

Akciğer Benign ve Malign Tümörlerinin Bölütlemesi için Segmentasyon Modellerinin
Karşılaştırılması

İrem Nur Yoldaş

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

ARALIK 2022

Comparison of Segmentation Models for Segmentation of Benign and Malignant Tumors of
the Lungs

İrem Nur Yoldaş

MASTER OF SCIENCE THESIS

Department of Computer Engineering

DECEMBER 2022

Akciğer Benign ve Malign Tümörlerinin Bölütlemesi için Segmentasyon Modellerinin
Karşılaştırılması

İrem Nur Yoldaş

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliği Uyarınca
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Yazılımı Bilim Dalı
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır

Danışman: Prof. Dr. Kemal Özkan
İkinci Danışman: Prof. Dr. Hakan Çevikalp

ARALIK 2022

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Prof. Dr. Kemal Özkan danışmanlığında hazırlamış olduğum “**Akciğer Benign ve Malign Tümörlerinin Bölütlemesi için Segmentasyon Modellerinin Karşılaştırılması**” başlıklı tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim. 02/01/2023

İrem Nur Yoldaş

ÖZET

Bu tez çalışması, çalışma kapsamında hazırlanmış yeni bir medikal görüntü setini kullanarak akciğer benign ve malign tümör segmentasyonunu konu almaktadır. Veriler sırasıyla; kanalların ayrı eğitilmesi, aynı hastaya ait tümör görüntüsünün farklı kanalları olan P, K ve M kanallarının birer veri seti olarak eğitilmesi ve kanalların birleştirilerek eğitilmesi olmak üzere toplam üç farklı versiyonda eğitilmiştir. Bahsedilen üç versiyon için ortak olarak Mask R-CNN mimarisi ve ResNet-101 sınıflandırıcısı kullanılmıştır. Sonuç olarak kanallar arasında en çok bilgi sağlayanının %59,86 mAP değeri ile K kanalı olduğu görülmüştür. Sınıf bazında ise %72,88 AP değeri ile K kanalının benign tümör ve %57,02 AP değeri ile M kanalının malign tümör tespitinde en başarılı kanal olduğu görülmüştür. Aynı mimari için üçüncü versiyon veri seti elde ettiği %67,16 mAP değeri ile beklentileri doğrulayarak en başarılı versiyon olmuştur. Veri setinin üçüncü versiyonu Mask R-CNN'e ek olarak YOLACT, SOLOv2 ve DeepLabv3+ mimarileri ve ResNet-101 sınıflandırıcısı ile eğitilmiştir. %74,14 mAP ile YOLACT en başarılı sonucu verirken SOLOv2 ile %62,70 mAP elde edilmiştir. Bir semantik segmentasyon ağı olan DeepLabv3+ %36,81 mAP ile diğer modellere göre başarılı segmentasyon sonuçları üretememiştir. Yapılan tez çalışması ile literatüre yeni veri seti ve akciğer MR görüntüsü üzerinde tümörün sınıfıyla birlikte segmentasyonunun sağlandığı bir çalışma eklenmiştir.

Anahtar Kelimeler: örnek segmentasyonu, semantik segmentasyon, derin öğrenme, benign akciğer tümör, malign akciğer tümör, MRI veri seti

SUMMARY

This thesis study is about lung benign and malignant tumor segmentation using a new set of medical images prepared within the scope of the study. The data are respectively; it was trained in three different versions, namely training the channels separately, training the P, K and M channels, which are different channels of the tumor image of the same patient, as a data set, and training the channels by combining them. Mask R-CNN architecture and ResNet-101 classifier were used in common for the three versions mentioned. As a result, it was seen that the K channel provides the most information among the channels with the value of %59.86 mAP. On the basis of class, the K channel was found to be the most successful channel in detecting benign tumors with %72.88 AP value, and the M channel was the most successful channel in detecting malignant tumors with %57.02 AP values. For the same architecture, the third version dataset was the most successful version, confirming the expectations with the value of %67.16 mAP. The third version of the dataset was trained with the YOLACT, SOLOv2 and DeepLabv3+ architectures and the ResNet-101 classifier in addition to Mask R-CNN. %74.14 mAP with YOLACT gave the most successful results, while SOLOv2 with %62.70 mAP. DeepLabv3+, a semantic segmentation network, could not produce successful segmentation results with %36.81 mAP compared to other models. With the thesis study, a new data set and a study in which the segmentation of the tumor is provided on the lung MR image have been added to the literature.

Keywords: instance segmentation, semantic segmentation, deep learning, benign lung tumor, malignant lung tumor, MRI dataset

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	vi
SUMMARY	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xiii
KISALTMALAR DİZİNİ	xiv
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	3
2.1. Akciğer Tümörü	3
2.1.1. Benign Akciğer Tümörü	4
2.1.2. Malign Akciğer Tümörü	5
2.2. Tıbbi Görüntüleme	6
2.2.1. Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging) (MRI)	7
2.2.2. Dijital Görüntü İşleme	8
2.3. Makine Öğrenmesi (Machine Learning) (ML)	9
2.4. Derin Öğrenme	14
2.5. Evrişimsel Sinir Ağları (Convolutional Neural Networks) (CNN)	16
2.6. Medikal Görüntü Segmentasyonu	20
2.7. Benzer Çalışmalar	21
3. MATERYAL VE YÖNTEM	28
3.1. Veri Seti	28
3.1.1. Birinci Versiyon	28
3.1.2. İkinci Versiyon	29
3.1.3. Üçüncü Versiyon	29
3.2. Ön İşleme	31
3.3. Derin Öğrenme Mimarileri	32

İÇİNDEKİLER (devam)

3.3.1.	Mask R-CNN	32
3.3.2.	DeepLabv3+	33
3.3.3.	You Only Look at Coefficients (YOLACT)	35
3.3.4.	Segmenting Objects by Locations (SOLOv2)	37
3.4.	Değerlendirme Metrikleri	39
3.4.1.	Karmaşıklık Matrisi	39
3.4.2.	Birleşim Üzerinden Kesişim (Intersection over Union) (IoU)	39
3.4.3.	Ortalama Kesinlik (Average Precision) (AP)	40
3.4.4.	Sorenson-Dice Katsayısı	41
4.	BULGULAR VE TARTIŞMA	42
5.	SONUÇ VE ÖNERİLER	54
	KAYNAKLAR DİZİNİ	56

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
2.1 Benign Akciğer Tümörü	4
2.2 Malign Akciğer Tümörü	5
2.3 Tıbbi Görüntüleme Sistemi (Subagja, 2019)	7
2.4 Gri Tonlamalı ve RGB Görüntülerin Matris Temsili	8
2.5 Önerilen Sistemlerin Akış Diyagramı (Moradi ve diğ., 2015)	13
2.6 Yapay Zeka, ML ve Derin Öğrenme İlişkisi (Chollet, 2018)	14
2.7 Temel Derin Öğrenme Adımları (Chollet, 2018)	15
2.8 Evrişimin İşleyişi (Chollet, 2018)	18
2.9 Piksel Ekleme Örnek (Chollet, 2018)	19
2.10 Maksimum Havuzlama Katmanı Temsili (Rana, 2020)	19
2.11 Semantik ve Örnek Segmentasyon Farkı (SuperAnnotate, 2021)	21
2.12 MIScnn Veri Hattı Akış Şeması (D. Müller ve Kramer, 2021)	22
2.13 AMRSeg-Net Mimarisi (J. Li, H. Chen, Y. Li, Peng, Cai ve diğ., 2021)	24
2.14 Çalışmanın Akış Şeması (Padma ve diğ., 2022)	25
2.15 CICVAE Mimarisi (J. Li, H. Chen, Y. Li, Peng, Sun ve diğ., 2022)	26
2.16 DRS-CNN-1 ve DRS-CNN-2 Mimarileri (Dutande ve diğ., 2022)	27
3.1 Veri Setinin P, K ve M Kanallarının Birleştirilmesi	29
3.2 Veri Setinden Örnekler	30
3.3 Veri Setinin P, K ve M Kanallarının Etiketlerinin Birleştirilmesi	31
3.4 Mask R-CNN Mimarisi Temsili (He ve diğ., 2017)	33
3.5 DeepLabv3+ Mimarisi Temsili (L.-C. Chen, Zhu ve diğ., 2018)	34
3.6 Derinlemesine, Noktasal ve Atrous Evrişim Katmanlarının Çalışma Prensipli (L.-C. Chen, Zhu ve diğ., 2018)	35
3.7 Tahmin Kafası Bloğu Temsili (Bolya ve diğ., 2019)	36
3.8 YOLACT Mimarisi (Bolya ve diğ., 2019)	37
3.9 SOLOv2 Mimarisi (X. Wang ve diğ., 2020)	38
3.10 IoU Metriği (Padilla ve diğ., 2020)	40
4.1 Veri Seti Versiyon-1 için Orijinal Görüntüler, Maskeler ve Tahmin Edilen Maskeler	43
4.2 Veri Seti Versiyon-2 K Kanalı için Orijinal Görüntüler ve Tahmin Edilen Maskeler	45
4.3 Veri Seti Versiyon-2 P Kanalı için Orijinal Görüntüler ve Tahmin Edilen Maskeler	46
4.4 Veri Seti Versiyon-2 M Kanalı için Orijinal Görüntüler ve Tahmin Edilen Maskeler	47
4.5 Veri Seti Versiyon-3 için Mask R-CNN Mimarisinin Ürettiği Orijinal Görüntüler, Maskeler ve Tahmin Edilen Maskeler	49

ŞEKİLLER DİZİNİ (devam)

4.6	Veri Seti Versiyon-3 için YOLACT Mimarisinin Ürettiği Orijinal Görüntüler, Maskeler ve Tahmin Edilen Maskeler	50
4.7	Veri Seti Versiyon-3 için SOLOv2 Mimarisinin Ürettiği Orijinal Görüntüler, Maskeler ve Tahmin Edilen Maskeler	51
4.8	Veri Seti Versiyon-3 için DeepLabv3+ Mimarisinin Ürettiği Orijinal Görüntüler, Maskeler ve Tahmin Edilen Maskeler	52



ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
2.1 Temel ML Terimleri (Mohri ve diğ., 2018)	10
3.1 Karmaşıklık Matrisi	39
4.1 Veri Setinin Birinci Versiyonu için Eğitim Sonuçları	42
4.2 Veri Setinin İkinci Versiyonu için Eğitim Sonuçları	44
4.3 Veri Setinin Üçüncü Versiyonu için Örnek Segmentasyonu Modellerinin Eğitim Sonuçları	48
5.1 Veri Setinin Birinci, İkinci ve Üçüncü Versiyonlarında Veri Dağılımı	54

KISALTMALAR DİZİNİ

<u>Kısaltma</u>	<u>Tanım</u>
3D	Üç Boyutlu (Tree Dimensional)
ADNI	Alzheimer Hastalığı Nörogörüntüleme Girişimi (Alzheimer's Disease Neuroimaging Initiative)
AP	Ortalama Kesinlik (Average Precision)
ASPP	(Atrous Mekansal Piramit Havuzu (Atrous Spatial Pyramid Pooling)
AUC	ROC Eğrisi Altında Kalan Alan (Area under the ROC Curve)
CBCT	Koni Işınlı Bilgisayarlı Tomografi (Cone Beam Computed Tomography)
CICVAE	Döngü Tutarlı Görüntü Koşullu Varyasyonel Otomatik Kodlayıcı (Cycle-Consistent Image Conditional Variational Auto-Encoders)
CLDA	Kısıtlı Doğrusal Ayırma Analizi (Constrained Linear Discriminant Analysis)
CNN	Evrişimsel Sinir Ağları (Convolutional Neural Network)
COCO	Common Objects in COntext
CT	Bilgisayarlı Tomografi (Computerized Tomography)
DBN	Derin İnanç Ağları (Deep Belief Network)
DCNN	Derin Evrişimsel Sinir Ağları (Deep Convolutaional Neural Network)
DRS-CNN	Derin Kalıntı Ayrılabilir Evrişimsel Sinir Ağı (Deep Residual Separable Convolutional Neural Network)
FCN	Tam Evrişimsel Ağ (Fully Convolutaional Network)
FN	Yanlış Negatif (False Negative)
FP	Yanlış Pozitif (False Positive)
FPN	Öznitelik Piramit Ağı (Feature Pyramid Network)
FPS	Saniyedeki Kare Sayısı (Frame Per Second)
GAN	Çekişmeli Üretici Ağ (Generative Adversarial Networks)
GPU	Grafik İşlemci Birimi (Graphics Processing Unit)
HPV	İnsan Papilloma Virüsü (Human Papilloma Virus)
ICVAE	Görüntü Koşullu Otomatik Değişken Kodlayıcı (Image Conditional Variational Auto-Encoders)

<u>Kısaltma</u>	<u>Tanım</u>
IoU	Birleşim Üzerinden Kesişim (Intersection over Union)
JSON	JavaScript Object Notation
k-NN	k En Yakın Komşu (k Nearest Neighbors)
KiTS	Böbrek Tümör Segmentasyonu (Kidney Tumor Segmentation)
LDA	Doğrusal Ayırma Analizi (Linear Discriminant Analysis)
LDS	Düşük Yoğunluklu Ayırma (Low Density Separation)
LSTM	Uzun Kısa Süreli Bellek (Long Short Term Memory)
mAP	Ortalama AP (Mean Average Precision)
MCI	Hafif Bilişsel Bozukluk (Mild Cognitive Impairment)
MIP	Maksimum Yoğunluk Projeksiyonu (Maximum Intensity Projection)
MIScnn	Evrişimsel Sinir Ağları ile Medikal Görüntü Segmentasyonu (Medical Image Segmentation with Convolutional Neural Networks)
ML	Makine Öğrenmesi (Machine Learning)
MR	Manyetik Rezonans (Magnetic Resonance)
MRI	Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging)
MSD	Medical Segmentation Decathlon
NMR	Nükleer Manyetik Rezonans (Nuclear Magnetic Resonance)
NMRI	Nükleer Manyetik Rezonans Görüntüleme (Nuclear Magnetic Resonance Imaging)
NMS	Maksimum Olmayan Bastırma (Non-Maximum Suppression)
Pascal VOC	Pascal Visual Object Classes
PET	Pozitron Emisyon Tomografisi (Positron Emission Tomography)
pMCI	İlerici Hafif Bilişsel Bozukluk (Progressive Mild Cognitive Impairment)
PR	Keskinlik Duyarlılık (Precision Recall)
R-CNN	Bölge Tabanlı Evrişimsel Sinir Ağı (Region-Based Convolutional Neural Network)
ReLu	Rektifiye Lineer Birim (Rectified Linear Units)
ResNet	Artık Ağ (Residual Network)
RF	Rastgele Orman (Random Forest)
RGB	Kırmızı Yeşil Mavi (Red Green Blue)

<u>Kısaltma</u>	<u>Tanım</u>
RMSD	Kök Ortalama Kare Yüzey Mesafesi (Root Mean Square Deviation)
RNN	Tekrarlayan Sinir Ağları (Recurrent Neural Network)
ROC	İşlem Karakteristikleri Eğrisi (Receiver Operating Characteristic)
ROI	İlgi Alanı (Region of Interest)
RPN	Bölge Teklif Önerici Ağ (Region Proposal Network)
sMCI	Stabil Hafif Bilişsel Bozukluk (Stable Mild Cognitive Impairment)
SOLOv2	Segmenting Objects by LOcations
SVM	Destek Vektör Makinesi (Support Vector Machine)
TN	Gerçek Negatif (True Negative)
TP	Gerçek Pozitif (True Positive)
uMCI	Bilinmeyen Hafif Bilişsel Bozukluk (Unknown Mild Cognitive Impairment)
XML	Extensible Markup Language
YOLACT	You Only Look CoefficientS

1. GİRİŞ VE AMAÇ

Bu tez çalışmasında Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Hastanesi Radyoloji Bölümü ile ortak çalışma sonucu ortaya çıkarılmış olan ve Manyetik Rezonans (Magnetic Resonance) (MR) akciğer tümörü görüntülerini içeren veri setini segmentasyon yöntemleri ile değerlendirmek hedeflenmiştir. Hazırlanan veri setinin farklı ayırımları ile tümörleri segmente etmek amaçlanmıştır. Bu çalışma, medikal görüntü segmentasyonu konusunu içermektedir.

