., Bozkurt Keser S. (2021)).


### 3.4.6. Densenet

DenseNet, Huang ve arkadaşları (2017) tarafından geliştirilen her bir katmanı birbirine bağlı yoğun evrişimli sinir ağıdır.  $L$  adet katman için  $(L \cdot L + 1) / 2$  adet katmanlar arası doğrudan bağlantı yer almaktadır. Her bir katman kendinden önceki tüm katmanların özellik haritalarını girdi olarak kullanır.



Şekil 35: Büyüme oranı  $k = 4$  olan 5 katmanlı yoğun bir blok. (Huang vd. 2017)


DenseNet'in kaybolan gradyanı hafifletme, özellik yayılımını güçlendirme ve özelliklerin yeniden kullanılması sayesinde parametre sayısının azaltılması gibi önemli avantajları vardır. ImageNet veriseti ile önceden eğitilmiş DenseNet201 ağı bu çalışmada kullanılmıştır.



Şekil 36: Bitişik iki blok arası geçiş katmanı içeren üç yoğun bloklü DenseNet.

### 3.4.7. EfficientNet

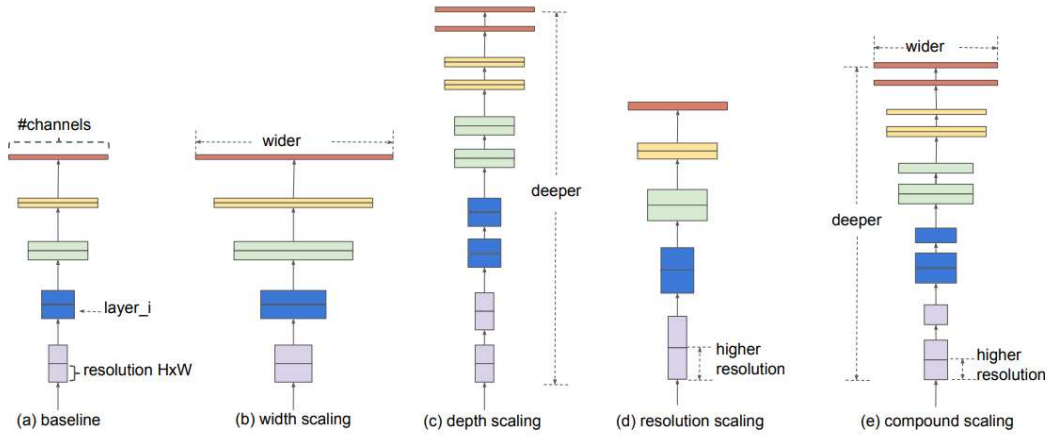
Tan vd. (2019) tarafından önerilen EfficientNet modeli yalnızca doğruluğu değil, evrişimli sinir ağı modelinin verimliliğini de artırmayı hedeflemiştir. EfficientNet mimarisi 2019 yılında ImageNet verisetinde daha az sayıda parametre ile %6 ya varan bir doğruluk artışıyla başarımlarını göstermektedir.



Grafik 1: EfficientNet Parametre Sayısı ve ImageNet Veriseti Doğruluk Oranı Grafiği

EfficientNet modelinde derinlik, genişlik ve imgeye ait çözünürlüğün birlikte ele alındığı bir bileşik ölçeklendirme tekniği kullanılmıştır. Ağın derinliği içerdiği katman sayısına eşit olup, derinleşen bir ağ içinde karmaşık özellikleri yakalamak mümkün olur bununla birlikte daha yüksek CPU ve GPU gücüne

#### EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks



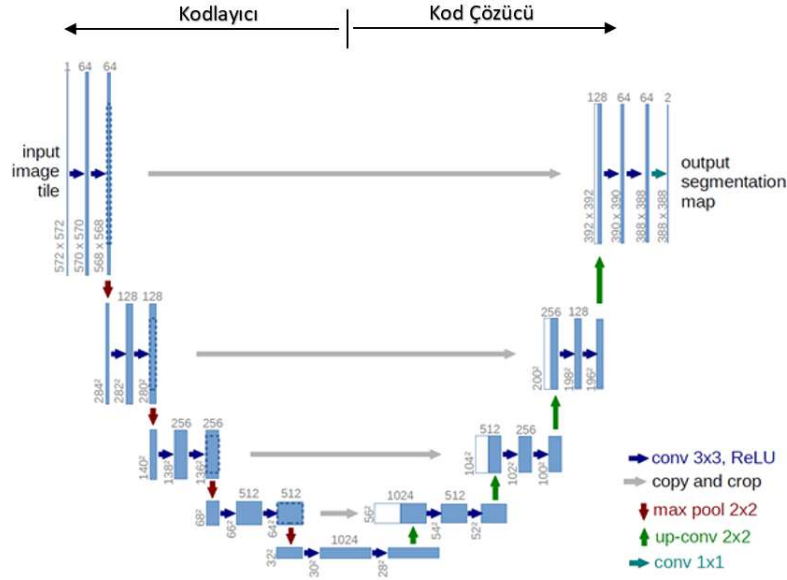
gereksinim duyulur. Ağın genişliği katmanlarında yer alan nöron sayısı ile olarak değerlendirilebilir. Çözünürlük ise modelin eğitiminde kullanılan görselin piksel cinsinden çözünürlüğünü gösterir.

Şekil 37: EfficientNet modelinin genişlik, derinlik, çözünürlük artışı ile gösterimi

### 3.4.8. U-Net

Ronneberger ve arkadaşları tarafından 2015 yılında sunulan U-Net CNN modelinin temel hedefi görüntüye ait her bir piksel sınıfını tahmin ederek biyomedikal görüntüleri bölütlemektir. U-net mimarisi adından da anlaşılacağı gibi U şeklinde olup kodlama, darboğaz ve kod çözme olmak üzere 3 bölümden oluşur. (Ronneberger vd. 2015)

Kodlama kısmında her bir blokta giriş verisinin boyutu azaltılır, özellik haritasının sayısı modelin kompleks yapıları öğrenebileceği şekilde hesaplanır. Darboğaz ise peş peşe gelen iki evrişim katmanından meydana gelir. Mimarinin kod çözme bölümünde ters evrişim işlemi uygulanır, kodlama bölümünden gelen bağlantılarla öznelikler birleştirilir. (Sohaib Najat H. 2019)



Şekil 38: Orjinal U-net Mimarisi (Ronneberger vd. 2015)

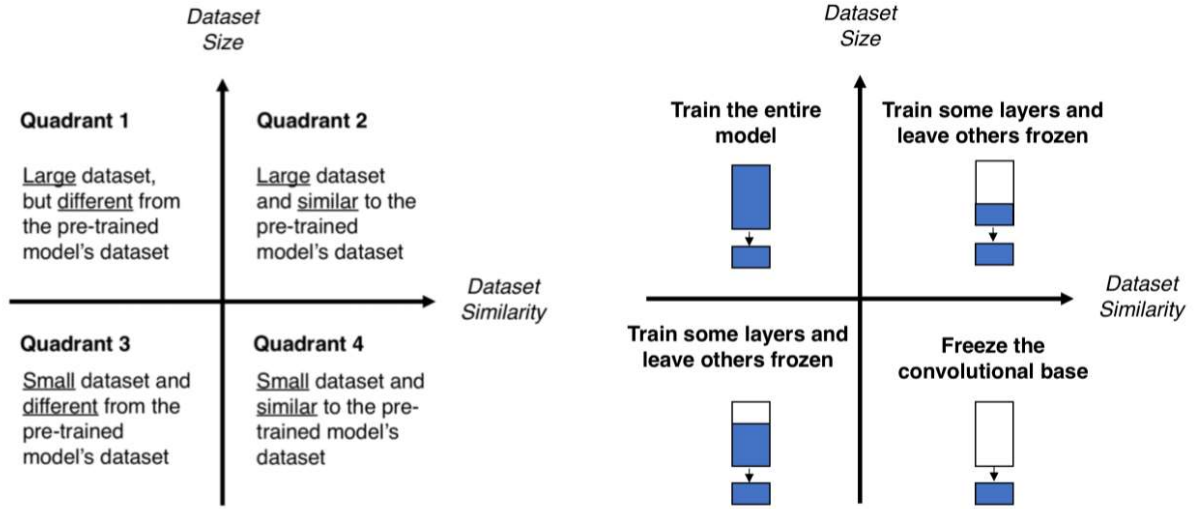
### 3.5. Öğrenme Transferi

CNN mimarisine dayalı öğrenme modelinin eğitiminde probleme özgü özneliklerin ortaya çıkarılması için nicel ve nitel olarak gerekli örüntüleri içeren eğitim kümesine ihtiyaç duyulmaktadır. Özellikle medikal görüntü sınıflandırması amacıyla tasarlanan etiketlenmiş halde yeterli miktarda veri bulmak zordur. Önceden eğitilmiş bir modelin yeni bir problem üzerinde tekrar kullanılması, makine öğreniminde öğrenme transferi olarak bilinir. Bilgi transferi 1000 farklı kategoriye ait 1.2 milyon adet imgeden oluşan ImageNet veri kümesi ile eğitilmiş bir CNN modelinden aktarımla gerçekleştirilebilir (Fırıldak, K. & Talu, M. F. 2019). Öğrenme transferi, eğitim süresinin azalmasına ve sinir ağının performansının artışına olumlu katkıda bulunmaktadır.