Medikal görüntülerin doğru analiz edilmesi; hastalıkların doğru ve erken teşhisinde, tedavi ve cerrahi süreçlerin planlanmasında büyük rol oynamaktadır. Özellikle kötü huylu akciğer tümörü beş yıllık sağkalım oranları düşük olan kanser türleri arasındadır. Genellikle son evreye gelene kadar belirti vermeyen akciğer kanserini erken farketmek hayati önem taşımaktadır. Medikal görüntülerin yorumlanmasının tamamen insan uzman yorumuna bağlı olması ise detayları farketmeme, yanlış yorumlama vb. olumsuzluklara yol açabilmektedir. Biriken medikal görüntüleri değerlendirmek ve uzmanlara yardımcı olmak amacıyla medikal görüntü segmentasyonu araştırmacılar arasında artan bir popüleriteye sahiptir. Tümör segmentasyonu için kullanılan görüntülerin sıklıkla Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging) (MRI) ve Bilgisayarlı Tomografi (Computerized Tomography) (CT) görüntüleri olduğu görülmektedir.

Dijital görüntü segmentasyonu, ileri seviye dijital görüntü işleme olarak geçmektedir. Bu yüksek seviyeli görev halen gelişmekte ve multidisipliner oluşuyla genişlemektedir. Tıbbi görüntü segmentasyonu ise dijital görüntü segmentasyonu uygulanabilen diğer alanlara göre ek zorluklar içermektedir. Medikal görüntülere ulaşmak bu zorluklardan biridir. Yeni veri seti oluşumunda ise etiketlerin muhakkak uzmanlar kontrolünde oluşturulması gerekmektedir. Medikal veri seti hazırlanırken hata payının düşük olması amaçlanmaktadır. Önerdiğimiz veri seti, dört kanallı MR görüntüsüne ait P, K ve M kanallarını kullanmaktadır. Veri seti, akciğerinde tümör bulunan 84 hastadan elde edilmiştir. 543 eğitim, 137 doğrulama örneği olmak üzere toplam 680 örnekten oluşmaktadır. Bu örneklerin 307 tanesi benign ve 373 tanesi malign tümördür.

Çalışma kapsamında literatürde popüler segmentasyon yöntemlerinin tıbbi görüntü segmentasyonu alanında başarıları gözlenmiştir. Segmentasyon için Mask R-CNN (He ve diğ., 2017), DeepLabv3+ (L.-C. Chen, Zhu ve diğ., 2018), You Only Look CoefficientS (Bolya ve diğ., 2019) ve Segmenting Objects by LOcations (X. Wang ve diğ., 2020)

mimarileri kullanılmıştır. Mask R-CNN iki aşamalı bir örnek segmentasyonu mimarisidir (He ve diğ., 2017). İlk aşamasında bölge teklifleri oluşturmakta ikinci aşamasında ise örnek maske oluşturmaktadır. Faster R-CNN (Daha Hızlı Bölge Tabanlı Evrişimli Sinir Ağı) (Ren ve diğ., 2015) nesne tespit ağına maske modülü eklenmesi ile meydana gelmiştir. YOLACT, Mask R-CNN gibi var olan nesne tespiti ağı olan RetinaNet'e (Lin, Goyal ve diğ., 2017) maske modülü ekleyerek örnek segmentasyonu modeli elde etmiştir (Bolya ve diğ., 2019). Mask R-CNN'den farklı olarak YOLACT tek aşamalı mimaridir. Modelde, hızı arttırmak için bölge önerisi adımı atlanmıştır ve maske katsayısı tahmin etmeye dayalı bir yol izlenmektedir. SOLOv2'nin (X. Wang ve diğ., 2020) hedefi piksel kümeleme ya da nesne tespiti yapmadan doğrudan segmentasyon yapabilmektir. Mimari bu amaçla görüntüyü ızgaralara bölmektedir. Izgarada nesne merkezi bulunması halinde ızgara, öznitelik ve evrişim çekirdeği öğrenme görevlerini gerçekleştirmektedir. Öğrenme görevlerinden gelen bu iki maske birleştirilerek prototip maskeleri elde edilmektedir. DeepLabv3+, kodlayıcı-kod çözücü bir mimaridir. Semantik segmentasyon yapan bu mimari kodlayıcı kısmında çıkardığı öznitelikleri kullanarak kod çözücü kısımda maske önerisi üretmektedir. Dört farklı segmentasyon mimarisinin önerilen veri seti üzerindeki segmentasyon başarıları karşılaştırılmıştır. Çalışmanın özgün değeri ve literatüre katkısı aşağıdaki gibi özetlenmiştir:

- Bu tez ile uzmanlar eşliğinde etiketlenmiş yeni bir veri seti önerilmiştir. Örnekler akciğer MR görüntülerinden oluşmaktadır ve tümör segmentasyonu hedeflenmektedir. Veri seti, benign ve malign olmak üzere iki sınıf etiketinden oluşmaktadır.
- Literatürdeki akciğer tümör segmentasyonu çalışmalarının aksine CT görüntüleri değil MR görüntüleri kullanılmıştır. Tümörün yerinin segmente edilmesine ek olarak türü de tahmin edilmiştir.
- Ağ seçimleri, medikal görüntü segmentasyonu alanında literatürde henüz kullanılmamış ya da az sayıda kullanılmış mimariler arasından yapılmıştır.
- Segmentasyon halen gelişmekte olan bir alan olarak karşımıza çıkmaktadır. Bu sebeple Türkçe kaynak sıkıntısı bulunmaktadır. Bu çalışmada Makine Öğrenmesi (Machine Learning) (ML), derin öğrenme ve dijital görüntü segmentasyonu kavramları derinlemesine incelenmiş ve anlaşılabilir şekilde verilmiştir. Segmentasyon modellerinin çalışma prensipleri açık şekilde anlatılmıştır. Bu yönüyle çalışmanın Türkçe kaynak kullanmayı arzu eden araştırmacılara yardım etme potansiyeli vardır.

2. LİTERATÜR ARAŞTIRMASI

2.1 Akciğer Tümörü


Doğada bulunan diğer canlılara benzer şekilde hücreler doğmakta, büyümekte, belli miktarda çoğalıp ölerek yerini sağlıklı hücrelere bırakmaktadır (Çakıcı, 2019). Sebebi kesin olarak bilinmemek ile beraber genetik, yaşam koşulları, alışkanlıklar vb. tetikleyici faktörlerin etkisiyle bahsi geçen yaşam döngüsü hücrelerin gerektiğinde ölmemeleri ya da kontrolsüz olarak çoğalmaları sebebiyle bozunuma uğramaktadır. Hayat döngüsü bozulmuş olan bu hücrelerin kümeleşmesi, tümör diğer bir ismi ile neoplazmi oluşumuna sebep olmaktadır (Charles, 2019).

Akciğer tümörü; geçmeyen ve giderek kötüleşen öksürük, bu öksürük ile kan veya kanlı balgam çıkarmak, tekerrür eden veyahut geçmeyen akciğer enfeksiyonları, sesin kısılması, nefesin daralması, iştah problemleri ve buna bağlı olarak kilo kaybı, yorgunluk, derin nefes alma, öksürük ve gülme durumlarında kötüleşen göğüs ağrısı gibi belirtiler vermektedir (HSGM, 2017). Çoğu vaka için ilk olarak fiziki muayene ile başlayan tanı süreci bulunmaktadır. Sonrasında ayrıntı yakalamak için göğüs röntgeni, CT, MRI vb. yöntemler tercih edilmektedir. Akciğerden alınan biyopsinin patolojik incelenmesi sonucunda kesin tanı belli olmaktadır. Tümörlerin tedavisi için cerrahi, radyocerrahi, radyoterapi ve kemoterapi yöntemlerinden hastaya uygun olanı uygulanmaktadır.


Akciğer tümörleri, akciğerde bulunan hücrelerin bozunumu sebebiyle ortaya çıkmaktadır. Bu bozunuma sahip olan hastaların %80 – 90'ı tütün ve ürünlerini kullanmaktadır (Hofmann ve diğ., 2004). İkinci el dumana maruz kalma, hava kirliliği vb. etkenler de hastalığı tetiklemektedir. Tümörler meydana geliş biçimleri ile temel olarak ikiye ayrılmaktadır. Eğer tümör akciğerde başladıysa ve mevcut olan diğer tümörler ile ilgisi yoksa tümör birincil akciğer tümörü olarak adlandırılmaktadır (Charles, 2019). Diğer yandan başka bir dokuda meydana gelmiş kansere ait hücre dolaşım ya da lenf sistemi ile akciğere gelip orada tutunmuş ise böyle bir tümöre metastaz ya da ikincil akciğer tümörü ismi verilmektedir. Mesane, meme, kolon, prostat kanserleri, nöroblastom ve sarkom genellikle akciğere yayılım gösteren kanser türleridir. İkincil akciğer tümörleri akciğer kanseri olarak geçmemektedir. Örnek olarak kolon kanseri akciğere sıçramışsa buna akciğer metastazlı kolon kanseri denilmektedir. Davranışları açısından ise tümörler iyi huylu (benign) ve kötü huylu (malign) tümörler olarak iki ana başlıkta incelenmektedir.

2.1.1 Benign Akciğer Tümörü

Benign diğer adıyla iyi huylu akciğer tümörü, kanserli olmayan akciğer tümörü olarak tanımlanmaktadır. Diğer dokulara metastaz yapmaz ve ilerlemesi yavaştır (CCS, 2020b). Boyut artışı, malign tümöre dönüşme vb. değişimler gösterme riskine karşın hastanın sağlık ekibi tarafından düzenli olarak kontrol edilmelidir. Genellikle hastanın yaşamını tehdit etmemektedir bu sebeple anormal doku büyümesi olarak tanımlanması mümkündür. Tıpkı diğer tümörler gibi tıbbi görüntüleme teknikleri ile tespit edilmektedir. Görüntü olarak kötü huylu tümörlerden oldukça farklıdır. Daha küçüktür ve kapsül gibi sınırları bellidir. Oluşturulan veri setinden alınan bir örnek ile benign akciğer tümörü Şekil 2.1’de gösterilmiştir.



(a) Tümörün MR Görüntüsü



(b) Tümörün İşaretlenmesi

Şekil 2.1 Benign Akciğer Tümörü

Bening akciğer tümörü bir çok durumda belirti vermemektedir. Ancak belirti verirse sıklıkla tekrar eden akciğer enfeksiyonları, öksürük, göğüste hırıltı, nefes alma sorunları ortaya çıkabilmektedir (Stuart, 2021). Pulmoner hamartom, bronşiyal adenom ve papillom akciğerde görülen benign tümörler arasındadır. Pulmoner hamartom, akciğerde en sık görülen benign tümördür (Temiz ve Gezer, 2016). Birçok durumda 4 santimetreden küçük olarak gözlemlenmiştir. Genellikle kas, yağ, kıkırdak gibi farklı hücre çeşitlerinden kaynaklanmaktadır (Charles, 2019). Bronşiyal adenom, pulmoner hamartomdan sonra akciğerde en çok rastlanan iyi huylu tümördür (CCS, 2020b). Bu tip bir tümör bronşlarda bulunan mukus bezlerinden ya da bu bezlerin boşaltımını sağlayan kanallardan meydana gelmektedir (Brooks ve Krummel, 2006). Papillom ise akciğerlerin içinde bulunan epitel dokularda oluşum göstermektedir (CCS, 2020b). İnsan Papilloma Virüsü (Human Papilloma Virus) (HPV) sonucunda ortaya çıkan skuamöz papillom, en sık rastlanan papillomlardan biridir (Charles, 2019).


2.1.2 Malign Akciğer Tümörü

Kötü huylu akciğer tümörü ya da akciğer kanseri olarak bilinen malign akciğer tümörü 2008 yılı verilerine göre %12,7'lik bir oran ile en sık karşılaşılan kanser türüdür (Ferlay ve diğ., 2010). Küresel olarak kansere bağlı ölümlerin %18,2'sini aynı zamanda en büyük kısmını oluşturmaktadır. Ulusal Kanser Enstitüsü'nün 2012-2018 SEER Kanser İstatistikleri İncelemesi raporlarına göre beş yıllık sağkalım oranı yaklaşık olarak %22,9'dur (NCI, 2022). Bahsi geçen oran sıklıkla karşılaşılan başka kanser türlerinin sağkalım oranından daha düşüktür. Örneğin aynı verilere göre meme kanserinin sağkalım oranı %90,6 olarak verilmiştir. 2019 yılı Birleşik Krallık verilerine göre akciğer kanseri tanısına sahip hastaların %40'ından fazlası 75 yaştan üzerindedir ve tanı alanların %30'u en az bir yıl %5'i en az 10 yıl yaşamaktadır (NHS, 2019) .

Malign akciğer tümörü, dağınık ve çoğu zaman büyük bir görünüme sahiptir. Oluşturulan veri setinden alınan örnek Şekil 2.2'de verilmiştir. Benign akciğer tümörlerine benzer şekilde akciğer kanseri de birçok durumda ilk aşamalarda belirti göstermemektedir (NHS, 2019). İlerleyen aşamalarla birlikte kalıcı nefes darlığı, kalıcı öksürük, kan tükürme, sebepsiz kilo kaybı ve yorgunluk gibi semptomlar ortaya çıkmaktadır. Hastalığın tedavisi için cerrahi operasyon uygulanabilmektedir (Herrera ve diğ., 2003). Ancak bazen kanserin konumu veya dağılmış oluşu buna müsaade etmemektedir. Bu sebeple cerrahiye alternatif olarak radyoterapi veya kemoterapi uygulanmaktadır.



(a) Tümörün MR Görüntüsü



(b) Tümörün İşaretlenmesi

Şekil 2.2 Malign Akciğer Tümörü

Primer akciğer kanseri (CCS, 2020a) temel olarak 2 ana başlık altında incelenmektedir: Küçük hücreli akciğer kanseri, Küçük hücreli olmayan akciğer kanseri. Küçük hücreli akciğer kanseri, adını küçük görünmesinden almıştır. Çoğu vakada vücudun


diğer bölgelerine metastaz yaptıktan sonra teşhis edilmektedir. Oldukça agresiftir. İki ana türü vardır. Bunlar, küçük hücreli karsinom ve kombine küçük hücreli karsinomdur. Küçük hücreli olmayan akciğer kanseri ise akciğerde en sık görülen kanser türüdür. Tüm akciğer kanseri vakalarının %80 – 85'ini oluşturmaktadır. Akciğerde bulunan farklı hücre veya dokularda başlangıç gösterebilen bu kanserin pek çok alt türü bulunmaktadır. Örnek olarak, adenokarsinom, skuamöz hücre karsinomu, büyük hücreli karsinom küçük hücreli olmayan karsinomun birkaç alt türüdür (NHS, 2019).

2.2 Tıbbi Görüntüleme

Vücut olarak ifade edilen varlık deri, kas, yağ vb. dokular ile kaplıdır ve sağlıklı bir vücutta iç organlar ile kemikler çıplak göz ile görülemez. Tıbbi görüntüleme, iç organları ve kemikleri görüntüleyerek bir sorun olması durumunda bu sorunu tespit edebilmek için kullanılan yöntemlerin tümüne verilen isimdir (Bilyk, 2020). Örneğin trafik kazası geçirmiş bir hastanın kemiklerinde kırık ve iç kanama olup olmadığını kontrol etmek için tıbbi görüntülemeye dayanılmaktadır. Bunun yanı sıra araştırmacılara, anatominin nasıl işlediğini anlamalarında yardımcı olmaktadır.

Tıbbi görüntüleme yöntemleri; kanser, iç kanama, damar tıkanıklığı, kalp hastalıkları, travmalar gibi pek çok hastalığın tespit edilmesinde kullanılırken farklı hastalıkların tespitinde farklı tıbbi görüntüleme yöntemleri kullanılmaktadır. Röntgen, CT, MRI, ultrasonografi, anjiyografi, Pozitron Emisyon Tomografisi (Positron Emission Tomography) (PET) sıklıkla kullanılan ve birçok kişi tarafından bilinen tıbbi görüntüleme yöntemlerindendir. Bütün bu yöntemlerin temeli ise röntgene dayanmaktadır (M. Y. Chen ve Whitlow, 2011). Röntgen, 1895 yılında fizikçi Wilhelm Röntgen tarafından X ışınları olarak bilinen röntgen ışınlarının bulunması ile ortaya çıkmıştır. X ışınını içerdiği iyonlaştırıcı radyasyonun DNA yapısını bozmaya yetecek enerjiye sahip olması nedeniyle bazı anormalliklere sebep olabilmektedir (FDA, 2020a). Bu sebeple hamile ve reşit olmayan hastalara önerilmemektedir.

Görüntüleme işleminde ışınlar, manyetik alanlar ve ses dalgaları gibi gözle görülemeyen dalgalar kullanılmaktadır. Örneğin röntgen ve CT'de görüntü alabilmek için X ışını, MRI'da manyetik alan, ultrasonografide ise ses dalgaları kullanılmaktadır. Şekil 2.3'te verildiği gibi görüntüleme yaparken genel olarak bir kaynaktan nesneye yöneltilen bu dalgalar, nesnenin yoğunluğuna göre yoğunluğu fazla olan bölgelerce soğrulmakta diğer bölgelerin ise içinden geçmektedir (FDA, 2020b). Nesnenin içinden geçen dalgalar nesnenin arkasına konumlandırılmış olan dedektörler ile yakalanmakta ve matematiksel hesaplamalar ile görüntü elde edilmektedir.



Şekil 2.3 Tıbbi Görüntüleme Sistemi (Subagja, 2019)

2.2.1 Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging) (MRI)

Ana amacı yumuşak dokuları görüntülemek ve işleyişinin incelenmesine yardım etmek olan MRI, esnekliği ve hassas ölçüm yapabilmesi ile güçlü bir görüntüleme yöntemidir (Brown ve diğ., 2014). MRI'nın günümüzde geldiği noktaya ulaşmasının esas sebebi güvenli ve neredeyse her yaştan hastanın hastalığının teşhisinde kullanılabilir olmasından gelmektedir. Bunun sebebi Bölüm 2.2'de bahsedildiği gibi MRI görüntü almak için manyetik alan kullanmaktadır ve radyasyon içermemektedir. Görüntüleme için güçlü bir manyetik alan kullanmaktadır ve bu manyetik alan dünyanın manyetik alanının yaklaşık 25000 katıdır. Bu sebeple vücudunda metal parça taşıyanlar MRI cihazına girememektedirler. Aynı sebeple boyasında kurşun ya da demir bulunma riskine karşın kalıcı dövme sahiplerine ve daha önce silahla yaralanmış kişilere MRI cihazına girmeleri önerilmemektedir.


MRI, Nükleer Manyetik Rezonans (Nuclear Magnetic Resonance) (NMR) tıbbi görüntülemeye uygulanması ile ortaya çıkmıştır. NMR, 1940'ların başlarından itibaren bilinmesine rağmen bunun tıbbi görüntülemenin bir alanı olarak kullanılması 1973 yılında Paul C. Lauterbur tarafından gerçekleştirilmiştir (Suetens, 2009). Lauterbur, NMR için kullanılan manyetik alandaki gradyanların yerleştirilmesini yumuşak doku ve organlardan görüntü almak için kullanmıştır. Atom içinde bulunan proton ve nötronlar hareketli yapılardır. Bu sayede atomlar ve moleküller manyetik alan içerisinde belirli bir yönelim almaktadır (*Lauterbur - Facts Nobel Prize Outreach* 2022). Ancak bu yönelimi yakalamak için her farklı atoma farklı frekanstaki radyo dalgaları gerekmektedir. 1974 yılında Peter Mansfield, bu fenomenin insan vücudunun iç kısmının görüntülerinin oluşturulması için kullanılmasını konu alan matematiksel bir teori sunmuştur. Bu hesaplamalar hidrojen atomlarının hareketini esas almaktadır ve dokularda bulunan su içeriğindeki farklılıklar, hidrojen atomlarının farklı hareketleri, MRI için bir temel oluşturmaktadır. Bu çalışmaların

ardında Lauterbur ve Mansfield aynı alanda beraber çalışmaya başlamışlardır ve 2003 yılındaki Fizyoloji veya Tıp Ödülü'nü birlikte kazanmıştır.

MRI'nın isminde bulunan manyetik, manyetik alanların kullanıldığına atıfta bulunurken rezonans, salınan bir manyetik alanın frekansının bir doku molekülündeki çekirdeğin dönüşünün öncelikli frekansı ile eşlemesini ifade etmektedir (Brown ve diğ., 2014). Burada çekirdeğin dönüşünün iyi huylu rolüne nükleer bileşen olarak atıf yapılabilmektedir. Bu sebeple MRI yerine Nükleer Manyetik Rezonans Görüntüleme (Nuclear Magnetic Resonance Imaging) (NMRI) olarak anılması daha doğru olacakken nükleer kelimesine karşı olan önyargıdan dolayı MRI olarak benimsenmiştir.

2.2.2 Dijital Görüntü İşleme

Dijital görüntü, sonlu ve iki boyutlu $f(x, y)$ fonksiyonu olarak tanımlanmaktadır (Gonzalez ve Woods, 2008). Fonksiyonun herhangi bir koordinattaki büyüklüğü görüntünün aynı noktadaki gri renginin yoğunluğunu göstermektedir. Bahsi geçen koordinat ise piksel veya nokta olarak isimlendirilmektedir. f fonksiyonunun çıktıları dijital bir ortamda iki boyutlu bir dizi yani matrisler ile temsil edilmektedir. Dijital görüntünün tek bir formatı bulunmamaktadır (Haqq, 2016). Nokta başına düşen örnek sayısına ya da içerdiği renklere göre farklı dijital görüntü formatları bulunmaktadır. İkili, gri tonlamalı, Kırmızı Yeşil Mavi (Red Green Blue) (RGB) dijital görüntüler yaygın olarak kullanılan formatlar arasındadır. İkili ve gri tonlamalı görüntüler nokta başına bir örnek içermektedir. Bir RGB görüntüde nokta başına üç örnek bulunmaktadır. Gri tonlamalı ve RGB dijital görüntünün matris temsili Şekil 2.4'te verilmiştir.



Şekil 2.4 Gri Tonlamalı ve RGB Görüntülerin Matris Temsili

Dijital görüntü işleme, dijital görüntülerin bilgisayarlar yardımı ile işlenmesine atıfta bulunmaktadır (Gonzalez ve Woods, 2008). Dijital görüntü işleme insan görü sistemini temel alsa da, görüntüleme makineleri elektromanyetik spektrumun hemen hemen tamamını algılamaktadır. Bu durum ultrason gibi farklı kaynaklarca oluşturulan görüntülerin makineler tarafından algılanmasını sağlamakta ve bu sayede dijital görüntü

işlemenin pek çok uygulama alanı bulunmaktadır. Astronomik gözlemler, PET gibi nükleer ilaçlar, anjiyografi, röntgen, florasan mikroskop, lazerler, endüstri de sıkça kullanılan kızılötesi bantlar, radarlar, MRI gibi görüntüleme teknikleri bahsi geçen uygulama alanları arasındadır.

Dijital görüntü işleme, genel olarak düşük, orta ve yüksek seviyeli olmak üzere üç kategoride incelenmektedir. Bu paradigma aralarında net bir çizgi bulundurmeyen bilgisayarla görü ve dijital görüntü işlemenin hangi noktada birleştiğini göstermek adına Gonzalez ve Woods (2008) tarafından kullanışlı olarak tanımlanmıştır. Düşük seviyeli dijital görüntü işleme; görüntü keskinleştirme, gürültü azaltma gibi temel uygulamaları içermekte ve bu seviyede bir işlemin girdisi de çıktısı da görüntü olmaktadır. Orta seviyeli görüntü işleme; bir görüntüyü bilgisayar ile işlemeye uygun hale getirme, görüntüdeki objelerin segmente edilmesi olarak örneklenebilmektedir. Bu durumda orta seviyeli bir görüntü işleme görevinde girdi görüntü iken çıktı görüntülerden çıkarılan öznitelikler olmaktadır. Üçüncü ve son kategori olan yüksek seviyeli görüntü işleme ise dijital görüntü işleme ile bilgisayarla görünün birleştiği görüntüyü anlamayı içermektedir. Girdi olarak öznitelik almakta ve çıktı olarak bir algıyı takip eden işlevleri yerine getirmektedir. Nesne takibi, otonom araçlar bahsi geçen seviye için örnek olabilecek çalışmalardır. Özetle dijital görüntü işleme görevlerinde girdi ve çıktılar görevin seviyesine göre değişmektedir.

2.3 Makine Öğrenmesi (Machine Learning) (ML)

Yapay zeka çalışma alanının ilk örneklerinde akıllı uygulamaların hemen hepsi *if-else* koşul yapıları ile kodlanmaktaydı (A. C. Müller ve Guido, 2016). Manuel olan bu yöntem ile akıllı uygulamanın kurallarını hazırlamak kuralların göreve özgü olması, insan faktörü büyük bir role sahip olduğu için zaman maliyetinin, hata payının artması ve nesnelliğin azalması anlamına gelmekteydi. Hızlı, insan iş gücüne göre oldukça uygun ve duygu barındırmadığı için objektif olan makine öğrenmesi, terim olarak ilk kez 1959'da araştırmacı Arthur Samuel'in dama oyunu ile ilgili olan araştırmasıyla dünyaya tanıtılmıştır (Mitchell ve Mitchell, 1997). Günümüzde hayatın her alanında sıkça kullanılan ve yüz tanıma gibi geleneksel programlama ile çözülemeyecek görevleri olan ML, geçmişte toplanmış ve analiz edilmeye uygun verilerden elde ettiği deneyimler ile doğru tahminde bulunmak ya da başarıyı arttırmak için kullanılan hesaplama yöntemlerinin tümü olarak tanımlanmaktadır (Mohri ve diğ., 2018). Bahsi geçen veriler sisteme girdi olarak verilmektedir. Veriler, insanlar tarafından hazırlanmış etiketli veri setleri olabileceği gibi sistemin çevreden elde ettiği farklı formatta veriler de olabilmektedir. Aynı zamanda bu alan; kullanılan verilerin kalitesi, analizi ve miktar olarak çokluğuyla sistemin başarısı doğrudan alakalı olduğu için istatistik, bilgisayar ve yapay zekanın ortak çalışma koludur

(A. C. Müller ve Guido, 2016) ve literatürde istatistiksel öğrenme olarakta geçmektedir. ML çalışma alanında sıklıkla kullanılan temel terimler ve onlara ait tanımlar Çizelge 2.1’de verilmiştir.