### 3.6. İnce Ayar (Fine Tuning)

Öğrenme transferi yoluyla aktarılan katmanlar orjinal modeldeki ağırlıkları aynen koruyabileceği gibi ince ayar (fine tuning) metodu ile CNN modelinin belirli katmanları yeniden eğitilebilir. Doğal görüntülerin sınıflandırılması için büyük bir veriseti ile eğitilmiş bir CNN modelinden alınan katmanlar tıbbi görüntüleme alanında kullanılabilir mi sorusu önümüze gelmektedir. Tajbakhsh vd. yaptığı çalışmada 4 farklı veriseti ile sınıflandırma, algılama ve segmentasyon problemlerinin çözümünde ince ayar yöntemi ile önceden eğitilmiş bir CNN modelinin performansının eğitim veriseti küçüldükçe daha belirgin hale geldiği görülmüştür. Uygulanması gereken ince ayar kullanılan verisetine, orijinal modelin eğitildiği veriseti ile benzerliğine, verisetinin büyüklüğüne göre değişiklik göstermektedir. Yapılan ince ayarın derinliği için geliştirilmiş bir en iyi çözüm bulunmamaktadır. (Tajbakhsh vd. 2016)

Genel olarak CNN'nın ilk katmanları çoğu bilgisayarlı görü işlemi için ortak kullanılabilir temel özellik katmanlarını ortaya çıkarır. Ağın sonunda yer alan katmanlardan verisine özgü üst düzey özellik haritaları ortaya çıkarılır. Eğer öğrenme transferinin yapıldığı veriseti ile uygulamanın veriseti birbirine benzemiyorsa son katmandan geriye doğru ince ayar yapılan katman sayısı artırılarak istenen başarımlar elde edilene kadar ince ayara devam edilebilir.




Şekil 39: Ön eğitilmiş modelin veriseti ile eğitilecek yeni modelin veriseti arasındaki benzerliğe ve eğitim verisetinin büyüklüğüne göre ince ayar yapılması önerilen katmanlar

Kaynak: <https://towardsdatascience.com/transfer-learning-from-pre-trained-models-f2393f124751>

## 4. POLİP SEGMENTASYONU İÇİN U-NET MODELİNİN GELİŞTİRİLMESİ

### 4.1. Veriseti

Bu tez çalışmasının veri kaynağı olan CVC-ClinicDB, Computer Vision Center Barcelona ve Hospital Clinic Barcelona işbirliği ile hazırlanmış olup, bilimsel araştırma ve eğitim amacıyla kullanılmak kaydıyla halka açıktır. CVC-ClinicDB veritabanı içinde endoskopi videolarından alınan polip görüntüleri ve polip tarafından kaplanan alanın uzman klinisyenler tarafından elle oluşturulmuş kesin referans görüntüleri yer almaktadır (Bernal, J. vd. 2015).



Şekil 40: Polip görüntüsü ve kesin referans görüntüsü (kaynak: <https://polyp.grand-challenge.org/CVCClinicDB/>)

CVC-ClinicDB veritabanı içinde .tif uzantılı dosyalardan oluşan iki tür görüntü bulunmaktadır.

- 1) Orijinal görüntüler: Original/goruntu\_no.tif
- 2) Polip maskesi, kesin referans görüntüsü: Ground Truth/goruntu\_no.tif

Sequence	1	2	3	4	5	6	7	8
Frames	1-25	26-50	51-67	68-78	79-103	104-126	127-151	152-177
Sequence	9	10	11	12	13	14	15	16
Frames	178-199	200-205	206-227	228-252	253-277	278-297	298-317	318-342
Sequence	17	18	19	20	21	22	23	24
Frames	343-363	364 -383	384 -408	409 -428	429 -447	448 -466	467 -478	479 -503
Sequence	25	26	27	28	29			
Frames	504-528	529 -546	547 -571	572-591	592-612			

Şekil 41: 29 adet kolonoskopi videosundan elde edilen 612 adet polipli görüntü


(Kaynak: <https://polyp.grand-challenge.org/CVCClinicDB/>)

Tıbbi görüntü veriseti rassal olarak eğitim, test ve doğrulama verisetine ayrıştırılmıştır. 612 adet görüntünün %30'u (184 adet) rassal olarak seçilerek test veriseti olarak, 428 adet görüntü ise eğitim ve doğrulama amaçlı kullanılmıştır. 428 adet görüntüden yine rassal olarak seçilen 129 farklı görüntü doğrulama için, 299 adet görüntü ise eğitim veri seti olarak kullanılmıştır.

**Tablo 4: Modelin eğitimi, doğrulanması ve testi için kullanılan görüntü sayısı ve oranı**

Veri Seti	Açıklaması	Oranı	Sayısı
<b>Eğitim</b>	Modelin eğitimi için kullanılacak veri seti	%49	299 adet
<b>Doğrulama</b>	Modelin doğrulanması için kullanılacak veri seti	%21	129 adet
<b>Test</b>	Doğrulanmış modelin testi için kullanılacak veri seti	%30	184 adet

Grafik 2: 612 adet kesin referans görüntüsü içinde yer alan beyaz pikselin yüzdeleri dağılımı grafiği

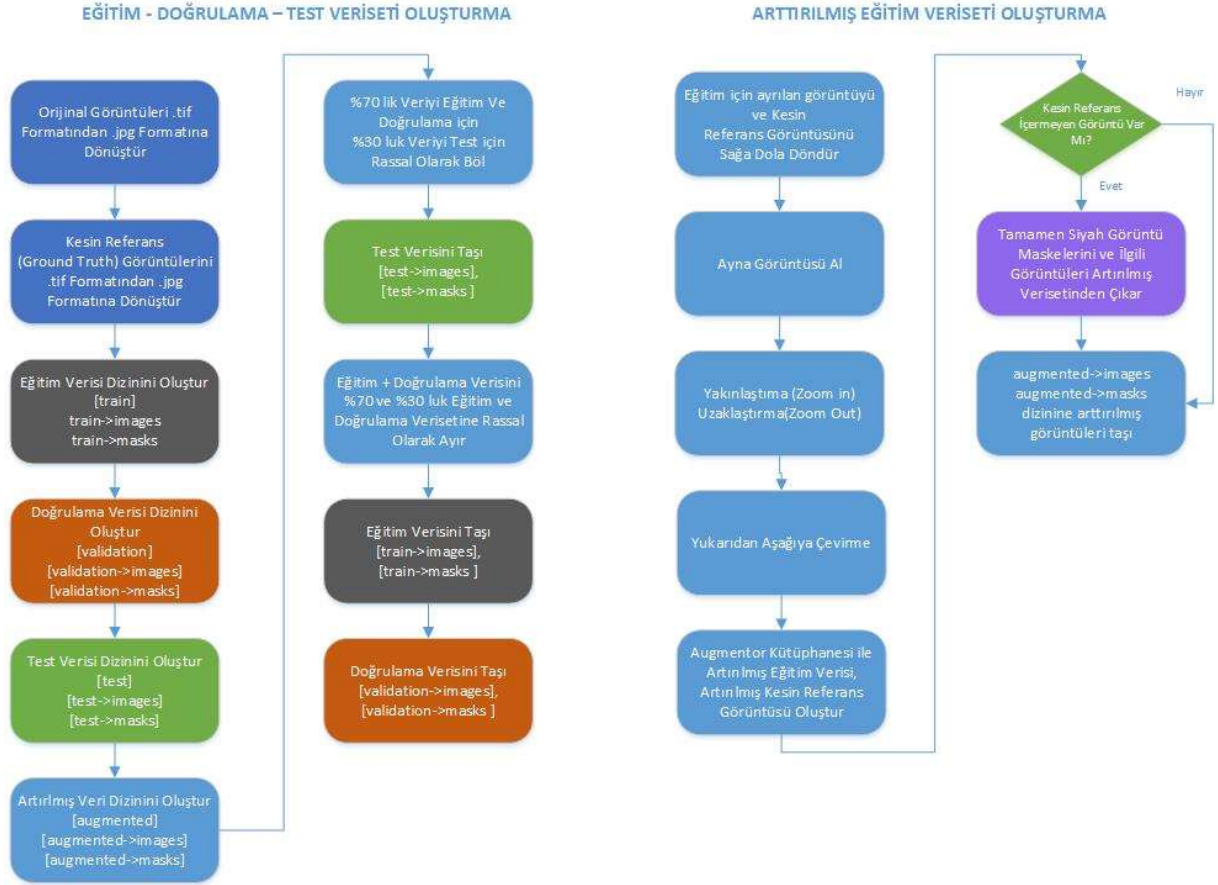


## 4.2. Veri Artırma

CNN modelinin eğitiminde kullanılacak görüntü veri seti üzerinde uygulanacak bir takım dönüştürme işlemleri ile eğitim verisi artırılabilir. CNN modelinin eğitiminde kullanılacak veri çeşitliliği arttıkça modelin başarımı yükselmektedir. Eğitim verisinin örneklem sayısını artırmak için açık kaynaklı Augmentor kütüphanesi kullanılmıştır. 299 adet eğitim veri seti ile çizelgedeki parametreler kullanılarak 1000 adetlik görüntüden oluşan yeni eğitim veri seti oluşturulmuştur. Görüntüye uygulanan veri artırma tekniği eş zamanlı olarak maske imgelerine de uygulanmıştır. Artırılmış veri seti içinde yer alan görüntülerden 2 tanesinde kesin referans değeri olmadığından eğitim setinden çıkarılmış, 998 adetlik artırılmış veri seti ile model eğitilmiştir.