Çizelge 2.1 Temel ML Terimleri (Mohri ve diğ., 2018)

Terim	Tanım
Veri Seti	Sistemin eğitimi ve değerlendirilmesi için kullanılan veri örnekleri
Öznitelik	Genellikle vektör olarak temsil edilen ve bir örneğe ait olan özelliklerin hepsi
Etkiket	Verilere tayin edilen sınıf değerleri ya da kategorileri
Hiperparametre	Kullanıcı tarafından belirlenen ve çoğunlukla sisteme girdi olarak verilen parametreler
Eğitim Seti	Bir makine öğrenmesi algoritmasının eğitim sırasında kullandığı örneklerin tümü
Doğrulama Seti	Sistem etiketli veriler ile çalışırken hiperparametrelerin değerlerini güncellemek için kullanılan set
Test Seti	Sistemin performansının değerlendirilmesi için eğitim verilerden ayrı olan ve sistemin ilk defa göreceği örnekleri içeren set
Kayıp Fonksiyonu	Sistem tarafından yapılan tahmin ile gerçek etiket arasındaki fark
Aşırı Öğrenme	Eğitim verilerinin ezberlenecek kadar öğrenilmesi sonucunda düşük eğitim kaybı ancak yüksek test kaybına neden olması
Eksik Öğrenme	Genellikle az hiperparametrelili basit modellerde meydana gelen, verilerdeki püf noktaların kaçırılması sorunu

ML, her biri ayrı bir araştırma kolu olan doğal dil işleme, metin ve belge sınıflandırılması, yüksek seviyeli bilgisayarla görü uygulamaları gibi birçok problemi içermektedir. Bunları çözmek için sınıflandırma, regresyon ve kümeleme gibi görevleri kullanmaktadır (Mohri ve diğ., 2018). ML; verilerin sisteme alınması ve çeşitleri, değerlendirme sistemi vb. yönüyle farklı türlere ayrılmıştır. Bunlardan en yaygın olanları denetimli, denetimsiz, yarı denetimli, çevrimiçi, takviyeli, aktif öğrenmedir. Basitçe denetimli öğrenme etiketli veriler ile çalışmaktadır. Makine, veriler ve onların sınıf etiketleri ile bir eğitim süreci tamamlamaktadır. Sonrasında hiç görmediği veriler hakkında tahminde bulunmaktadır. Müller ve Guido (2016) tarafından en başarılı sonuçları veren tür olarak tanımlanmıştır. Sıklıkla sınıflandırma ve regresyon görevlerini gerçekleştirmek için kullanılmaktadır (Mohri ve diğ., 2018). Denetimsiz öğrenme eğitim için etiketlenmemiş

veriyi kullanmaktadır. Etiketli veri kullanmaması somut olarak ölçümleme yapılmasını güçleştirmektedir. Kümeleme ve boyut azaltma görevlerinde bu yöntem kullanılmaktadır. Yarı denetimli öğrenme girdi olarak hem etiketli hem de etiketsiz verilerden oluşan bir set almaktadır. Temelde yarı denetimli bir ML sistemi etiketli olan verileri kullanarak kalan verilere belirlenen güven değerine göre etiket vermektedir. Genellikle sınıflandırma ve regresyon görevleri için kullanılmaktadır. Çevrimiçi öğrenme, eğitim ve test adımlarını karıştıran turlardan oluşmaktadır. Her turun sonunda test setinden birkaç veri alınmakta ve bu verilerin kayıpları hesaplanmaktadır. Böyle bir sistemin amacı kümülatif kaybı minimize etmektir. Çevrimiçi öğrenmeye benzer olarak takviyeli öğrenme de eğitim ve test adımlarını bir arada yürütmektedir. Ancak takviyeli öğrenme farklı olarak sistemin doğru davranışlarını ödüllendirip yanlış davranışlarını cezalandırmaktadır. Ek olarak sistem çevre ile iletişim kurabilmektedir. Belli adımdan sonra sistem cezadan kaçma ve ödüle yönelme eğilimi göstermektedir. Bu tür, Pavlov'un da savunduğu davranışçılık olarak bilinen psikolojik kuramdan esinlenerek ortaya çıkmıştır (Otterlo ve Wiering, 2012). Son olarak aktif öğrenme veri miktarının etiketlenemeyecek kadar çok (Solaguren-Beascoa, 2020) ya da etiketlemenin çok masraflı olduğu durumlarda, veriler arasından belirleyiciliği fazla olanların seçilmesi ve sistemin seçilen noktalara etkiket talep etmesini esas almaktadır (Mohri ve diğ., 2018). Böyle bir durum başarılı bir sonuç için pasif öğrenme olarakta anılan denetimli öğrenmeye göre çok daha az etiketli veri gerektirmektedir.


Esas olarak sistemin öğrenmesi için ilk aşama veri setinin eğitim, test ve doğrulama olarak rastgele ayrılmasıdır. Genel olarak eğitim seti miktarı tüm veri setinin fazlasını kapsamaktadır. Kullanışlı öznitelikler ile çalışmak ML algoritmalarının başarılı sonuçlar elde etmesi için elzemdir. Bu sebeple diğer adım kullanışlı özniteliklerin seçilip, gürültü olarak ifade edilebilecek içerisinde bilgi barındırmayan özniteliklerin elenmesi için öznitelik seçimi adıımıdır. ML algoritmalarında bu adım kullanıcıya bırakılmıştır. Seçilen öznitelikler ve ayarlanan hiperparametreler ile eğitim başlatılmakta ve doğrulama seti içerisinde en iyi sonucu veren eğitim modeli nihai model olmaktadır. Eğitilmiş sistemi değerlendirmek için test seti ve sisteme uygun olarak seçilen kayıp fonksiyonu kullanılmaktadır.

Literatürde tıbbi görüntüleme yöntemlerinden MRI ve ML kullanılarak gerçekleştirilen pekçok çalışma bulunmaktadır. Bu çalışmalardan birinde araştırmacılar, ML algoritmasına girdi olarak verilen MR görüntüleriyle beyin tümörünü metastazlardan ayırt etmeyi ve bu tümörlerin derecelendirilmesini hedeflemişlerdir (Zacharakı ve diğ., 2009). Önerdikleri İlgi Alanı (Region of Interest) (ROI), öznitelik çıkarımı, öznitelik seçimi ve sınıflandırma gibi birkaç adımdan oluşmakta ve kullandıkları veri seti 98 hastaya ait MR görüntülerinden oluşmaktadır. ROI'lerin belirlenmesiyle iki uzman nörolog kontrolünde öznitelik çıkarımı işlemi tamamlanmıştır. Öznitelik çıkarımında yaş ve tümör detaylarını


içeren çok fazla parametre göz önüne alındığı için araştırmacılar ilk olarak öznitelik azaltmak adına iki kuyruklu t testi ve Kısıtlı Doğrusal Ayırma Analizi (Constrained Linear Discriminant Analysis) (CLDA) uygulamıştır. Bahsi geçen iki kuyruklu t testi ile veriler arası korelasyon hesaba katılmadığından gereksiz öznitelikler seçilmektedir. Bu öznitelikleri elemek ve sınıflandırıcı başarısını arttırmak amacıyla araştırmacılar, öznitelik alt kümesi seçimi için Destek Vektör Makinesi (Support Vector Machine) (SVM) tabanlı bir sistem tercih etmiştir. Veriler; SVM, k En Yakın Komşu (k Nearest Neighbors) (k-NN) algoritması ve Doğrusal Ayırma Analizi (Linear Discriminant Analysis) (LDA) ile Fisher'ın diskriminant kuralı olmak üzere üç farklı sınıflandırma metodu kullanılarak sınıflandırılmıştır. Bu metotlardan en yüksek doğruluk değerini %91,20 ile araştırmacıların da beklediği gibi t testi uygulanmış verilerle SVM elde etmiştir. k-NN ve LDA için bu değer sırasıyla %89,8 ve %81,10'dır. CLDA uygulanmış verilerde doğruluk yüzdesi ise SVM, k-NN ve LDA için sırasıyla %90,60, %89,40, %85,20'dir. Verilen sonuçlar, araştırmanın yapıldığı dönemde elde edilmiş en yüksek doğruluk değerlerine tekabül etmektedir.

Başka bir çalışmada araştırmacılar (Moradi ve diğ., 2015) Alzheimer hastalığının erken teşhisinin tahmini için MRI tabanlı bir makine öğrenmesi yöntemi önermişlerdir. Hastalığın erken teşhisi için yaşa bağlı gerileme ile Alzheimer arasında geçiş olan Hafif Bilişsel Bozukluk (Mild Cognitive Impairment) (MCI) aşaması baz alınmıştır. Kullandıkları veri seti Alzheimer Hastalığı Nörogörüntüleme Girişimi (Alzheimer's Disease Neuroimaging Initiative) (ADNI) tarafından sağlanmıştır. Veri setinde bulunan görüntüler içerisindeki heterojenlikler giderilmiş ve normalize edilmiştir. Sınıflandırma için görüntülerdeki gri madde bölümü kullanılacağından bu bölüm beyaz madde ve omurilik sıvısı bölümünden segmente edilip yumuşatma filtresinden geçirilmiştir. Sınıflandırma aşamasında araştırmacılar iki farklı yöntem önermiştir. Bu yöntemlerden ilki MRI biyobelirteç olarak isimlendirilmiştir. Bu yöntem ek olarak beyindeki yaş etkilerinin Alzheimer ile karıştırılmaması için görüntüden yaş etkilerinden temizlenmesi adımı içerir ve temel olarak iki aşamadan oluşmaktadır. Birinci aşama öznitelik seçimidir ki o denetimli öğrenme yöntemi olan düzenli lojistik regresyonu kullanarak MRI voksellerinden iyi öznitelik alt kümesi seçmeyi hedeflemektedir. İkinci aşamada yarı denetimli öğrenme yöntemi olan ve dönüştürücü SVM'lere dayanan Düşük Yoğunluklu Ayırma (Low Density Separation) (LDS), İlerici Hafif Bilişsel Bozukluk (Progressive Mild Cognitive Impairment) (pMCI) ve Stabil Hafif Bilişsel Bozukluk (Stable Mild Cognitive Impairment) (sMCI) sınıflandırması için kullanılmıştır. Sistem eğitim esnasında etiketlenmemiş Bilinmeyen Hafif Bilişsel Bozukluk (Unknown Mild Cognitive Impairment) (uMCI) görüntüleri ile de beslenmiştir. Eğitim sonucunu değerlendirmek için araştırmacılar ROC Eğrisi Altında Kalan Alan (Area under the ROC Curve) (AUC) kullanmışlardır. LDS için %76,61'lik bir AUC elde ederek literatürdeki oranları yükseltmiştir. AUC hesaplanmasında kullanılan ROC, İşlem Karakteristikleri Eğrisi (Receiver Operating Characteristic)ni ifade

etmektedir. İkinci yöntem olan toplu biyobelirteçin öz nitelikleri için LDS sınıflandırıcılı MRI biyobelirteç kullanılmış ve bunlar orijinal verilerin farklı alt kümeleri ile eğitilmiş karar ağaçlarından oluşan Rastgele Orman (Random Forest) (RF) sınıflandırıcısına girdi olarak verilmiştir. Araştırmacılar bu sistem ile %90,20'lik bir AUC elde ederek kendi sonuçlarını geliştirmişler ve her iki sistemde de 10 kat çapraz doğrulama kullanılmıştır. Bahsedilen iki sistemin akış diyagramları Şekil 2.5'da verilmiştir.



(a) MRI Biyoışaretçi Akış Diyagramı




(b) Toplu Biyoışaretçi Akış Diyagramı

Şekil 2.5 Önerilen Sistemlerin Akış Diyagramı (Moradi ve diğ., 2015)

2.4 Derin Öğrenme


Yapay zeka, ML ve derin öğrenme terimleri birbirleri ile sıkça karıştırılan ve esasında birbirleriyle iç içe bulunan bilgisayar bilimi alanlarıdır. 1950’lerde makineler de insanlar gibi düşünebilir mi sorusu ile ortaya çıkan yapay zeka, Şekil 2.6’de görüldüğü üzere ML ve derin öğrenmeyi içine almaktadır (Chollet, 2018). Derin öğrenme, ML’in özel bir çalışma alanıdır ve bu iki çalışma alanını birbirinden ayıran nokta ise öğrenebildikleri temsil katmanlarıdır. Bu katmanlar veri dönüşümlerini ifade etmekte ve bu dönüşümlerin veri setinden örnekler uygulanmasıyla öğrenme gerçekleşmektedir. Bir ML modeli, bu katmanlardan bir ya da iki adet öğrenebilirken bir derin öğrenme sistemi içerdiği katman kadar derin olmaktadır. Derin öğrenme, bahsedilen katman temsillerini birbiri üstüne eklenmiş sinir ağları adı verilen yapılar ile öğrenmektedir. Yani bir derin öğrenme ağının, bilginin sıralı filtrelerden geçtiği bir damıtma işlemine benzetilmesi olasıdır.



Şekil 2.6 Yapay Zeka, ML ve Derin Öğrenme İlişkisi (Chollet, 2018)

Bir derin öğrenme katmanı, veri dönüşümlerini gerçekleştirmek için ağırlıklarını kullanmaktadır. Ağırlıklara katmanın parametreleri demek mümkündür. Verilen ağırlıkları kullanarak örnekler üzerinden tahmin sağlayan sistemi kontrol etmek için beklenen sonuç ile çıktı arasındaki uzaklık ölçülmelidir. Bu ise Çizelge 2.1’de bahsedilmiş olan kayıp ya da diğer bir ismi ile amaç fonksiyonunun görevidir. Kayıp fonksiyonunun çıktısı ağırlıkların istenen yöne doğru güncellenmesi için kullanılmaktadır. Bu ise derin öğrenmenin temel hilesi olarak tanımlanan geri yayılım algoritmasıdır ki bu optimizasyon fonksiyonu ile yapılmaktadır. Bahsedilen basit bir derin ağın çalışma ve öğrenme mantığı Şekil 2.7’de akış diyagramı olarak verilmiştir. Eğitim yeni başlatıldığında ağırlıklar rastgele belirlenebileceği gibi eğitilmiş başka bir modelin ağırlıkları da yeni sisteme girdi olarak verilebilmektedir.

Bu yüzden eğitim verileri ile ağırlıklar başlangıçta uyum sağlamayabilmekte, bu da kayıp fonksiyonunun yüksek olmasına neden olmaktadır. Optimizasyon fonksiyonu, kayıp fonksiyonu değerini kullanarak ağırlıkları güncelledikçe kayıp fonksiyonunun değeri düşmektedir. Temelde bir eğitim döngüsü kayıp fonksiyonunu düşürmek için ağırlıkların güncellenmesini içermektedir. Çünkü minimize edilmiş kayıp, eğitilmiş ağırlıkların beklenen sonuçlara mümkün olduğu kadar yaklaşması anlamına gelmektedir.



Şekil 2.7 Temel Derin Öğrenme Adımları (Chollet, 2018)

1989'da LeNet ile ilk başarılı uygulaması gerçekleştirilen derin öğrenme, Evrimsel Sinir Ağları (Convolutional Neural Network) (CNN) geri besleme algoritmasının fikri temellerinin bu çalışma ile atılmasına karşın 2011 yılına kadar ML'nin gerisinde kalmıştır. 2011 yılında ise Grafik İşlemci Birimi (Graphics Processing Unit) (GPU) ile eğitilmiş görüntü sınıflandırma yarışmaları sonuç vermeye başlamış ve 2012 yılında ImageNet görüntü sınıflandırma yarışmaları derin öğrenmenin dönüm noktası olmuştur. Diğer alanlara göre problemlere hızlı yanıt vermesi, ML'de insan tarafından yapılan öznel çıkarma adımını otomatikleştirmesi vb. özellikleri ile öne çıkan bu alan donanım araçlarının gelişmesi, internet sayesinde veriye olan erişimin kolaylaşması ile ivmeli bir yükselişe

geçmiştir. Bugün derin öğrenme farklı ağ mimarilerini içermekte ve bunlara bağlı olarak geniş bir çalışma alanını kapsamaktadır. CNN, Tam Evrişimsel Ağ (Fully Convolutaional Network) (FCN), Uzun Kısa Süreli Bellek (Long Short Term Memory) (LSTM), Tekrarlayan Sinir Ağları (Recurrent Neural Network) (RNN), Çekişmeli Üretici Ağ (Generative Adversarial Networks) (GAN), Derin İnanç Ağları (Deep Belief Network) (DBN) bilinen ve sıklıkla kullanılan derin öğrenme algoritmalarıdır (Biswal, 2022). Bu algoritmalar, hiçbir zaman başarıyı garantilemese de bazıları, belirli çalışmalar için daha uygundur. Örnek olarak CNN'ler tıbbi görüntü işleme, uydu görüntüsü tanımak, anomali tespiti için sıklıkla kullanılmaktadır. LSTM'ler genellikle konuşma tanıma, zaman serisi tahmini gibi görevler ile kullanılmaktadır. RNN'ler resim yazısı, el yazısı tanıma ve doğal dil işleme vb. görevleri yerine getirmek için tercih edilmektedir. GAN'lar ise astronomik görüntüleri geliştirmek, çizgi film karakteri ve insan yüzü oluşturmak için giderek artan şekilde yaygınlaşmaktadır. Çalışma kapsamında tıbbi görüntü segmentasyonu için Bölüm 3.3'te bahsedilecek dört farklı CNN mimarisi kullanılmıştır.


2.5 Evrişimsel Sinir Ağları (Convolutional Neural Networks) (CNN)

CNN ile geleneksel yapay sinir ağları arasındaki en önemli fark CNN'nin evrişim katmanında örüntü tanıma alanı bulundurmasıdır (O'Shea ve Nash, 2015). Bu alan, ağı görüntü odaklı görevlere uyumlu hale getirmeye ve model parametrelerini azaltmaya yaramaktadır. Bu sayede geleneksel yapay sinir ağlarının en büyük problemlerinden olan görüntülerin işlenmesi ve beraberinde gelen yüksek hesaplama maliyeti problemi çözmektedir (Chollet, 2018). CNN genellikle evrişim, havuzlama ve dense olarak da bilinen tam bağlantılı katman olmak üzere üç tip katman bulundurmaktadır. Evrişim katmanları, CNN'nin temelini oluşturduğu için mimaride önemli bir yere sahiptir. Evrişim katmanı girdiyi kenar, doku gibi yerel özniteliklere bölmekte ve bunları öğrenebilmektedir. Öğrenilen özniteliklerin tıpkı gerçek dünyada olduğu gibi çevrilmiş ya da döndürülmüş görüntülerde de tanınabilmesi ve bu katmanların hiyerarşiye uygun çalışması nispeten daha az eğitim seti ile daha çok öğrenmeyi sağlamaktadır. Örnek olarak ilk evrişim katmanı kenar özniteliklerini öğrenirken sonraki evrişim katmanı bir öncekinin özniteliklerinden oluşan daha büyük örüntüleri öğrenmektedir. Evrişim katmanları; genişlik, yükseklik, derinlik ya da kanal eksenini olarak adlandırılan eksenlere sahip Üç Boyutlu (Tree Dimensional) (3D) tensörlerle çalışmaktadır. Bu 3D tensörler öznitelik haritası şeklinde isimlendirilmektedir. Öznitelik haritası aynı zamanda katmanların çıktısı ya da girdinin üzerinde gezen katman filtrelerinin sonuçları olan özniteliklere karşılık gelmektedir. Öznitelikler tepki haritası şeklinde de anılmaktadır.


Evrişim işlemi iki farklı parametre ile tanımlanmaktadır: Girdilerden çıkarılan yamaların boyutu, Katman çıktısı olan öznitelik haritasının derinliği. Girdilerden elde edilen yamaların boyutu yaygın olarak 3×3 olarak seçilmektedir. Öznitelik haritasının derinliği ise evrişim tarafından hesaplanan filtre sayısına karşılık gelmektedir. Derinlik ekseninin her boyutu girdinin bir tepki haritasına karşılık gelmektedir. Bir evrişim, boyutu parametre olarak verilen pencereleri girdi üzerinde varolan her noktayı dolaşacak şekilde kaydırarak yamaları elde etmektedir. Yamalar, aynı öğrenilmiş ağırlıklara sahip olan ve evrişim çekirdeği adı verilen matris ile nokta çarpımı işlemine sokulmaktadır. Bu sayede parametre olarak verilen çıktı derinliğine bir vektör olarak ulaşılmaktadır. Tüm yamalar için bu işlem tekrar edildikten sonra elde edilen tüm vektörler yükseklik, genişlik, çıktı derinliği eksenlerini içerecek şekilde birleştirilmektedir. Elde edilmiş çıktı öznitelik haritasındaki her konum giriş öznitelik haritasında aynı konuma karşılık gelen nokta ile ilgili bilgi içermektedir. Özetle evrişimin işleyişi Şekil 2.8’de verilmiştir.

Şekil 2.8’de görüldüğü gibi girdi ile evrişim işleminin çıktısı eşit yükseklik ve genişlik değerlerine sahip değildir. Buna kaydırma adımı ya da piksel ekleme yol açabilmektedir. Girdi öznitelik haritası ile çıktı öznitelik haritasının aynı boyutta olması için piksel ekleme kullanılmaktadır. Örneğin, Şekil 2.9a’da görüldüğü gibi 5×5 boyutlu bir girdi üzerinde 3×3 boyutlu bir pencere gezdirildiğinde çıktı olarak 3×3 boyutlu bir öznitelik haritası alınmakta ve boyut kaybı yaşanmaktadır. Ancak Şekil 2.9b’de görüldüğü gibi girdi öznitelik haritasının çevresine bir sıra piksel eklenirse çıktı öznitelik haritası her karoyu ortalamakta ve 25 adet yama elde edilmektedir. Kaydırma adımı ise çıktı öznitelik haritasını direkt olarak etkileyen bir parametredir. Girdi öznitelik haritasında dolaşacak pencerenin adım büyüklüğünü ifade etmektedir. Kaydırma adımının birden büyük olması altörnekleme olarak da isimlendirilen boyut azaltma anlamına gelmekte ve nadiren kullanılmaktadır. CNN’ler bunun yerine havuzlama katmanı kullanmaktadır.


Öznitelik haritası evrişim katmanından geçtikçe boyutu büyümektedir. Bu öğrenilmesi gereken parametre sayısının artması anlamına gelmekte ve aşırı öğrenme, hesaplama karmaşıklığı gibi problemlere sebep olmaktadır. CNN’ler bahsedilen problemlerden kaçınmak için havuzlama katmanı kullanılarak altörnekleme yani boyut azaltma adımı bulundurmaktadır. Bu sayede öğrenilmesi gereken parametre sayısı azalırken aynı zamanda ardışık evrişim katmanları orijinal görüntüye giderek büyüyen bir pencere ile bakabilmektedir. Havuzlama katmanı; ortalama havuzlama katmanı, global havuzlama katmanı vd. farklı dallara ayrılabilir da genellikle maksimum havuzlama katmanı tercih edilmektedir. Çünkü seçilen boyuta göre öznitelik haritasında dolaşan pencerenin en baskın özelliği seçmesi diğerlerine göre daha bilgilendirici altörnekleme yapılmasını sağlamaktadır. Kaydırma adımı kullanılmayan evrişim katmanlarından sonra maksimum



Şekil 2.8 Evrişimin İşleyişi (Chollet, 2018)




(a) Piksel Ekleme Olmadan Elde Edilen Yamalar



(b) Piksel Ekleme ile Elde Edilen Yamalar

Şekil 2.9 Piksel Ekleme Örnek (Chollet, 2018)

havuzlama katmanının parametreleri genellikle Şekil 2.10'de temsili verildiği gibi pencere boyutu 2×2 ve kaydırma adımı iki olacak şekilde ayarlanmaktadır.



Şekil 2.10 Maksimum Havuzlama Katmanı Temsili (Rana, 2020)

Tam bağlantılı katman ise modelin sonunda bulunmaktadır. Genellikle havuzlama katmanından sonra gelmekte ve bir önceki katmandaki tüm nöronların sonraki katmandakilere bağlı olduğu bir sinir ağı olarak tanımlanmaktadır (Dumane, 2020). Girdiye ait global özniteliklerin kullanıldığı bu katman, öznitelik haritasını vektöre çevirmekte ve nöronlarını bu vektör ile besleyip girdiyi sınıflandırmaktadır. Bunun için son katman çıktısına bakılmaktadır. Katmandaki her nöron bir sınıfa tekabül etmektedir. Bu katmanda sınıf sayısına göre Sigmoid ya da Softmax aktivasyon fonksiyonlarından uygun olanı

kullanılmaktadır. Katmanın verdiği sınıf puanı kullanılarak seçilen kayıp fonksiyonuyla geri yayılım değeri hesaplanmaktadır.

Aktivasyon fonksiyonları, veriye lineer olmayan bir dönüşüm uygulayıp lineer olarak ayırmayı hedeflemektedir (Baeldung, 2022). Evrişim katmanlarından ve tam bağlantılı katmanların çoğundan sonra işlem maliyeti düşük ve verimli olduğu için Rektifiye Lineer Birim (Rectified Linear Units) (ReLu) adı verilen aktivasyon fonksiyonu kullanılmaktadır. Ek olarak birçok CNN mimarisi evrişim, havuzlama ve tam bağlantılı katman dışında aşırı öğrenmeyi engellemek, eğitim başarısını yükseltmek ve hesaplama maliyetini düşürmek için dropout katmanını bünyesinde barındırmaktadır. Bunu parametre olarak aldığı 0-1 arasındaki ondalıklı değere göre modeldeki bazı nöronları atarak sağlamaktadır (Dumane, 2020). Derin öğrenme yöntemlerinde dropout katmanı sıklıkla kullanılmaktadır (Chollet, 2018).

2.6 Medikal Görüntü Segmentasyonu

Segmentasyon, görüntünün kendini oluşturan objelere bölünmesidir. Otonom segmentasyon, literatürde dijital görüntü işlemenin en zor başlıklarından biri olarak görülmektedir (Gonzalez ve Woods, 2008). Görüntünün, segmente edilmesinin tamamlanabilmesi için beş adet şart bulunmaktadır. Bunlar her pikselin bir bölgeye ait olması, bir bölgenin içerdiği her noktanın önceden tanımlanmış bir algı ya da anlama bağlanması, her bölgenin birbirinden ayrık olması, bir bölgenin içine aldığı noktaların aynı yoğunluk seviyesinde olmaları gibi ortak bir özelliğe sahip olmaları ve son olarak her bölgenin temsil ettiği algının ya da anlamın birbirinden farklı olmasıdır. Her görüntünün farklı yapısı ve içeriği olması sebebiyle pek çok segmentasyon tekniği bulunmaktadır. Bu teknikler temel olarak bölge bazlı, eşik, kenar, kümeleme, yapay sinir ağları tabanlı teknikler şeklinde ayrılmaktadır.

Yapay sinir ağları tabanlı teknikler önemli performans iyileştirmeleri sağlamıştır (Klingler, 2022). Renkli görüntüler için yapay sinir ağları tabanlı teknikler semantik ve birey segmentasyon yöntemlerini esas almaktadır. Semantik segmentasyonda her piksel bir sınıf etiketi ile eşleşmektedir (Karayegen, 2021). Bu aynı sınıfa ait farklı nesnelerin tek bir nesne olarak algılanması anlamına gelmektedir. Örnek segmentasyonunda ise aynı sınıfa ait nesneler farklı bireyler olarak değerlendirilmektedir (Hassan, 2022). Aynı sınıfa ait farklı bireyleri belli etmek için her bireye farklı renk uygulanmakta ve piksel çakışmalarına izin verilmektedir. Ek olarak bu yöntem sınırlayıcı kutuları da içermektedir. Özetle semantik segmentasyon anlamsal etiketler ile çalışmaktayken örnek segmentasyonu ise bireysel nesnelerin bölümlere ayrılmasına dayanmaktadır (Klingler, 2022). Bir görüntüde üç adet kuzu varsa semantik segmentasyon bunları tek nesne gibi algılanmakta ve nesne adedini

sayamamaktadır. Diğer yandan örnek segmentasyonu için her kuzu birey olarak değerlendirilmekte ve ayrı ayrı segmente edilmektedir. Örnek segmentasyonu ile semantik segmentasyon arasındaki bahsedilen fark Şekil 2.11’de verilmiştir.