**Tablo 5: Augmentor kütüphanesi ile veri artırma yöntemleri**

Veri Artırma Yöntemi	Açıklaması	Değeri	Olasılık Değeri
<b>max_left_rotation</b>	Görüntünün sola doğru kaç derece döndürüleceği	20	0.2
<b>max_right_rotation</b>	Görüntünün sağa doğru kaç derece döndürüleceği	20	0.2
<b>flip_left_right</b>	Görüntünün soldan sağa ayna görüntüsünün oluşması	True	0.2
<b>zoom_min_factor</b>	Görüntüden uzaklaşma oranı	0.75	0.2
<b>zoom_max_factor</b>	Görüntüye yaklaşma oranı	1.25	0.2
<b>flip_top_to_bottom</b>	Görüntünün yukarıdan aşağıya çevrilmesi	True	0.2
<b>random_contrast</b>	Kontrast değeri	min:0.8 max:1.2	0.1
<b>random_brightness</b>	Görüntü parlaklığı	min:0.8 max:1.2	0.1
<b>shear</b>	Görüntünün sağa veya sola kaydırılması	left:10 right:10	0.1
<b>number_of_samples</b>	Oluşturulacak örneklem sayısı	1000	1



Şekil 42: Eğitim, doğrulama, test veri seti oluşturma artırılmış veri üretme aşamaları

## 4.3. Geliştirme Platformu ve Teknolojiler

### 4.3.1 Python

Polip segmentasyonu için geliştirilen U-Net modeli Python programlama dili ile yazılmıştır. Python, nesne yönelimli, açık kaynaklı, ücretsiz, üst düzey bir programlama dilidir. Python dilini öğrenmesi kolay olup, dilin okunabilirliği yüksektir, bu sayede kodun bakım maliyeti azalmaktadır. Kodun yeniden kullanımını teşvik eden modülleri ve paketleri desteklemektedir. Windows, Linux, Mac, Unix, Symbian gibi farklı platformlarda çalışabilir. Python ile masaüstü, mobil ve web uygulamaları geliştirmek mümkündür.

### 4.3.2 Google Colab

Araştırma eğitim için yüksek grafik işlemci birimi (GPU) gerektirdiğinden Google Colab (COLAB) platformu kullanılmıştır. COLAB araştırmacılara herhangi bir internet tarayıcısı (chrome, opera, edge vb.) aracılığıyla python kodu yazma ve çalıştırma imkanı sunan, güçlü merkezi işlem birimi (CPU) ve GPU barındıran, arayüzü ile Jupyter Notebook'a benzeyen ücretsiz bulut tabanlı bir geliştirme platformudur.

### 4.3.3 NumPy, SciPy

Python'un günümüzde artan bir ilgiyle kullanılmasının temel nedenlerinden biri de sahip olduğu zengin kütüphanelerden kaynaklanmaktadır.

Numpy, Python'da nümerik hesaplama için kullanılan temel pakettir. Numpy, çok boyutlu diziler ve matrisler üzerinde matematiksel, mantıksal, seçme, sıralama ve temel lineer cebir işlemlerini hızlıca yapmayı sağlayan kütüphanedir. NumPy dizileri, çok sayıda veri üzerinde ileri düzey matematiksel ve diğer işlem türlerini Python'un kendi dizi yapısını kullanarak daha etkin ve daha az kodla yürütür.

SciPy ise bilimsel hesaplamalar için NumPy kütüphanesine dayalı olarak geliştirilmiş ücretsiz, açık kaynaklı bir kitaplıktır. Verileri işlemek ve görselleştirmek için sinyal işleme, Fourier dönüşümü, lineer cebir, integral için hazır fonksiyonlar ve sınıflar sağlayarak uygulama geliştiriciye önemli bir güç katar.

### 4.3.4 Tensorflow

Tensorflow, Google tarafından geliştirilmekte olup, derin öğrenme tabanlı YZ uygulamalarında kullanılabilen açık kaynak kodlu makine öğrenmesi kütüphanesidir. Python, C#, Java, C++, R, JavaScript gibi birçok dili desteklemektedir. Mobil uygulama, web uygulaması veya nesnelerin interneti (IoT) cihazları üzerinde geliştirilecek platforma uygun kütüphane desteği bulunmaktadır. Tensorflow ismini iki kelimenin birleşiminden almaktadır. Tensor, n boyutlu bir diziyi ifade ederken, flow (akış) ise tensor üzerinde gerçekleştirilen sıralı işlemleri belirtmektedir.

### 4.3.5 Keras

Keras, tensorflow kütüphanesi üzerinde çalışan, derin öğrenme için geliştirilmiş bir kütüphanedir. Uygulamanın CPU veya GPU ile çalışması tensorflow kütüphanesi ile sağlanır. Keras, kullanıcılara kayıp (maliyet) fonksiyonları, aktivasyon fonksiyonları, model değerlendirme metrikleri sunmaktadır. Keras ile geliştirilen modeller JavaScript ile doğrudan bir tarayıcı ile, IOS, Android veya gömülü sistemlerde ise Tensorflow Lite kütüphanesi ile çalıştırmak mümkündür.

## 4.4. Performans Ölçütleri

Kolonoskopi görüntülerinin bölütlenmesinde kullanılan yöntemlerin değerlendirme performansı görüntüye ait kesin referansa (ground truth) bağlıdır. Kesin referans, uzman klinisyen tarafından orijinal kolonoskopi görüntüsüne karşılık maske olarak tanımlanmıştır. Performans kriterleri, bölütlenen görüntü ile kesin referans görüntüsü arasındaki ilişkiyi göstermektedir. Geliştirilen CNN modelinin başarımı çeşitli metriklerle ölçülebilir. CNN modeli görüntüyü değerlendirirken her bir piksel bazında tahminlenen değer ve gerçek görüntü birbirinden farkı olabilir. Tahmin edilen piksel değeri doğru iken gerçekte yanlış, yanlış iken gerçekte doğru olabilmektedir. Jaccard indeksi (kesişen bölge) ve Dice ölçütü bölütlemeye sıkça kullanılan iki ayrı değerlendirme kriteridir.

## 4.5. Karmaşıklık Matrisi

Karmaşıklık matrisi, sınıflandırma problemlerinin sonucunu değerlendirirken kullanılan bir tablodur. Veri madenciliğinde, makine öğrenmesi ve yapay zeka uygulamalarında bu tablodan

faýdalanılmaktadır. Gerçek dünya değerleri ile modelin tahmin ettiği sınıfı karşılaştırırken, sınıflandırmanın doğruluğu ve hatalar hakkında daha iyi fikirler verir.

		Sınıflandırma Çıktısı (Tahmin)	
		Pozitif	Negatif
Referans Değer (Gerçek Dünya)	Pozitif	TP	FN
	Negatif	FP	TN

Şekil 43: Karmaşıklık Matrisi (Prabha, D. S., & Kumar, J. S. (2016).)

Karmaşıklık matrisinde gerçek referans değer ve sınıflandırma modelinin tahmin ettiği 4 ayrı durum ortaya çıkmaktadır:

- Gerçek Pozitif (TP – True Positive): Model tarafından tahmin edilen değer pozitif, gerçek dünya değeri ise pozitiftir.
- Gerçek Negatif (TN – True Negative): Model tarafından tahmin edilen değer negatif, gerçek dünya değeri ise negatiftir.
- Yanlış Pozitif (FP – False Positive): Model tarafından tahmin edilen değer pozitif, gerçek dünya değeri ise negatiftir.
- Yanlış Negatif (FN – False Negative): Model tarafından tahmin edilen değer negatif, gerçek dünya değeri ise pozitiftir.

#### 4.6.Sınıflandırma Performans Ölçütleri

**4.6.1 Doğruluk (Accuracy):** Performans değerlendirmede en sık kullanılan ölçütlerden biridir. Doğru tahmin edilen gözlem sayısının toplam gözlem sayısına oranını ifade eder. Modelin doğruluğu şu formülle hesaplanır:

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (7)$$

**4.6.2 Kesinlik (Precision):** Doğru tahmin edilmiş pozitif gözlem sayısının, modelin doğru olarak tahmin ettiği gözlem sayısına oranını ifade eder, başka bir deyişle modelin pozitif tahmininin ne kadar başarılı olduğunu gösterir. Şu formülle hesaplanır:

$$\text{Kesinlik} = TP/(TP + FP) \quad (8)$$

**4.6.3 Hassasiyet (Recall):** Doğru tahmin edilmiş pozitif gözlem sayısının gerçekteki pozitif sınıfa ait gözlem sayısına oranıdır.

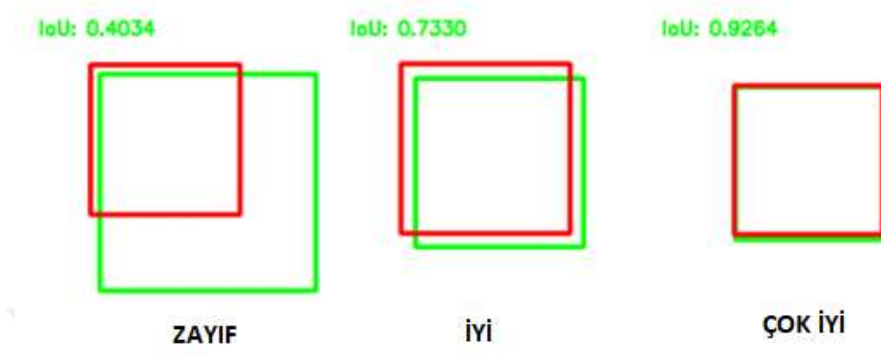
$$\text{Hassasiyet} = TP/(TP + FN) \quad (9)$$

**4.6.4 F1 Skoru:** F1 ölçütü, hassasiyet ve kesinlik ölçütlerini birleştirerek daha yüksek etkinliğe sahip yeni bir ölçüt olarak kullanılmaktadır. Modelin eğitiminde kullanılan veri seti içinde sınıflara ait dengesiz bir dağılım söz konusu ise doğruluk (accuracy) yerine bu ölçütün kullanılması uygun olur.

#### 4.6.5 IoU: (Kesişen Bölge - Jaccard İndeksi - Intersection Over Union)

Tahmin edilen bölge ile gerçek dünya kesin referans değerlerinin birbirine ne kadar benzediğini hesaplamak amacıyla kullanılır. Kesişen bölge değeri 1 'e yaklaştıkça modelin başarımı yükselir. Formülü şu şekildedir:

$$\text{Jaccard İndeksi (Kesişen Bölge, IoU)}(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (10)$$

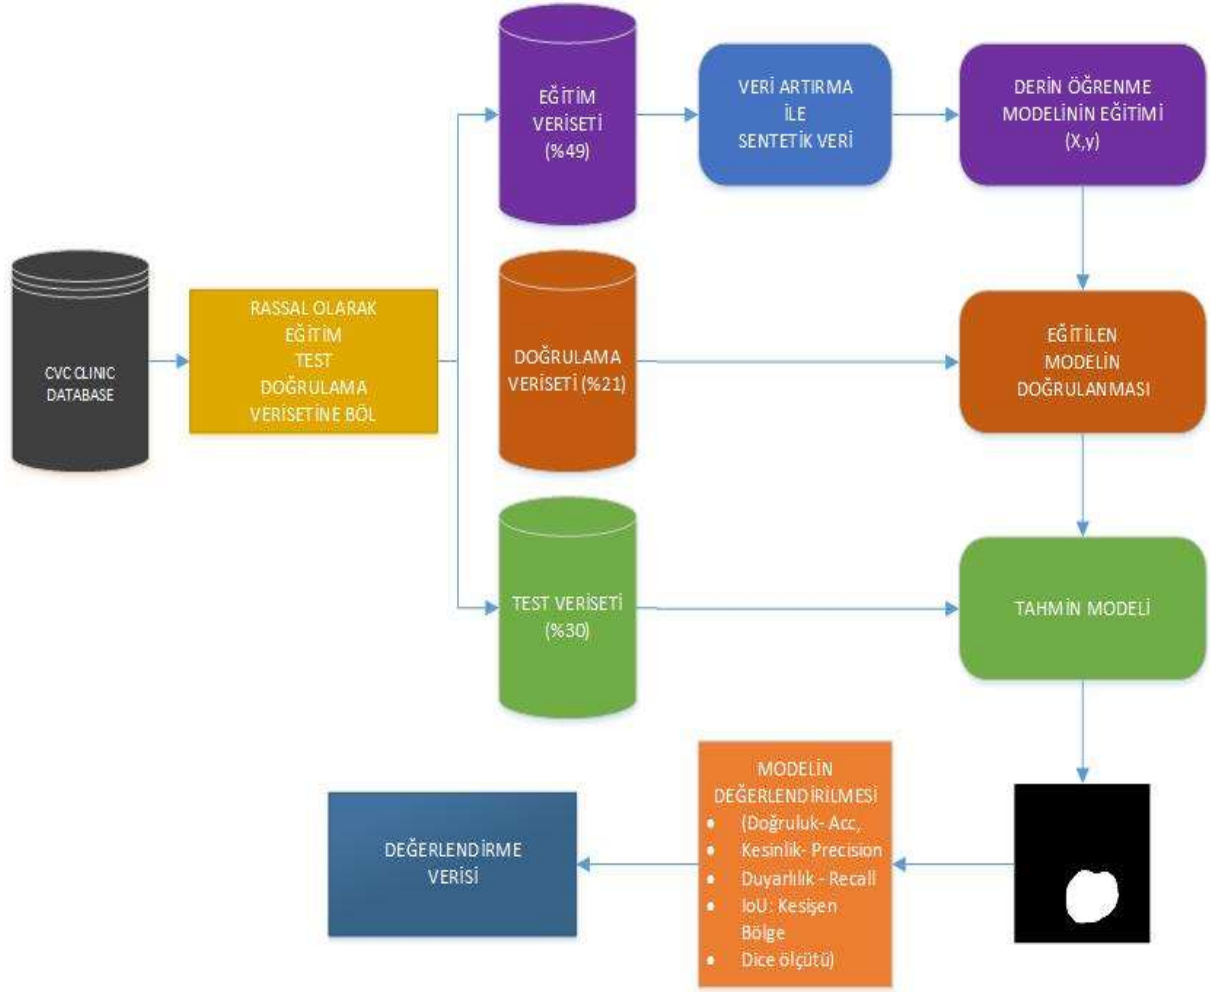


Şekil 44: Kesişen Bölge Başarımı Değerlendirmesi

#### 4.6.6 Dice Ölçütü (Dice Co-efficient)

Dice ölçütü, jaccard indeksine benzer bir ölçüttür. Tıbbi görüntü işlemede önceden tanımlanmış kesin referans değerle bölütleme algoritmaları sonucu hakkında bilgi verir. Burada A, kesin referans içinde gerçekte sıfır olmayan piksel ögesi olup, B ise bölütleme sonucu tahmin edilen, sıfır olmayan piksel ögesidir.

$$\text{Dice Ölçütü } (A, B) = \frac{2 * |A \cap B|}{|A| + |B|} \quad (11)$$



Şekil 45:Kolorektal Polip Segmentasyonu Süreci

## 5. BULGULAR

Bu çalışma önceden eğitilmiş derin öğrenme modelleri transfer öğrenmesi yöntemiyle COLAB platformunda Python programlama dili 3.7.13 sürümü, Tensorflow 2.8.0 ve Keras 2.8.0, Augmentor-0.2.10, segmentation\_models-1.0.1 kütüphanesi kullanılarak gerçekleştirilmiştir. Google Colab platformu 12 GB belleğe sahip Tesla K80 GPU, Intel(R) Xeon(R) CPU @ 2.30GHz sunmaktadır.

Eğitimin daha hızlı yapılabilmesi amacıyla 384x288 piksel boyutundaki görüntü 224x224 piksel olarak yeniden boyutlandırılmış, modelin eğitiminde görüntü piksel değerleri 0-1 arasında normalize edilmiştir.

Verisinde yer alan 612 adet görüntü %70 eğitim ve doğrulama (428 adet), %30 test veriseti (184 adet) olmak üzere iki gruba ayrılmıştır. Eğitim ve doğrulama veriseti ise kendi içinde yeniden %70 eğitim (299 adet), %30 doğrulama (129 adet) olmak üzere ikiye ayrılmıştır. Çalışmada eğitilen modellerin tümünde ImageNet veriseti ile önceden eğitilmiş modellerin ağırlıkları kullanılmıştır. Eğitim için kullanılan veriseti 50 dönem boyunca 8 olan görüntülük gruplar halinde eğitilmiştir. Eğitim tur sayısının (epoch) belirlenmesinde COLAB platformunun sunduğu aralıksız eğitim süresi etkili olmuştur. Eğitim için kullanılan ön eğitimli modelin parametre sayısı, doğrulama ve test veriseti için elde edilen IoU, doğruluk, duyarlılık, kesinlik, dice katsayısı değerleri tabloda sunulmuştur. Eğitilen modellerde RmsProp eniyileyicisi kullanılmıştır. Gözlenen val\_iou değeri 20 kez artmadığı takdirde öğrenme katsayısı yarıya indirilmiştir. Modelin eğitiminde gözlenen val\_iou değeri 0.001 değerinden daha fazla artmadığında ise keras kütüphanesinin erken durdurma özelliğiyle eğitim sonlandırılmıştır.