(a) Semantik Segmentasyon




(b) Örnek Segmentasyonu

Şekil 2.11 Semantik ve Örnek Segmentasyon Farkı (SuperAnnotate, 2021)

2.7 Benzer Çalışmalar

Medikal görüntü segmentasyonu derin öğrenme, sağlık ve yüksek seviyeli dijital görüntü işlemenin kesiştiği noktada bulunmaktadır ve günden güne artan bir popüleriteye sahiptir. Bu alan MRI, CT, röntgen vb. tıbbi görüntüleme cihazları aracılığıyla elde edilen görüntülerin temel olarak hastalıklı doku ve sağlıklı dokuyu ayıracak şekilde bölütlenmesini içermektedir. Literatürde bir çalışmada akciğer tümörünün otomatik segmente edilmesiyle tümörün geometrik değişikliklerini daha rahat analiz etmek amaçlanmıştır (C. Wang ve diğ., 2019). Araştırmacılar bunun için dokuz akciğer kanseri hastasının altı haftalık MR görüntülerini takip etmişlerdir ve hastaya özel uyarlanabilen Uyarlanabilir CNN’yi (A-net) önermişlerdir. Görüntüler arka plan ve tümör olacak şekilde manuel olarak etiketlenmiştir. Önerilen sistem yama bazlı çalışmaktadır ve yamalar arası yoğunluk değişimlerini engellemek için tüm yamalar normalize edilmiştir. Evrişim ve havuzlama katmanında kaydırma adımı için sırasıyla 2 ve 1 değerlerinin ayarlanması ve tam bağlantılı katmandan sonra ReLu yerine Dropout katmanının olması A-net’i diğer mimarilerden ayırmaktadır. Sistemin değerlendirilmesi için hassasiyet, Dice benzerlik katsayısı, Kök Ortalama Kare Yüzey Mesafesi (Root Mean Square Deviation) (RMSD) metrikleri kullanılmış ve her hafta gelen yeni veriler ile eğitim sonuçları güncellenmiştir. En yüksek sonuçlar ikinci hafta gelen verilerden elde edilmiştir. Bu değerler verilen metrikler için sırasıyla $0,80(\pm 0,15)$, $0,84(\pm 0,10)$ ve $1,90(\pm 0,6)$ ’dur.

Başka bir çalışmada araştırmacılar medikal görüntü segmentasyonunu otomatikleştiren ve açık kaynak olarak paylaştıkları bir veri hattı önermişlerdir (D. Müller ve Kramer, 2021). Evrişimsel Sinir Ağları ile Medikal Görüntü Segmentasyonu (Medical Image Segmentation with Convolutional Neural Networks) (MIScnn) olarak isimlendirilen bu veri hattı Şekil 2.12’te de verildiği gibi iki veya üç boyutlu veri girişi, veri ön işleme, veri arttırma, model seçimi seçenekleri sunmakta ve eğitim adımlarını otomatikleştirmektedir. Sistem ikili segmentasyona uygun olduğu gibi çok sınıflı da çalışabilmektedir. İkili sınıflandırma problemlerinde kullanılan tek sıcak kodlama (One Hot Encoding) MIScnn’de ikili segmentasyon ile beraber çoklu sınıflara da otomatik olarak uygulanabilmektedir. Diğer veri hatlarından farklı olarak MIScnn, tanımlanan mimariler dışında özel mimarilerin eklenmesine ve GPU kullanımına izin vermektedir. Veri hattı 300 adet CT görüntüsü bulunduran Böbrek Tümör Segmentasyonu (Kidney Tumor Segmentation) (KiTS) 2019 veri seti kullanılarak değerlendirilmiştir. Veri seti arka plan, böbrek ve tümör olmak üzere üç kategoriden oluşmuştur. CT görüntülerinden 120 tanesi değerlendirme seti olarak kullanılmıştır. Mimari olarak standart 3D UNet tercih edilmiştir. Sonuçlar için Dice benzerlik katsayısı metrikleri ile beraber kategorik çapraz doğrulama, Tversky kaybı metrikleri kullanılmıştır. Sınıf bazında Dice benzerlik katsayısı kullanılarak arka plan, böbrek ve tümör için sırasıyla %99,94, %93,19, %67,50 değerleri elde edilmiştir.




Şekil 2.12 MIScnn Veri Hattı Akış Şeması (D. Müller ve Kramer, 2021)

Diğer bir çalışmada araştırmacılar çoklu akış çerçevesi ve uyarlanabilir modalite tekrar kalibrasyon modülü şeklinde iki ana parçadan oluşan AMRSeg-Net isimli bir ağ önermişlerdir (J. Li, H. Chen, Y. Li, Peng, Cai ve diğ., 2021). Bu ağ ile çoklu model akciğer

MR görüntülerindeki tümörleri segmente etmek amaçlanmıştır. Önerilen ağ Şekil 2.13'te görüldüğü gibi U-Net'i temel almış, çoklu model görüntü segmentasyonu sağlayan bir ağ olan IVD-Net'ten esinlenerek tasarlanmıştır. AMRSeg-Net'i esinlendiği ağdan ayıran iki temel farklılık bulunmaktadır. Bunlardan ilki gradyan yayılımını ve çok modlu öznetelik çıkarımını basitleştirmektir. Diğerisi ise IVD-Net'te öznetelik birleştirmeden sonra yürütülen evrişim kaldırılarak kodlanmış çoklu akış öznetelik haritaları birleştirilmektedir. İki farklı tip MR görüntüsünden alınan farklı bilgileri kullanarak tümör segmentasyonu amaçlayan ağ, içerisinde öznetelikleri tanımlamak için kanal bazlı değil modalite bazlı bir tanımlayıcı olan ResSe bloğunu kullanmaktadır. Araştırmacılar veri setini Guangzhou Medikal Üniversitesi First Affiliated Hastanesi'nden toplamışlardır. Veri setinde toplamda 71 hastaya ait 364 tarama dilimi bulunmaktadır. Görüntüler T2 ağırlıklı ve difüzyon ağırlıklı MR görüntülerinden oluşmaktadır. AMRSeg-Net veri seti ile beslenmeden önce veri seti üzerinde sekiz defa rastgele döndürme ve kaydırma işlemlerini içeren veri çoğaltma uygulanmıştır. Ağı değerlendirmek için ResSe bloğu aracılığıyla kalibre edilmeyen AMRSeg-Net, kanal bazında kalibre için kullanılan ResSe bloğu ve AMRSeg-Net, modalite bazında kalibre için kullanılan ResSe bloğu ve AMRSeg-Net'e ek olarak aynı veri seti ile HyperDenseNet ve U-Net tabanlı çoklu model segmentasyon ağı da eğitilmiştir. Eğitim sonuçlarını değerlendirmek için Dice benzerlik katsayısı, hassasiyet ve Hausdorff mesafesi kullanılmıştır. En başarılı sonuç modalite bazında kalibre için tüm katmanlara uygulanan ResSe bloğu ve AMRSeg-Net ile elde edilmiştir ve metriklere göre elde edilen değerler sırasıyla şu şekildedir: 0,84($\pm 0,11$), 0,91, 16, 27. Araştırmacılar önerdikleri model ile son teknoloji modellerin başarısını Dice benzerlik katsayısı ile %20 oranında iyileştirmişler ve modalite tabanlı tanımlayıcısı olan bir modele yeniden kalibre modülünü ekleyerek parametre sayısını önemli ölçüde azaltmışlardır.

Akciğer kanserinin daha gerçekçi incelenebilmesi için fareler üzerinde kanser tespitinin geliştirilmesi gerektiğini savunan araştırmacılar, farenin tüm vücut Koni Işınlı Bilgisayarlı Tomografi (Cone Beam Computed Tomography) (CBCT) taramalarında tümörü segmente etmeyi hedeflemişlerdir (Worp ve diğ., 2021). 10 haftalık 60 erkek fareden elde edilen 3D CBCT görüntüleri uzmanlar eşliğinde etiketlenerek veri seti olarak kullanılmıştır. Görüntüler, yeniden boyutlandırmanın sonrasında kırpma ve rotasyon uygulanarak çoğaltılmıştır. Araştırmacılar, verileri eğitmek için iki adımlı 3D U-Net önermişlerdir. Her iki adım benzer şekilde üç kodlayıcı ve üç kod çözücü katman içermektedir. Veri seti, dört kat çapraz doğrulama ile her biri 15 adet görüntü içermekte olan dört farklı sete bölünmüştür. Bu setler üçü eğitim biri test seti olacak şekilde ayrıldıktan sonra her setin bir kez test verisi olarak kullanılmasıyla eğitim tamamlanmıştır. Her test seti, Dice benzerlik katsayısı ve Hausdorff Mesafesi kullanılarak değerlendirilmiş ve sırasıyla ortalama olarak 0,80 $\pm$ 0,10 ve 0,74 $\pm$ 0,48 mm değerleri elde edilmiştir.




Şekil 2.13 AMRSeg-Net Mimarisi (J. Li, H. Chen, Y. Li, Peng, Cai ve diğ., 2021)

Araştırmacılar, otomatik segmentasyon için başarılı sonuçlar elde etmekle beraber insan etiketlemesine kıyasla 69 kat daha hızlı bir sistem önermişlerdir.

Bir başka çalışmada araştırmacılar Mask R-CNN kullanarak MR görüntülerini segmente etmişlerdir (Padma ve diğ., 2022). Kullandıkları veri seti içinde ön işlemden geçmiş ve gri seviyeli toplam 300 beyin MR görüntüsü bulunmaktadır. Mask R-CNN mimarisinde sınıflandırıcı olarak Artık Ağ (Residual Network) (ResNet) tercih edilmiştir. Mimari kapsamında ResNet'in çıktısı olan öznetelik haritası Bölge Teklif Önerici Ağ (Region Proposal Network) (RPN) aracılığı ile taranıp belirlenen ROI'ler ROI Hizalama bloğuna gelmektedir. Burada tüm ilgi bölgeleri eşit boyuta getirilmekte ve Birleşim Üzerinden Kesişim (Intersection over Union) (IoU) değerleri hesaplanmaktadır. Elde edilen değer 0,85 ve üzerinde ise bölge ilgi bölgesi olarak kabul edilerek nesne tespiti veya segmentasyon bloklarına gönderilmektedir. Kullanılan yapı Şekil 2.14'te verilmiştir. Araştırmacılar nesne tespiti bloğu kullanarak Mask R-CNN ile Bölge Tabanlı Evrişimsel Sinir Ağı (Region-Based Convolutional Neural Network) (R-CNN), Fast R-CNN (Hızlı R-CNN) ve Faster R-CNN'yi (Daha Hızlı R-CNN) kıyaslamışlar ve beklendiği gibi Mask R-CNN ile daha yüksek doğruluk oranı elde edildiğini gözlemlemişlerdir.


Başka bir çalışmada araştırmacılar bir önceki çalışmaya benzer şekilde çok modlu akciğer MR görüntü segmentasyonu için çapraz modalite sentez ağı ve çok modlu bir



Şekil 2.14 Çalışmanın Akış Şeması (Padma ve diğ., 2022)


segmentasyon ağı olan Res-UNet'in birleşmesi ile meydana gelen bir model önermişlerdir (J. Li, H. Chen, Y. Li, Peng, Sun ve diğ., 2022). Bu model Döngü Tutarlı Görüntü Koşullu Varyasyonel Otomatik Kodlayıcı (Cycle-Consistent Image Conditional Variational Auto-Encoders) (CICVAE) olarak isimlendirilmiştir. CICVAE, üretici ve yeniden yapılandırıcı olmak üzere iki adet Görüntü Koşullu Otomatik Değişken Kodlayıcı (Image Conditional Variational Auto-Encoders) (ICVAE) ile meydana gelmiştir. Sentez görüntüyü bu yapı ve T2 ağırlıklı MR görüntüsü kullanarak üretmektedir. Bunun için difüzyon ağırlıklı MR görüntülerine ihtiyaç duymaması içerik kaymalarının önüne geçmekle beraber hesaplama maliyetinin azalmasını sağlamıştır. CICVAE'nin yapısı Şekil 2.15'de verilmiştir. Deneyler için kullanılan görüntüler T2 ağırlıklı ve difüzyon ağırlıklı MR görüntüleridir. Veri seti orijinal olarak 57 farklı hastadan elde edilen 355 tarama dilimini içermektedir. Çalışmada T2 ağırlıklı MR görüntüleri zengin dokusu ve görüntü kalitesi ile anatomik modalite olarak, difüzyon ağırlıklı MR görüntüsü ise tümör bölgesinin görüntüde diğer yapılara göre yüksek sinyalli olması ile fonksiyonel modalite olarak kullanılmıştır. Veri seti sekiz kere rastgele kırpma ve döndürme işlemleri uygulanarak çoğaltılmıştır. Sonuçları değerlendirmek için Dice benzerlik katsayısı ve Hausdorff Mesafesi tercih edilmiştir. Objektif değerlendirme için HDUNet, Res-UNet, AMRSegNet, DAFNet modelleri de aynı veri seti ile eğitilmiştir. En başarılı sonuçlar önerilen model olan CICVAE ve Res-UNet ile elde edilmiştir. Değerler sırasıyla $0,85(\pm 0,10)$ ve $15,74(\pm 7,58)$ 'dir. Model, literatürde bulunan çalışmalara göre Dice benzerlik katsayısını %3,14 oranında ve Hausdorff Mesafesi'ni %4,89 oranında attırmıştır.

Akciğer kanserinin tespit edilmesi için Derin Kalıntı Ayrılabilir Evrişimsel Sinir Ağı (Deep Residual Separable Convolutional Neural Network) (DRS-CNN)-1 ve Derin Kalıntı Ayrılabilir Evrişimsel Sinir Ağı (Deep Residual Separable Convolutional Neural Network) (DRS-CNN)-2 olarak isimlendirilmiş iki farklı CNN mimarisi önerilen çalışmada



Şekil 2.15 CICVAE Mimarisi (J. Li, H. Chen, Y. Li, Peng, Sun ve diğ., 2022)

araştırmacılar, literatürde öne çıkan mimarilerin avantajlarını koruyup dezavantajlarını minimize etmeyi hedeflemişlerdir (Dutande ve diğ., 2022). Önerilen mimarilerde uçtan uca veri hattını başarılı bir şekilde tanımladığı için U-net baz alınmıştır. Ek olarak gradyan problemini çözmek için ResNet, başarı oranını etkilemeden parametre azaltmak için MobileNet, daha uygun öznetelikler seçebilmek için atrous evrişimlerinin kullanımıyla DRS-CNN-2’de DeepLab mimarilerinden de esinlenilmiştir. Önerilen iki mimarinin yapısı da Şekil 2.16’de verilmiştir. U-net’te altörnekleme işlemleri ile kaybolan önemli bilgiler için bu işlemler DRS-CNN mimarisinde ayrılabilir ayırık evrişim birimleri (SCRE ve SCRD) ile değiştirilmiştir. Bu birimler sayesinde mimari U-net’ten fazla katman içermesine rağmen daha az hiperparametreye sahiptir. Model sonuçları objektif olarak karşılaştırabilmek için aynı veri setleri ile eğitilmiştir. Kullanılan veri setlerinden ilki Medical Segmentation Decathlon (MSD) isimli veri setidir. 63 hastaya ait CT görüntüsü içermektedir. Bu veri seti eğitim, doğrulama ve test olarak 7:2:1 oranında bölünmüştür. Diğer veri seti ise yalnızca test için kullanılan StructSeg 2019 isimli veri setidir ve 50 hastaya ait CT görüntüsü bulundurmaktadır. Görüntülerin hepsi sırasıyla akciğer bölgesinin belirgin hale gelmesi için satirasyon, araştırmacıların Maksimum Yoğunluk Projeksiyonu (Maximum Intensity Projection) (MIP) adını verdikleri tümör segmentasyonuna yardım edebilecek yüksek yoğunluklu yapıların belirginleştirilmesi işlemi ve görüntüden tümör çevresini içeren 256×256 boyutlu yama çıkarılması adımlarından geçirilerek işlenmiştir. Sonuçların değerlendirilmesi için Dice benzerlik katsayısı, Hausdorff Mesafesi, ortalama hassasiyet metrikleri kullanılmıştır. DRS-CNN-2 ortalama olarak sırasıyla 0,65, 18,26, 0,737 değerlerini elde ederek Unet, SegNet, FCN, R2-Unet mimarilerinin önüne geçmiştir.