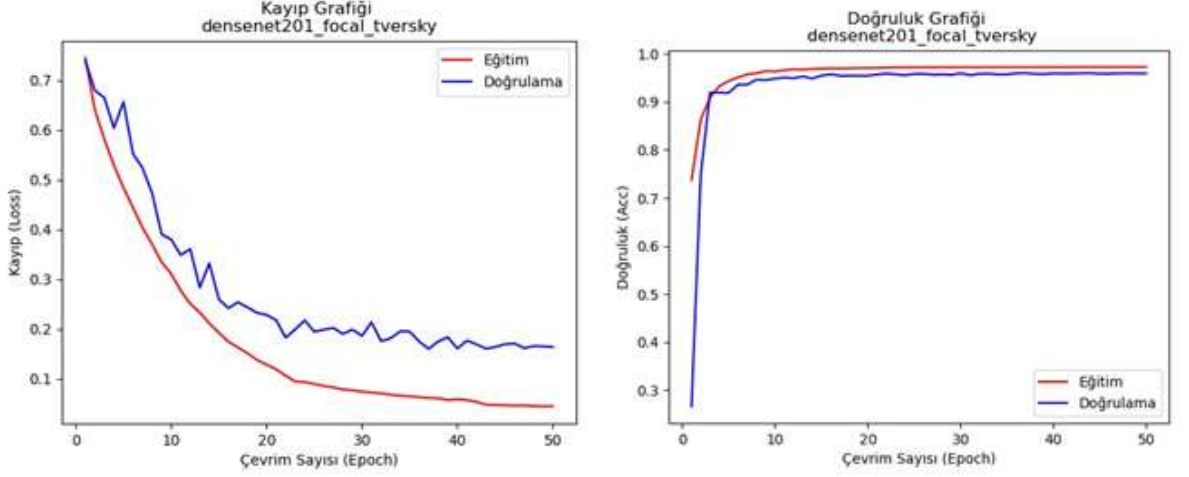
### 5.1. Model Eğitiminde Orjinal Veri ve Artırılmış Veri Kullanımının Etkisi

#### 5.1.1 DenseNet201 Ön Eğitimli Modelinin U-NET Mimarisi İle Kullanılması

DenseNet201 modelinin ImageNet ile eğitilmiş ağırlıkları kullanılarak U-NET mimarisine transfer edilmiş, elde edilen modelin orijinal verisiyle (Model 6) ve artırılmış eğitim verisiyle (Model 7) eğitim ve doğrulama aşamasındaki kayıp (loss) grafiği ile doğruluk (accuracy) grafiği çizilmiştir. Veri artırımı öncesi ve sonrası performans kıyaslaması çizelgede sunulmuştur.

**Tablo 6: DenseNet201 modeli ile veri artırma öncesi ve sonrası performans değerlendirmesi**

Model No	Veri	Doğruluk (Acc)	Duyarlılık (Recall)	Kesinlik (Precision)	Kesişen Bölge (IoU)	Dice Katsayısı
6	Orjinal	0.9594	0.8013	0.9781	0.8505	0.9173
7	Artırılmış	0.9620	0.8218	0.9847	0.8777	0.9332



Grafik 3: DenseNet201 Modeli, focal tversky kayıp fonksiyonu, orijinal eğitim seti ile Doğruluk Grafiği


### 5.1.2 EfficientNetB7 Ön Eğitilmiş Modelinin U-NET Mimarisi İle Kullanılması

EfficientNetB7 modelinin ImageNet ile eğitilmiş ağırlıkları kullanılarak U-NET mimarisine transfer edilmiş, elde edilen modelin orijinal verisiyle (Model 3) eğitim ve doğrulama aşamasındaki kayıp (loss) grafiği ile doğruluk (accuracy) grafiği çizilmiştir. Veri artırımı öncesi ve sonrası performans kıyaslaması çizelgede sunulmuştur.

Tablo 7: EfficientNetB7 modeli ile veri artırma öncesi ve sonrası performans değerlendirmesi

Model No	Veri	Doğruluk (Acc)	Duyarlılık (Recall)	Kesinlik (Precision)	Kesişen Bölge (IoU)	Dice Katsayısı
3	Orjinal	0.9599	0.8096	0.9786	0.8552	0.9202
4	Artırılmış	0.9630	0.8332	0.9827	0.8781	0.9329

Grafik 4: EfficientNetB7 Modeli, focal tversky kayıp fonksiyonu, orijinal eğitim seti ile Doğruluk Grafiği, Kayıp Grafiği



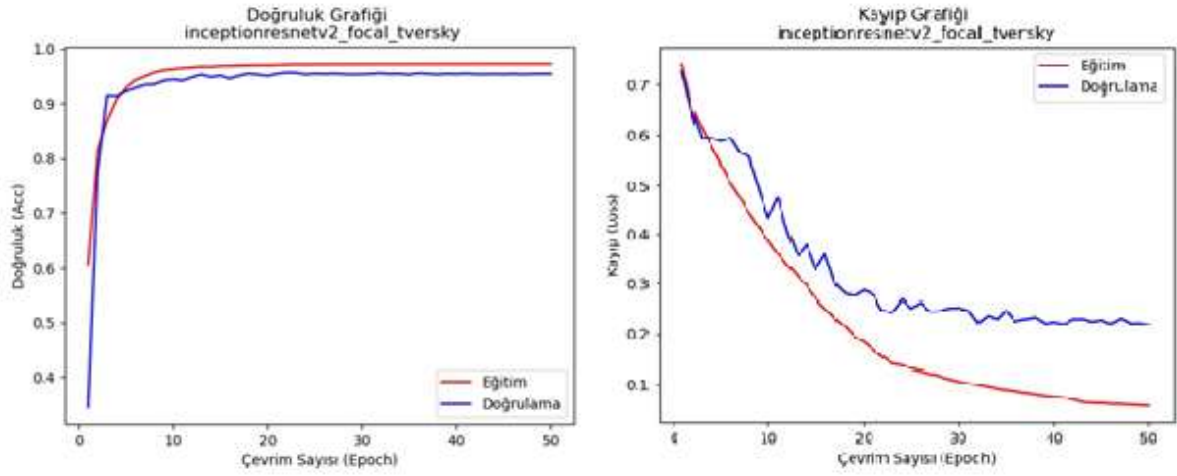
### 5.1.3 InceptionResNetV2 Ön Eğitilmiş Modelinin U-NET Mimarisi İle Kullanılması

InceptionResNetV2 modelinin ImageNet ile eğitilmiş ağırlıkları kullanılarak U-NET mimarisine transfer edilmiş, elde edilen modelin (Model 10) orijinal verisiyle ve artırılmış eğitim verisiyle eğitim

ve doğrulama aşamasındaki kayıp (loss) grafiği ile doğruluk (accuracy) grafiği çizilmiştir. Veri artırımı öncesi ve sonrası performans kıyaslaması çizelgede sunulmuştur.

**Tablo 8: InceptionResNetV2 modeli ile veri artırma öncesi ve sonrası performans değerlendirmesi**

Model No	Veri	Doğruluk (Acc)	Duyarlılık (Recall)	Kesinlik (Precision)	Kesişen Bölge (IoU)	Dice Katsayısı
10	Orjinal	0.9545	0.74.86	0.9808	0.7964	0.8846
11	Artırılmış	0.9588	0.7918	0.9852	0.8554	0.9198



Grafik 5: InceptionResnetV2 Modeli, focal tversky kayıp fonksiyonu, orijinal eğitim seti ile Doğruluk Grafiği, Kayıp Grafiği

## 5.2 Kayıp (Loss) Fonksiyonunun Modelin Performasına Etkisi

ImageNet veriseti ile eğitilmiş EfficientNetB7 modelinden öğrenme transferi yöntemiyle orijinal eğitim verisi kullanılarak oluşturulan üç farklı U-NET modelinde kayıp fonksiyonunun performansa etkisi incelenmiştir.

**Tablo 9: EfficientNetB7 modeli ile veri artırma öncesi ve sonrası performans değerlendirmesi**

Model No	Kayıp Fonksiyonu	Doğruluk (Acc)	Duyarlılık (Recall)	Kesinlik (Precision)	Kesişen Bölge (IoU)	Dice Katsayısı
1	Binary Cross Entropy (bce)	0.9592	0.8089	0.9664	0.8416	0.9111
2	log_cosh_dice_loss	0.9597	0.8056	0.9753	0.8517	0.9186
3	focal_tversky	<b>0.9599</b>	<b>0.8096</b>	<b>0.9786</b>	<b>0.8552</b>	<b>0.9202</b>

Focal twersky kayıp fonksiyonu ile eğitilen 3 nolu modelin daha başarılı sonuç verdiği gözlenmiştir. Bu sebeple artırılmış veri ve ince ayar uygulama aşamasında bu kayıp fonksiyonu ile yeni modeller eğitilmiştir.

### 5.3 İnce Ayar Uygulamanın Modelin Performansına Etkisi

DenseNet201 ön eğitilmiş modelinden öğrenme transferi yapıldıktan sonra 3 farklı U-NET Modeli oluşturulmuştur. 7 nolu modelde kodlayıcı, darboğaz ve kod çözücü kısmında herhangi bir dondurma işlemi uygulanmamıştır, imagenet ile eğitilen parametrelerin ilk değeri kullanılmış ve tüm ağ eğitilmiştir. 8 nolu modelde ise kodlayıcı kısmı dondurularak eğitilen parametre sayısı 26.1 milyondan 8.3 milyona düşürülmüştür. 9 nolu modelde ise sadece darboğaz (bottleneck) kısmında yer alan katmanlar dondurulmuş ve eğitilen parametre sayısı 26.1 milyondan 19.2 milyona düşmüştür.

**Tablo 10: DenseNet201 ön eğitilmiş modeliyle ince ayar uygulanması**

Model No	Doğruluk (Acc)	Duyarlılık (Recall)	Keskinlik (Precision)	Kesişen Bölge (IoU)	Dice Katsayısı	Eğitilen Parametre (Milyon)
7	0.9620	0.8218	0.9847	0.8777	0.9332	26.1
8	0.9517	0.7685	0.9439	0.7532	0.8537	8.3
9	0.9611	0.8145	0.9847	0.8698	0.9288	19.2

### 5.4 Geliştirilen Modellerin Doğrulama ve Test Performanslarının Karşılaştırılması

Öğrenme transferi ile geliştirilmiş 11 farklı U-NET modelinin doğrulama ve test veriseti ile elde edilmiş sonuçları şekil 46 da gösterilmiştir. EfficientNetB7 ön eğitilmiş modelinin ImageNet ile eğitilmiş haline ait ağırlıkların başlangıçta kullanılmasıyla tüm katmanlar eğitilerek oluşturulan 4 nolu model ile en başarılı sonuçlar elde edilmiştir. Model eğitilirken elde edilen doğrulama ve eğitim sonrası test aşamasında elde edilen metrikler tabloda sunulmuştur.

**Tablo 11: EfficientNetB7 ön eğitilmiş U-NET modelinin doğrulama ve test performansı**

Model No:4	Doğruluk (Acc)	Duyarlılık (Recall)	Keskinlik (Precision)	Kesişen Bölge (IoU)	Dice Katsayısı
<b>Doğrulama</b>	0.9630	0.8332	0.9827	0.8781	0.9329
<b>Test</b>	0.9676	0.8352	0.9765	0.8847	0.9384


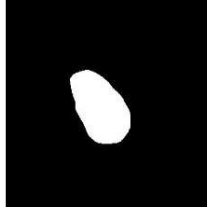
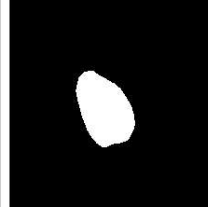

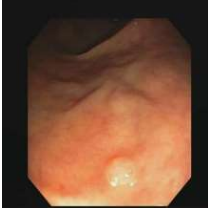
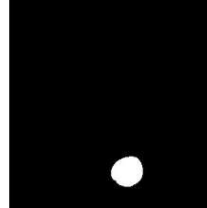
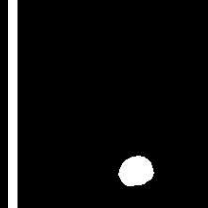
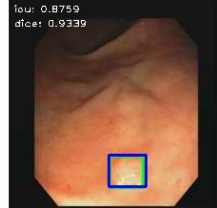

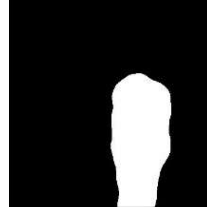
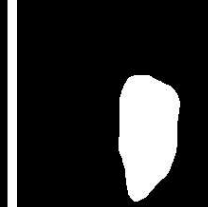

Model No	Ön Eğitimli Model	Veri	Tur	Süre (dk)	IoU	TestIoU	Doğruluk (Val_Acc)	Test Doğruluk (val_Test)	Kesimlik (val_precision)	Test Kesimlik (test_precision)	Duyarlılık (val_recall)	Test Duyarlılık (test_recall)	Dice Coeff (val_dice_coeff)	Dice (test_dice)	Eğitilen Parametre-milyon	Eğitilmeyen Parametre-milyon	Kayıp (Loss) Fonksiyonu	Kodlayıcı Donduruldu mu?	Darboğaz Donduruldu mu?
1	efficientnetb7	Orjinal	50	96	0.8416	0.8466	0.9592	0.9656	0.9664	0.9619	0.8089	0.8205	0.9111	0.9158	74,7	0,3	bce	Hayır	Hayır
2	efficientnetb7	Orjinal	50	96	0.8517	0.8559	0.9597	0.9657	0.9753	0.9648	0.8056	0.8232	0.9186	0.9215	74,7	0,3	log_cosh_dice_loss	Hayır	Hayır
3	efficientnetb7	Orjinal	50	57	0.8552	0.8630	0.9599	0.9658	0.9766	0.9677	0.8096	0.8269	0.9202	0.9256	74,7	0,3	focal_tversky	Hayır	Hayır
4	efficientnetb7	Afırılmış	41	137	0.8781	0.8847	0.9630	0.9676	0.9827	0.9765	0.8332	0.8352	0.9329	0.9384	74,7	0,3	focal_tversky	Hayır	Hayır
5	efficientnetb7	Afırılmış	31	102	0.8467	0.8772	0.9598	0.9666	0.9807	0.9734	0.8080	0.8332	0.9144	0.9340	51,7	23,3	focal_tversky	Hayır	Evet
6	densenet201	Orjinal	50	61	0.8505	0.8463	0.9594	0.9649	0.9781	0.9739	0.8013	0.8043	0.9173	0.9158	26,1	0,2	focal_tversky	Hayır	Hayır
7	densenet201	Afırılmış	50	125	0.8777	0.8744	0.9620	0.9663	0.9847	0.9764	0.8218	0.8217	0.9332	0.9323	26,1	0,2	focal_tversky	Hayır	Hayır
8	densenet201	Afırılmış	36	117	0.7532	0.7564	0.9517	0.9547	0.9439	0.8914	0.7685	0.7899	0.8537	0.8590	8,3	18,1	focal_tversky	Evet	Hayır
9	densenet201	Afırılmış	50	113	0.8698	0.8553	0.9611	0.9648	0.9847	0.9611	0.8145	0.8166	0.9288	0.9211	19,3	7,1	focal_tversky	Hayır	Evet
10	inceptionresnetv2	Orjinal	50	40	0.7964	0.8194	0.9545	0.9629	0.9808	0.9704	0.7486	0.7787	0.8846	0.8992	62	0,1	focal_tversky	Hayır	Hayır
11	inceptionresnetv2	Afırılmış	50	116	0.8554	0.8760	0.9588	0.9665	0.9852	0.9725	0.7918	0.8339	0.9198	0.9333	62	0,1	focal_tversky	Hayır	Hayır

Şekil 46: Geliştirilen Modellerin Doğrulama ve Test Veriseti ile Performans Değerlendirmesi


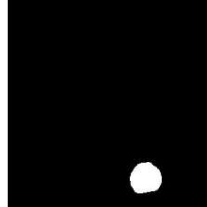


## 5.5 Önerilen Modele Ait Tahminleme Örnekleri


EfficientNetB7 ön eğitilmiş U-NET modelinin artırılmış veri ile eğitilerek oluşturulan 4 nolu modelin test veriseti kullanıldığında elde edilen başarılı ve başarısız tahminleme örnekleri tablo 10 ve tablo 11 de sunulmuştur.

**Tablo 12: Başarılı Polip Tespiti Örnekleri**

Görsel	Orijinal Görüntü	Kesin Referans	Tahmin	Sonuç
513				
380				
234				

**Tablo 13: Başarısız Polip Tespiti Örnekleri**

Görsel	Orijinal Görüntü	Kesin Referans	Tahmin	Sonuç
78				



## 5.6 Önerilen Modelin Performans Karşılaştırması

EfficientNetB7 ön eğitilmiş modeli ile geliştirilen U-Net modelinin literatürde yer alan mevcut çalışmalarla karşılaştırması tabloda sunulmuştur.

**Tablo 14: Mevcut Çalışmalarla Karşılaştırma**

Çalışma	Doğruluk(Acc)	IoU	F1-Score
Xiao (2018), Semantic segmentation of colorectal polyps with DeepLab and LSTM networks		0.932	
Nguyen, Lee, (2018) Colorectal segmentation using multiple encoder-decoder network in colonoscopy images		0.889	
Wickstrøm (2018), Uncertainty modeling and interpretability in convolutional neural networks for polyp segmentation	0.949	0.767	0.786
Vázquez (2017), A benchmark for endoluminal scene segmentation of colonoscopy images	0.968	0.516	0.792
Bardhi (2017), Automatic colon polyp detection using convolutional encoder-decoder model	0.967		
Wichakam (2018), real-time polyps segmentation for colonoscopy video frames using compressed fully convolutional network		0.694	0.739
Branch, Carvalho (2021) Polyp Segmentation in Colonoscopy Images using U-Net-MobileNetV2		0.816	
EfficientNetB7 Ön Eğitilmiş Önerilen Model	<b>0.968</b>	0.884	<b>0.900</b>

## 6 SONUÇ VE ÖNERİLER

Derin öğrenme temelli yapay zeka çözümleri hastalığın erken evrede teşhisinde ve tanı konmasına yardımcı birer karar destek sistemi olarak kullanılmaktadır. CNN tabanlı uygulamalar sayesinde tıbbi görüntüde hastalığın tespiti, sınıflandırılması, imgedeki yerinin saptanması mümkündür. YZ çözümleri beyin tomografi görüntülerinin analiz edilmesiyle Alzheimer, Parkinson hastalığının teşhisinde, mamografi görüntülerin analizi ile meme kanserinin erken aşamada tespitinde kullanılabilir.

Tıbbi görüntüleme için kullanılacak YZ çözümleri yoğun mesai gerektiren görüntü tanıma ve hastalığın önceliklendirilmesi sürecinde hekime yardımcı olabilecektir. Yakın dönemde dünya çapında yaşadığımız Covid-19 salgınında hastaların akciğer X-Ray görüntülerinden otomatik olarak Covid-19 hastalığının tahmini amacıyla CNN temelli çalışmalar yapılmıştır (Yılmaz A.2021). Diz MR görüntüsünde menüsküs segmentasyonunda, bir göz hastalığı olan diyabetik retinopatinin teşhis edilmesinde evrişimli sinir ağlarından faydalanmak mümkündür. YZ temelli tıbbi görüntüleme uygulamaları, doktorun hastalığın teşhisinde hızlı karar alabilmesine, kurumsal kaynak planlaması açısından hastanedeki en değerli kaynak olan hekimin diğer vakalara daha çok zaman ayırabilmesine fırsat verecektir. Hem hastalığın daha erken aşamada tespitiyle hastaya fayda sağlayacak, hem de zaman ve maliyet açısından hastaneye katma değer sunacaktır.