Şekil 2.16 DRS-CNN-1 ve DRS-CNN-2 Mimarileri (Dutande ve diğ., 2022)

3. MATERİYAL VE YÖNTEM

Mevcut çalışmada gerçek veriler ile hazırlanmış veri seti kullanarak tümör segmentasyonu ve tümörün sınıflandırılması yapılmıştır. Farklı formatlarda eğitilen veri seti segmentasyon modellerine uygun olarak Common Objects in COntext (COCO)(Lin, Maire ve diğ., 2014) ve Pascal Visual Object Classes (Pascal VOC) (Everingham ve diğ., 2010) formata getirilmiştir. Segmentasyon için Mask R-CNN (He ve diğ., 2017), DeepLabv3+ (L.-C. Chen, Zhu ve diğ., 2018), YOLACT (Bolya ve diğ., 2019), SOLOv2 (X. Wang ve diğ., 2020) olmak üzere dört farklı örnek ve semantik segmentasyon yöntemi kullanılmıştır. Modellerin uygulanması için Python programlama dili (Van Rossum ve Drake Jr, 1995), PyTorch (Paszke ve diğ., 2017) ve Detectron2 (Girshick, Radosavovic ve diğ., 2018) modülleri tercih edilmiştir. Eğitim için kullanılan her mimari IoU, AP, mAP ve Dice benzerlik katsayısı metrikleri kullanılarak değerlendirilmiştir.

3.1 Veri Seti

Çalışma kapsamında Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Hastanesi'nde 32 benign ve 52 malign olmak üzere toplam 84 farklı hastadan elde edilen akciğer MR görüntüleri kullanılmıştır. Dört kanallı MR görüntülerinin P, K ve M kanallarının farklı volümetrik görüntüleri ayrı birer görüntü olarak kayıt edildikten sonra radyoloji uzmanları eşliğinde LabelMe aracı (Wada, 2018) ile nesne sınıfları benign ya da malign olacak şekilde etiketlenmiştir. Veri setinde toplam 2033 görüntü bulunmaktadır. Bu görüntülerin 920'si benign tümörü ve 1113'ü malign tümörüdür ve toplamda 306 adet benign ve 371 adet malign P kanalı, 307 adet benign ve 370 adet malign K kanalı, 307 adet benign ve 372 adet malign M kanalı görüntüsü bulunmaktadır. Veri setini doğru analiz edebilmek ve segmentasyon başarısını yükseltebilmek amacıyla veri seti üç farklı versiyonda eğitilmiştir.

3.1.1 Birinci Versiyon

Veri setinin ilk versiyonu, her kanalın ayrı görüntü olarak kayıt edildiği ham versiyondur. Medikal görüntü kanalların ayrı görüntüler olarak ele alınması RGB bir görüntünün kırmızı, yeşil ve mavi kanallarının ayrılarak birer görüntü şeklinde işlenmesine eş değerdir. Veri setinin birinci versiyonu Şekil 3.2a, Şekil 3.2b ve Şekil 3.2c'de verilen görüntüleri bulundurmaktadır. İlk versiyonda bulunan 920 benign ve 1113 malign tümör görüntüsü, 1633 eğitim ve 400 doğrulama örneği olarak ayrıldıktan sonra segmentasyon mimarisine girdi olarak verilmiştir.

3.1.2 İkinci Versiyon

Veri setinin ikinci versiyonunda kanallardan en çok bilgi sağlayanını bulmak ve hangi tümör tipinin hangi kanalda daha rahat ayırt edildiğini görmek hedefiyle kanallara ait görüntüler ayıklanarak her kanal ayrı eğitilmiştir. Bu versiyonda veri sayısının P, K ve M kanalları için eşit olması amacıyla eğitimlerde 306 benign ve 370 malign tümör görüntüsü kullanılmıştır. Bu görüntüler her kanala ait set için 546 eğitim ve 130 doğrulama örneği olacak şekilde ayrılmış ve sonrasında eğitilmiştir.


3.1.3 Üçüncü Versiyon

Farklı kanallardan gelen görüntülerin birbirinden ayrı bilgiler vermesi sebebiyle aynı hastaya ait tümörün farklı kanal görüntülerindeki poligonları örtüşmemektedir. Bu sebeple görüntünün tüm kanallarından gelen bilgilerden faydalanmak ve segmentasyon başarısını yükseltmek amacıyla kanallar birleştirilerek üçüncü versiyon veri seti elde edilmiştir. Kanalların birleştirilmesi Şekil 3.1’de verilen görselleştirmeye uygun olarak gerçekleştirilmiştir. Şekil 3.2’de bir tümöre ait ayrı kanal görüntüleri ve kanalların birleşmesi ile ortaya çıkan yeni görüntü verilmiştir.




Şekil 3.1 Veri Setinin P, K ve M Kanallarının Birleştirilmesi

Veri setinin üçüncü versiyonunda tümörün çevresini işaret eden poligonların örtüşmemesi sebebiyle farklı poligonların birleşimi alınarak veri setinin etiketleri düzenlenmiştir. Görüntülere ait etiketlerin birleştirilmesi Şekil 3.3’te verilen temsile uygun olarak gerçekleştirilmiştir. Birleştirme sonrası veri setinin üçüncü versiyonunda 307 adet benign, 373 adet malign tümör bulunmaktadır. Üçüncü versiyon veri setinde 543 eğitim ve 137 doğrulama verisi olacak şekilde bir ayırma yapılmıştır.



Şekil 3.2 Veri Setinden Örnekler



Şekil 3.3 Veri Setinin P, K ve M Kanallarının Etiketlerinin Birleştirilmesi

3.2 Ön İşleme

Çalışma kapsamında veri seti üç farklı versiyonda ve model gereksinimlerine bağlı olarak iki farklı formatta eğitilmiştir. LabelMe aracı (Wada, 2018) etiketleme çıktısını JavaScript Object Notation (JSON) uzantılı dosyalara kayıt etmektedir. Her görüntünün kendine ait bir dosyası bulunmakta ve bu dosya görüntü ismi, poligon noktaları vb. bilgiler içermektedir. Veriler bahsi geçen formattan COCO formata (Lin, Maire ve diğ., 2014) çevirilmiştir. İlk olarak Microsoft tarafından yayınlanan COCO veri seti, verilerin yönetimini kolaylaştıran ve segmentasyon, obje tanıma gibi görevleri bir değişiklik yapmadan uygulamaya yarayan bir formata sahiptir. Bu sebeple format özel veri setlerine de uygulanmaya başlanmıştır. COCO formatında bir veri seti; eğitim, değerlendirme ve varsa test veri seti için ayrı birer JSON dosyası içermektedir. Setlerin içerisindeki görüntüler ve görüntülere ait etiket kimliği, görüntü kimliği nesne sınıfı, sınırlayıcı kutu koordinatları, segmentasyon noktaları vd. bütün bilgiler tek JSON dosyasında toplanmıştır. Bu çalışmada Mask R-CNN, YOLACT ve SOLOv2 modelleri JSON formatında veri seti ile beslenmiştir. Ek olarak veri setinin üç versiyonu için veriler JSON formata çevirilmiştir.

Semantik segmentasyon yapan DeepLabv3+ modeli için veri setinin Pascal VOC formatı (Everingham ve diğ., 2010) elde edilmiştir. Pascal VOC, COCO'ya benzer şekilde veri seti olarak yayınlanmış ve formatın kullanışlı bulunması ile özel veri setlerine uygulanmaya başlanmıştır. Bu formatta veriler Extensible Markup Language (XML) dosyalarında ve her görüntü için bir XML dosyası bulunmaktadır. Her bir dosya; sınırlayıcı kutu koordinatları, segmentasyon için kullanılacaksa segmentasyon noktaları, görüntünün ismi ve bulunduğu dosya yolu, içerdiği nesnelerin sınıfı gibi bilgiler içermektedir. Segmentasyon için kullanıldığında JSON formatın aksine görüntülere ait maskelerinde veri seti içerisinde bulunması gerekmektedir. Tüm görüntüler tek bir klasör altında verilmekte ve görüntülerin ait oldukları veri seti grubunun bulunması için metin

dosyası içinde görüntü isimleri verilmektedir. Veri setinin üçüncü versiyonu Pascal VOC formata çevirilmiştir.

Görüntülerin yeniden boyutlandırılarak boyutlarının azaltılması, görüntüye oranla küçük olan tümörlerin daha da küçülmesine yol açtığı için tercih edilmemiştir. Bunun dışında görüntüler modeller için uygun formata çevrildikten sonra Mask R-CNN için bir dönüşüm uygulanmazken, SOLOv2 için görüntülerin normalizasyonu, YOLACT için görüntülerin normalizasyonu, DeepLabv3+ için ise görüntülerin normalizasyonu ve mimari büyüklüğü sebebiyle boyutları 513×513 olacak şekilde merkezi ve rastgele kırpma dönüşümleri uygulanmıştır.


3.3 Derin Öğrenme Mimarileri

3.3.1 Mask R-CNN

Nesne tespiti, örnek segmentasyonu ve oynar eklemlerin konumunu tahmin etmek adına anahtar nokta tespiti olmak üzere üç farklı görevi yerine getirebilen Mask R-CNN (He ve diğ., 2017); kolay eğitilebilir, esnek ve verimli olması ile öne çıkmaktadır. Facebook tarafından geliştirilen bu mimari, Faster R-CNN mimarisini (Ren ve diğ., 2015) temel almaktadır. Mask R-CNN mimarisi, tıpkı Faster R-CNN mimarisi gibi iki aşamalı ve CNN tabanlı bir mimaridir (He ve diğ., 2017). İlk aşamada RPN ile ROI teklifleri oluşturulmaktadır. İkinci aşama her ROI'nin sınıflandırılmasını ve ikili maske oluşturulmasını içermektedir. İkili maske oluşturmak Faster R-CNN mimarisinde halihazırda bulunan sınırlayıcı kutu konumu ve sınıf etiketi çıkışlarına paralel maske tahmini veren üçüncü bir dal ekleyerek sağlanmıştır.

Faster R-CNN, R-CNN mimarisinde (Girshick, Donahue ve diğ., 2014) bulunan ROI'lere uygulanan ilgi havuzu bölgesi ile önemli bilgi içeren daha küçük alanı incelemekte ve eğitimi hızlandırmaktadır. Ancak ROI havuzlama olarak isimlendirilen bu katmanda iki defa niceleme kullanımı önemli bilgi kaybına yol açmaktadır (He ve diğ., 2017). Bu sebeple araştırmacılar Mask R-CNN'de her ROI'den çıkarılan öznetelik haritasını niceleme kullanmadan elde edebilen bu sayede bilgi kaybını minimize eden ROIAlign işlemini önermişlerdir. Bahsi geçen mimarinin temsili Şekil 3.4'te verilmiştir.

Çalışmada hızı kaybetmeden doğruluğu arttırmak için sınıflandırıcı olarak ResNet ve Öznetelik Piramit Ağı (Feature Pyramid Network) (FPN) beraber kullanılmıştır. Önerilen bu mimari ResNet-101-FPN sınıflandırıcısı ile COCO veri seti kullanılarak eğitilmiştir. Mask R-CNN, COCO 2015 ve 2016 kazananlarını geride bırakarak 35,40 IoU Üzerinden Ortalama ya da diğer bir deyişle Ortalama Kesinlik (Average Precision) puanı elde etmiştir.