Bu tezde kolonoskopi görüntülerindeki poliplerin segmentasyonu için CNN tabanlı bir derin öğrenme modeli önerilmektedir. U-Net mimarisini esas alan modele doğal görüntülerle eğitilmiş ön eğitilmiş modellerden öğrenme transferi yöntemi uygulanmıştır.

Öğrenme transferinde kullanılan omurgada yer alan ön eğitilmiş modelin performansa etkisi incelenmiştir. Modellerin eğitimi, doğrulanması ve testi için 612 adet polip görüntüsü içeren CVC-ClinicDB veriseti kullanılmıştır. Değerlendirme aşamasında uzman klinisyenler tarafından işaretlenmiş siyah-beyaz renkli kesin referans görüntüleri kullanılmıştır.

Modelin eğitimi için 384x288 piksellik medikal görüntüler 224x224 piksel olarak yeniden boyutlandırılmış, eğitime 0.0001 öğrenme katsayısı ile başlanmıştır. IoU değerini maksimize etmek amacıyla eğitim aşamasında IoU değeri 20 kez değişmezse öğrenme katsayısı yarıya indirilmiştir. Modelin eğitiminde aşırı uyumu engellemek için erken durdurma özelliğinden faydalanılmıştır. ReLU aktivasyon fonksiyonu ve RMSProp eniyileyicisi kullanılmıştır.

U-NET modeline kernel\_size (3, 3), stride adım sayısı ise (2,2) ile başlanmıştır. 847 katmandan oluşan modelin 74.735.393 adet eğitilebilir parametresi, 312.704 adet eğitilmeyen parametresi bulunmaktadır. Kod çözücü kısmında 256,128,64,32,16 adetlik filtreler kullanılmıştır.

129 adet doğrulama görüntüsünden doğrulama aşamasında %96.30 doğruluk, %83.32 duyarlılık, %98.27 kesinlik, %87.21 IoU, %93.29 Dice değeri elde edilmiştir. Test aşamasında ise 184 adet görüntüde %96.76 doğruluk, %83.52 duyarlılık, %97.65 kesinlik, %88.47 IoU değeri, %93.84 Dice değeri elde edilmiştir.

DenseNet201 tabanlı U-Net modeline (Model 8) ince ayar uygulanırken ön eğitilmiş modelden transfer edilen kodlayıcı katmanı tamamen dondurularak eğitilen parametre sayısı 26.14 milyondan 8.28 milyona düşürülmüştür. Modelin test verisetindeki IoU skoru %87.44'ten %75.64'e düşmüştür.

DenseNet201 tabanlı U-Net modelinde (Model 9) darboğaz (bottleneck) katmanı dondurularak eğitilen parametre sayısı 26.14 milyondan 19.26 milyona düşmüştür. Modelin test verisetindeki IoU skoru %87.44'ten %85.53'e düşmüştür. Parametre sayısının azalması ile birlikte modelin eğitim süresinin de azaldığı gözlenmiştir. İnce ayar aşamasında elde edilen sonuçlar Amiri M. vd. 2020 yaptığı ultrason görüntülerinin segmentasyonu çalışması ile uyumluluk göstermektedir.

Jadon S. 2020 tarafından beyin lezyonu segmentasyonu için CNN modelinin eğitiminde önerilen log\_cosh\_dice\_loss kayıp fonksiyonu yerine focal twersky fonksiyonunun polip segmentasyonunda daha başarılı sonuç verdiği görülmüştür. 2 nolu model ile log\_cosh\_dice\_loss fonksiyonu kullanılmış test verisetinde %85.59 IoU değeri elde edilmiştir. 3 nolu modelde ise focal twersky kayıp fonksiyonu ile test verisetinde %86.30 IoU skoru elde edilmiştir.

Shin vd. 2018 otomatik bölgesel kolon polip tespiti için geliştirdikleri modelde veri artırmanın model performansını artırdığı ifade edilmiştir. Tez çalışmasında ise InceptionResnetV2 ön eğitilmiş U-Net modelinde (Model 10) orjinal veriseti ile veri artırmadan önce test verisetinde %81.94 IoU değeri elde edilirken veri artırımı ile eğitilen modelde (Model 11) %87.60'lık IoU skoru elde edilmiştir.

Gelecek çalışmalarda Çekişmeli Üretici Ağlar (Generative Adversarial Networks) kullanılarak oluşturulacak olan sentetik tıbbi görüntüler eğitim verisetine eklenebilir, modelin eğitimine katkısı araştırılabilir.

Topluluk öğrenmeleri yöntemi ile oluşturulan farklı modeller birleştirilerek yeni modellerin performansa etkisi incelenebilir.

Çalışmada önerilen model için android, IOS tabanlı mobil uygulama geliştirilebilir, önerilen model bulut sisteminde çalışan bir servis olarak sunulabilir.

## 7 KAYNAKLAR

Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11), e00938. <https://doi.org/10.1016/j.heliyon.2018.e00938>

Akalın F. (2020) İnce Bağırsak Görüntüleri Üzerinde Sezgisel Algoritma Teknikleri İle Polip Teşhisi, Yüksek Lisans Tezi, Sakarya, Sakarya Üniversitesi

Akbari, M., Mohrekesh, M., Rafiei, S., Soroushmehr, S. R., Karimi, N., Samavi, S., & Najarian, K. (2018). Classification of informative frames in colonoscopy videos using convolutional neural networks with binarized weights. In 2018 40th annual international conference of the IEEE engineering in medicine and biology society (EMBC) (pp. 65-68). IEEE. DOI: 10.1109/EMBC.2018.8512226

Akbayir, A. (2020, 8 Mayıs). “Lenet — AlexNet — GoogLeNet — VGGNet ve Derinlemesine Resnet”. <https://ahmedakbayir.medium.com/resnet-ve-%C3%B6ncesi-cnn-mimarileri-791d0c9a9f75> adresinden alındı.

Amiri M., Brooks R., Rivaz H. 2020. “Fine-Tuning U-Net for Ultrasound Image Segmentation: Different Layers, Different Outcomes”. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control* 67(12): 2510-18. DOI: 10.1109/TUFFC.2020.3015081

Ataseven, B. (2013). Yapay sinir ağları ile öngörü modellemesi. *Öneri Dergisi*, 10(39), 101-115.

Bagheri R. (2020, 21 Temmuz) An Introduction to Deep Feedforward Neural Networks <https://towardsdatascience.com/an-introduction-to-deep-feedforward-neural-networks-1af281e306cd> adresinden alındı.

Bardhi, O., Sierra-Sosa, D., Garcia-Zapirain, B., & Elmaghraby, A. (2017, December). Automatic colon polyp detection using Convolutional encoder-decoder model. In 2017 IEEE international symposium on signal processing and information technology (ISSPIT) (pp. 445-448). IEEE. DOI: 10.1109/ISSPIT.2017.8388684

Basavarajaiah M. (2019, 8 Şubat) “Which Pooling Method Is Better? Maxpooling vs Minpooling vs Average Pooling”. Medium. <https://medium.com/@bdhuma/which-pooling-method-is-better-maxpooling-vs-minpooling-vs-average-pooling-95fb03f45a9> adresinden alındı.

Bernal, J., Sánchez, F. J., Fernández-Esparrach, G., Gil, D., Rodríguez, C., & Vilariño, F. (2015). WM-DOVA maps for accurate polyp highlighting in colonoscopy: Validation vs. saliency maps from physicians. *Computerized Medical Imaging and Graphics*, 43, 99-111. <https://doi.org/10.1016/j.compmedimag.2015.02.007>

Bernal, J., Tajbaksh, N., Sanchez, F. J., Matuszewski, B. J., Chen, H., Yu, L., & Histace, A. (2017). Comparative validation of polyp detection methods in video colonoscopy: results from the MICCAI 2015 endoscopic vision challenge. *IEEE transactions on medical imaging*, 36(6), 1231-1249.

Büyükgöze, S. & Dereli, E. (2019). Dijital Sağlık Uygulamalarında Yapay Zeka. VI. Uluslararası Bilimsel ve Mesleki Çalışmalar Kongresi-Fen ve Sağlık, 07-10. DOI: 10.1109/TMI.2017.2664042

Branch, M. V., & Carvalho, A. S. (2021). Polyp segmentation in colonoscopy images using u-net-mobilenetv2. arXiv preprint arXiv:2103.15715. <https://doi.org/10.48550/arXiv.2103.15715>

Cengiz E. 2020, Endoskopi Görüntülerindeki Poliplerin Derin Öğrenme Algoritması Kullanılarak İncelenmesi, Yüksek Lisans Tezi, Eskişehir, Eskişehir Osmangazi Üniversitesi

Çarkacı, N. (2018,22 Ocak). “Derin Öğrenme Uygulamalarında En Sık Kullanılan Hiper-Parametreler”. <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4> adresinden alındı.

Dabbura, I. (2017, 21 Aralık) “Gradient Descent Algorithm and Its Variants”. Medium. <https://towardsdatascience.com/gradient-descent-algorithm-and-its-variants-10f652806a3> adresinden alındı.

Ergin, T. (2018,2 Ekim) “Convolutional Neural Network (ConvNet Yada CNN) Nedir, Nasıl Çalışır?” <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad>

Ersoy, E. & Karal, Ö. (2012). Yapay sinir ağları ve insan beyni. İnsan ve Toplum Bilimleri Araştırmaları Dergisi, 1(2), 188-205.

Fırıldak, K. & Talu, M. F. (2019). Evrimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi. Computer Science , 4 (2) , 88-95 . <https://dergipark.org.tr/en/pub/bbd/issue/49546/527863>

Hannun, A. Y., Rajpurkar, P., Haghpanahi, M., Tison, G. H., Bourn, C., Turakhia, M. P., & Ng, A. Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. Nature medicine, 25(1), 65-69. <https://doi.org/10.1038/s41591-018-0268-3>

International Agency for Research On Cancer - World Health Organization 2020, <https://gco.iarc.fr/today/data/factsheets/cancers/39-All-cancers-fact-sheet.pdf>

Lee, J., Park, S. W., Kim, Y. S., Lee, K. J., Sung, H., Song, P. H., & Moon, J. S. (2017). Risk factors of missed colorectal lesions after colonoscopy. Medicine, 96(27). doi: 10.1097/MD.00000000000007468

Jadon, S. (2020, October). A survey of loss functions for semantic segmentation. In 2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB) (pp. 1-7). IEEE. DOI: 10.1109/CIBCB48159.2020.9277638

Karpathy A. (2021), Stanford University, Stanford CS class CS231n: “Convolutional Neural Networks for Visual Recognition” <https://cs231n.github.io/neural-networks-1/> adresinden alındı. Erişim Tarihi: 6 Şubat 2021

Kesici B. 2020. “Kolonoskopi nedir?” <https://www.medicalpark.com.tr/kolonoskopi/hg-2127> adresinden alındı (Erişim Tarihi: 17 Nisan 2021).

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. Advances in neural information processing systems, 25. <https://proceedings.neurips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf>

Kızrak, M. A. & Bolat, B. (2018). Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286.

Kutlu H. (2020) Derin Öğrenme Yöntemleri Kullanılarak Kalın Bağırsak Poliplerinin Tespiti Takibi Ve Sınıflandırılması, Doktora Tezi, Elazığ, Fırat Üniversitesi

LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324. DOI: 10.1109/5.726791

Leufkens, A. M., Van Oijen, M. G. H., Vleggaar, F. P., & Siersema, P. D. (2012). Factors influencing the miss rate of polyps in a back-to-back colonoscopy study. *Endoscopy*, 44(05), 470-475. DOI: 10.1055/s-0031-1291666

Mohammed, A., Yildirim, S., Farup, I., Pedersen, M., & Hovde, Ø. (2018). Y-net: A deep convolutional neural network for polyp detection. *arXiv preprint arXiv:1806.01907*. <https://doi.org/10.48550/arXiv.1806.01907>

Nabiyev, V.V. (2016) Yapay Zeka (5. Baskı), Ankara: Seçkin Yayıncılık

Nguyen, Quang, ve Sang-Woong Lee. 2018. "Colorectal Segmentation Using Multiple Encoder-Decoder Network in Colonoscopy Images". İçinde 2018 IEEE First International Conference on Artificial Intelligence and Knowledge Engineering (AIKE), , 208-11.

Özkan, İ. N. İ. K., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.

Ölmez E. (2020) Derin Öğrenme ve Morfolojik Görüntü İşleme Yöntemleri İle MR Görüntülerinde Otomatik Menüsküs Segmentasyonu Doktora Tezi, Yozgat, Yozgat Bozok Üniversitesi

Özcan A. R. (2020) EEG İşaretlerinde Evrişimli Sinir Ağları ile Epileptik Nöbet Tahmini, Doktora Tezi, Kocaeli, Kocaeli Üniversitesi

Özgür, S.N., Bozkurt Keser S. (2021). "Meme Kanseri Tümörlerinin Derin Öğrenme Algoritmaları ile Sınıflandırılması". *Türk Doğa ve Fen Dergisi* 10(2): 212-22.

Öztemel, E. (2020) Yapay Sinir Ağları (5. Baskı), İstanbul: Papatya Yayıncılık

Prabha, D. S., & Kumar, J. S. (2016). Performance evaluation of image segmentation using objective methods. *Indian J. Sci. Technol*, 9(8), 1-8. DOI: 10.17485/ijst/2016/v9i8/87907

Ronneberger O., Fischer P., and Brox T., "U-Net: Convolutional Networks for Biomedical Image Segmentation," in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, vol. 9351, N. Navab, J. Hornegger, W. M. Wells, and A. F. Frangi, Eds. Cham: Springer International Publishing, 2015, pp. 234–241. doi:10.1007/978-3-319-24574-4\_28

Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386-408. <https://doi.org/10.1037/h0042519>

Saha, Sumit. 2018. "A Comprehensive Guide to Convolutional Neural Networks — the ELI5 Way". Medium. <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53> ( Erişim Tarihi: 13 Şubat 2021).

Sánchez-Peralta, Luisa F. vd. 2020. “Deep Learning to Find Colorectal Polyps in Colonoscopy: A Systematic Literature Review”. *Artificial Intelligence in Medicine* 108: 101923. <https://doi.org/10.1016/j.artmed.2020.101923>

Shin, Younghak vd. 2018. “Automatic Colon Polyp Detection Using Region Based Deep CNN and Post Learning Approaches”. *IEEE Access* 6: 40950-62. DOI: 10.1109/ACCESS.2018.2856402

Sinecen, M. 2016. “Digital Image Processing with MATLAB”. *Applications from Engineering with MATLAB Concepts*. <https://www.intechopen.com/books/applications-from-engineering-with-matlab-concepts/digital-image-processing-with-matlab> adresinden alındı (Erişim Tarihi: 13 Şubat 2021)

Sohaib Najat H. (2019) Derin öğrenme yöntemleri ile cilt lezyon bölütlemesi, Yüksek Lisans Tezi, İstanbul, İstanbul Üniversitesi

Srivastava, N., G. E. Hinton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov (2014). "Dropout: a simple way to prevent neural networks from overfitting." *Journal of machine learning research* 15 (1): 1929- 1958.

Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826). <http://arxiv.org/abs/1512.00567>

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9). doi:10.1109/cvpr.2015.7298594

T.C. Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü Kanser Dairesi Başkanlığı. <https://hsgm.saglik.gov.tr/tr/kanser-tarama-standartlari/listesi/kolorektal-kanser-tarama-program%C4%B1-ulusal-standartlar%C4%B1.html> (31 Ocak 2021).

Tajbakhsh, Nima vd. 2016. “Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?” *IEEE Transactions on Medical Imaging* 35(5): 1299-1312. DOI: 10.1109/TMI.2016.2535302

Tajbakhsh, N., Gurudu, S. R., & Liang, J. (2016). Automated polyp detection in colonoscopy videos using shape and context information. *IEEE transactions on medical imaging*, 35(2), 630-644. [2487997]. <https://doi.org/10.1109/TMI.2015.2487997>

Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR. <https://doi.org/10.48550/arXiv.1905.11946>

Ucuzaal H. (2020) Yapay Zekaya Dayalı Anlamsal Video İşleme Yöntemlerinin Tıpta Kullanılabilirliğinin Araştırılması, Yüksek Lisans Tezi, Malatya, İnönü Üniversitesi

Vázquez, D., Bernal, J., Sánchez, F. J., Fernández-Esparrach, G., López, A. M., Romero, A., Courville, A. (2017). A benchmark for endoluminal scene segmentation of colonoscopy images. *Journal of healthcare engineering*, 2017. <https://doi.org/10.1155/2017/4037190>

Wani, M. A., Bhat, F. A., Afzal, S., & Khan, A. I. (2020). *Advances in Deep Learning. Studies in Big Data*. doi:10.1007/978-981-13-6794-6

Wichakam, Itsara vd. 2018. “Real-Time Polyps Segmentation for Colonoscopy Video Frames Using Compressed Fully Convolutional Network”. *MultiMedia Modeling*, ed. Klaus Schoeffmann vd. Cham: Springer International Publishing, 393-404. DOI: 10.1007/978-3-319-73603-7\_32

Wickstrøm K, Kampffmeyer M, Jenssen R. Uncertainty modeling and interpretability in convolutional neural networks for polyp segmentation. 2018 IEEE international workshop on machine learning for signal processing 2018. <https://doi.org/10.1109/MLSP.2018.8516998>.

Xiao, W. T., Chang, L. J., Liu, W. M. (2018). Semantic segmentation of colorectal polyps with DeepLab and LSTM networks. In 2018 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW) (pp. 1-2). IEEE. DOI: 10.1109/ICCE-China.2018.8448568

Yılmaz, A. (2021). Çok kanallı CNN mimarisi ile X-Ray görüntülerinden COVID-19 tanısı . *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* , 36 (4) , 1761-1774 . DOI: 10.17341/gazimmfd.746883

Zijie, Yuan vd. 2017. “Automatic polyp detection in colonoscopy videos”. <https://doi.org/10.1117/12.2254671>.