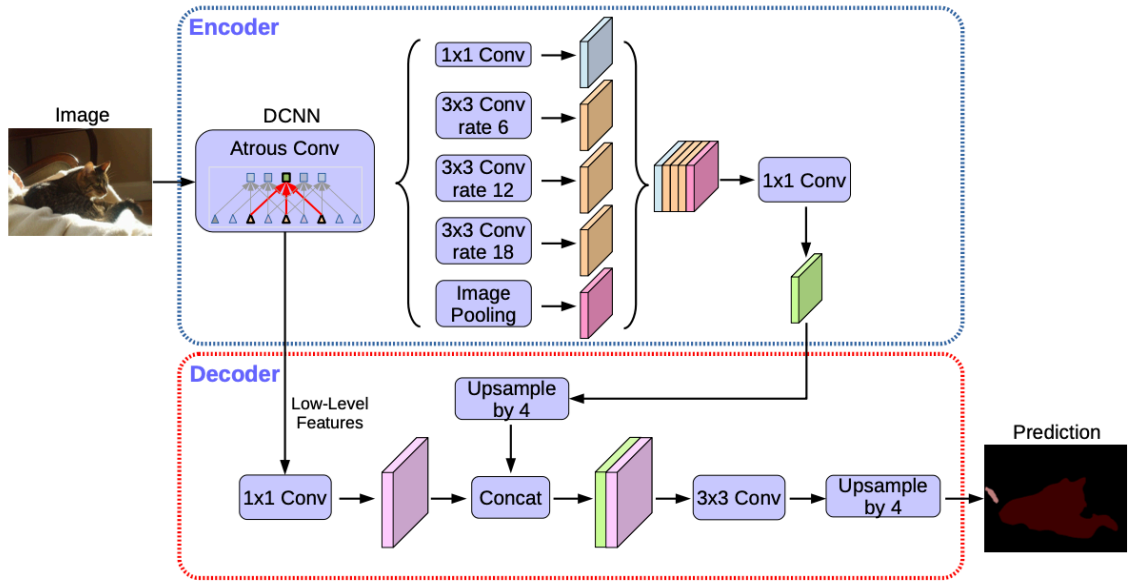
Şekil 3.4 Mask R-CNN Mimarisi Temsili (He ve diğ., 2017)

Çalışma kapsamında, veri setinin Bölüm 3.1’de verilen üç ayrıımı Mask R-CNN mimarisi ile eğitilmiştir. Veri setinin ilk versiyonu ResNet-101 sınıflandırıcı kullanılarak 0,0005 öğrenme oranı, 12 batch boyutu ile 5000 iterasyon eğitilmiştir. 4000. iterasyondan sonra ise WarmUpMultiStepLR öğrenme oranı düzenleyicisi uygulanmıştır. İkinci versiyonunda K, P ve M kanalları ayrı olarak ResNet-101 sınıflandırıcısı kullanılarak 12 batch boyutu, 0,0004 öğrenme oranı ile 3000 iterasyon eğitilmiştir. 2500. iterasyondan sonra ise WarmUpMultiStepLR öğrenme oranı düzenleyicisi uygulanmıştır. Üç kanalın birleştirilmesi ile elde edilen versiyonda ResNet-101 sınıflandırıcı olarak tercih edilmiştir. Öğrenme oranı 0,0005 ve her iterasyon için batch boyutu 12 olarak belirlenmiştir. İlk iki versiyonda uygulanan öğrenme oranı düzenleyicisi bu eğitimde de kullanılmış olup toplam 5000 iterasyon olan eğitim sürecinin 4000. iterasyonundan sonra uygulanmıştır. Versiyon iki ve üç için ROIMaskHead parametresi 512 olarak güncellenmiştir. Diğer parametreler orijinale sadık kalınarak değiştirilmemiştir. Modelin Detectron2 modülü ile inşası için Roboflow (Solawetz, 2020) tarafından sağlanan açık kaynaklı bir eğitim temel olarak alınmıştır. Her üç eğitim tek NVIDIA Quadro P5000 GPU ile gerçekleştirilmiştir. Değiştirilen parametrelerin değerleri yapılan deneyler sonucunda elde edilmiş en yüksek başarıyı veren parametrelerdir.

3.3.2 DeepLabv3+


DeepLabv3+, Google tarafından geliştirilmiş ve DeepLabv3’nin genişletilmiş versiyonu olarak literatüre eklenmiştir (L.-C. Chen, Zhu ve diğ., 2018). Önerilen model, Derin Evrişimsel Sinir Ağları (Deep Convolutaional Neural Network) (DCNN) örneklerinden biri olan FCN’yi temel almaktadır. FCN, yapısında tam bağlantılı katman bulundurmadığı için girdi olarak verilen görüntülerin boyutlarında özgürlük sağlayan bir CNN’dir. DeepLabv3+’nın önceki versiyonunda bulunan ve DCNN mimarilerin gerektirdiği yukarı örnekleme işlemini hesaplama maliyetini arttırmadan katman filtresinin görüş alanını genişletmek amacıyla kullanılan Atrous ya da genişletilmiş evrişim katmanı ile DeepLabV2’de (L.-C. Chen, Papandreou ve diğ., 2017) önerilen ve aynı objenin farklı boyutlarda tespit edilmesini kolaylaştıran (Atrous Mekansal Piramit Havuzu (Atrous Spatial Pyramid Pooling) (ASPP) bu modelde de korunmaktadır.

DeepLabv3+, bir kodlayıcı-kod çözücü mimaridir (L.-C. Chen, Zhu ve diğ., 2018). Araştırmacılar mimariyi güçlü bir kodlayıcı ve basit ama etkili bir kod çözücü olarak tanımlamışlardır. Hem keskin sınırlar elde etmeyi hem de başarılı bir segmentasyon işlemi yapmayı hedefleyen DeepLabv3+, bir önceki versiyonu olan DeepLabv3'ü kodlayıcı olarak kullanmaktadır. Atrous evrişim katmanı, mimarinin kodlayıcı kısmında DCNN tarafından hesaplanmış öznetelikkleri çıkarmak için kullanılmaktadır. Önerilen modele ait mimari Şekil 3.5'te verilmiştir.



Şekil 3.5 DeepLabv3+ Mimarisi Temsili (L.-C. Chen, Zhu ve diğ., 2018)

DeepLabv3'den farklı olarak önerilen model, maksimum havuzlama katmanı yerine araştırmacıların önermiş olduğu atrous derinlemesine ayrılabilir evrişim katmanını kullanmaktadır. Atrous derinlemesine ayrılabilir evrişim katmanı, MobileNetV1 (Howard ve diğ., 2017) ile tanıtılan derinlemesine ayrılabilir evrişim katmanının atrous evrişim katmanı ile desteklenmesidir. Derinlemesine ayrılabilir evrişim katmanı ise standart evrişim ile noktasal evrişim işlemini birleştirerek hesaplama karmaşıklığını azaltan bir katmandır (L.-C. Chen, Zhu ve diğ., 2018). Atrous evrişimi ile desteklenerek modelin başarımı korunurken hesaplama karmaşıklığı da azaltılmıştır. Katman hem ASPP hem de kod çözücü kısımda kullanılmıştır. Şekil 3.6'da derinlemesine, noktasal ve atrous evrişim katmanlarının çalışma prensibi verilmiştir.




Şekil 3.6 Derinlemesine, Noktasal ve Atrous Evrişim Katmanlarının Çalışma Prensibi (L.-C. Chen, Zhu ve diğ., 2018)

DCNN, aşamalı olarak öznitelik haritalarının boyutlarını belirlenen bir faktöre göre azaltmaktadır. Klasik sınıflandırma görevleri için bu faktör genellikle 32 olarak belirlenirken otomatik segmentasyon gibi yüksek seviyeli bir göreve seyrek öznitelik çıkarımı yetmeyeceği için önerilen modelde çıktı adımı olarak isimlendirilen bu parametrenin 8 ya da 16 şeklinde kullanılması önerilmiştir. Araştırmacılar önerilen modeli, sınıflandırıcı olarak segmentasyon için uyarladıkları Xception-JFT kullanarak Pascal VOC veri seti üzerinde eğitmişlerdir. DeepLabv3+, semantik segmentasyon yapan benzer modelleri geçerek %89,00 ortalama IoU elde etmiştir. Bu çalışmada veri setinin üçüncü versiyonu kullanarak gerçekleştirilen deneylerde çıktı adımı 16 olarak kullanılmıştır. Araştırmacıların Tensorflow kullanarak açık kaynaklı paylaştıkları modeli Pytorch modülünü kullanarak Pascal VOC format veri setine uygulamak için yayımlanmış olan bir GitHub deposu kullanılmıştır (VainF, 2022). Eğitimde sınıflandırıcı olarak ResNet-101 tercih edilmiştir. Öğrenme oranı 0,03 ve batch boyutu 36 olacak şekilde parametreler güncellenmiştir. Dört adet NVIDIA Quadro P5000 GPU kullanılarak ve model 10000 iterasyon eğitilerek eğitim tamamlanmıştır. Bahsedilen parametreler DeepLabv3+ için yapılan deneyler sonucunda en yüksek başarımın elde edildiği eğitime ait parametrelerdir.

3.3.3 You Only Look at Coefficients (YOLACT)

Başarılı dijital görüntü segmentasyon ağları, hesaplama maliyetlerinin yüksek oluşundan dolayı gerçek zamanlı uygulamaların gerektirdiği hızı karşılayamamaktadır. Araştırmacılar literatürdeki bu eksikliği gidermek adına YOLACT mimarisini önermişler (Bolya ve diğ., 2019) ve Mask R-CNN'ye (He ve diğ., 2017) benzer şekilde var olan bir nesne tanıma modeline maske dalı eklemeyi hedeflemişlerdir. Araştırmacılar hesaplama maliyetini düşürüp hızı arttırmak için tek aşamalı model olan CNN tabanlı RetinaNet'i (Lin, Goyal ve diğ., 2017) tercih etmiştir. Aynı sebepten modelde ROIAAlign bölgesi veya ROI havuzlama


katmanı tarafından gerçekleştirilen önerilen bölgelerin maskeye hizalanması adımı atlanmıştır (Bolya ve diğ., 2019). YOLACT bunu yapabilmek için maskelerin uzamsal olarak tutarlı oluşuna dayanarak problemi iki paralel dala ayırmaktadır. İlk dal, örneğe bağlı olmadan prototip maske üretmek için FCN kullanmaktadır. Diğer dal ise prototip uzayındaki her elemana ait maske katsayılarını tahmin etmek üzere nesne tanıma dalına fazladan bir kafa eklemektedir. "Tahmin Kafası" olarak adlandırılan bu bloğun yapısı Şekil 3.7'de görüldüğü gibi RetinaNet'e göre daha sığdır ve maske katsayılarını veren fazladan bir dal bulundurmaktadır. Tahmin Kafası bloğunun sonrasında Maksimum Olmayan Bastırma (Non-Maximum Suppression) (NMS) bloğundan çıkmayı başarmış her örnek için bahsedilen iki dalın çalışmaları doğrusal olarak birleştirilerek örnek için bir maske önerisi üretilmektedir.



Şekil 3.7 Tahmin Kafası Bloğu Temsili (Bolya ve diğ., 2019)

Prototip maskelerin üretildiği dal, Mask R-CNN'den esinlenerek tasarlanmış ve Protonet olarak isimlendirilmiştir. Burada her görüntü için k adet prototip bulunmaktadır. Her prototip için bir kanalı bulunan k kanallı çıktı FCN olarak uygulanarak sınıflandırıcının öznetelik katmanına eklenmektedir. Araştırmacılar daha derin sınıflandırıcı özneteliklerinden protonet alınmasının daha sağlam maskeler ürettiğini vurgulamaktadır. Daha sağlam maskeler yüksek çözünürlüklü prototiplerin ortaya çıkmasını sağlamakta ve bu ise görüntüde bulunan küçük nesnelerin tespitinde daha iyi performans gösterilmesini sağlamaktadır. Araştırmacılar bundan faydalanmak için FPN kullanmışlardır. Nihai maske oluşumu için prototip dalı ve maske katsayısını tahmin eden daldan gelen bilgiler doğrusal olarak birleştirilmiştir. Bahsedilen YOLACT mimarisinin temsili Şekil 3.8'de verilmiştir.

Literatürdeki diğer örnek segmentasyonu modellerinden farklı olarak YOLACT çoklu GPU yerine tek GPU ile eğitilmiştir. Araştırmacılar sınıflandırıcı olarak FPN ve ResNet-101'i beraber kullanmışlardır. Veri seti olarak COCO veri seti tercih edilmiştir. 550×550 boyutlu veriler ile beslenmiş YOLACT-550, rekabet içinde olduğu diğer örnek




Şekil 3.8 YOLACT Mimarisi (Bolya ve diğ., 2019)

segmentasyonu modellerine göre 3,9 kat daha hızlıdır. Bu ise 33, 50 Saniyedeki Kare Sayısı (Frame Per Second) (FPS) olarak ölçülmüştür. Ortalama AP (Mean Average Precision) (mAP) değeri 29, 80 ile benzerinden bir miktar geri kalmış olsa da YOLACT mimarisi bunu hızıyla telafi etmektedir. Çalışma kapsamında bu mimariyi kullanmak için araştırmacıların çalışmalarında bağlantısına yer verdikleri ve GitHub üzerinde açık kaynaklı olarak paylaştıkları depo kullanılmıştır. Orijinalde tek GPU ile çalışma imkanı sağlayan YOLACT'a sonrasında çoklu GPU özelliği de getirilmiştir ve çalışma kapsamında dört adet NVIDIA Quadro P5000 GPU kullanılarak eğitim gerçekleştirilmiştir. Eğitimde sınıflandırıcı olarak ResNet-101 kullanılırken toplam batch boyutu 24 ve öğrenme oranı 0,001 olarak belirlenmiştir.

3.3.4 Segmenting Objects by Locations (SOLOv2)

Segmentasyon görevini yerine getiren ağlar genellikle iki ana yaklaşım benimsemektedir: Nesne tespitinden sonra segmentasyon, Benzer piksellerin kümelenmesi (X. Wang ve diğ., 2020). SOLOv2, benzer pikselleri gruplamadan ve sınırlayıcı kutuları kullanmadan doğrudan segmentasyon hedeflemekte ve bahsedilen yaklaşımlara bir yenisini eklemektedir. Tek aşamada segmentasyon için nesneleri konumlarına göre ayırmakta ve ismini de buradan almaktadır. Doğrudan, dinamik segmentasyon için SOLOv2 görüntüyü ızgaralara ayırmaktadır. İçerisinde nesne merkezi bulunduran ızgaralar iki farklı görevi gerçekleştirmektedir. Bunlar evrişim çekirdeği öğrenmek (Maske G) ve öznetelik öğrenmektir (Maske F). İki görevden gelen maskeler dinamik evrişim ile birleştirilerek maske önerisi (Maske M) elde edilmektedir. İki maskenin ayrı ayrı öğrenilmesi Maske M'nin doğrudan üretilmesine göre daha avantajlıdır. Maske M büyük bir tensördür ve bir çekirdek için üretilen her maske eğitim aşamasında kullanılmamaktadır. Bu sebeple her çekirdek için her Maske M'nin hesaplanması hesaplama maliyetini arttırmaktadır. Maske F

ve Maske G'nin ayrı öğrenilmesi ile ızgara çekirdeği daha rahat seçilmektedir. Ek olarak çekirdeğin girdiye göre dinamik olarak üretilmesi modele esneklik sağlamaktadır. Bahsedilen SOLOv2 mimarisi Şekil 3.9'da verilmiştir.



Şekil 3.9 SOLOv2 Mimarisi (X. Wang ve diğ., 2020)

Bir objenin tespiti için birden çok maske üretilmektedir. Bu şekilde yinelenen tahminleri kaldırmak için NMS algoritması kullanılmaktadır. Maske NMS, sınırlayıcı kutu NMS'ye göre daha maliyetlidir. İşlemi gerçekleştirmek için farklı metotlar önerilmiştir ancak bu metotlar hızı arttırmak için doğruluğu ikinci plana atmaktadır. Araştırmacılar bu darboğazı çözmek için paralel matris işlemleriyle bir defada NMS yapan Matris NMS'yi önermişlerdir. Matris NMS, geleneksel NMS'den dokuz kat daha hızlı ve %0,4 AP daha doğrudur. COCO veri seti ve ResNet-101 sınıflandırıcısı ile eğitilen SOLOv2 %39,70 AP değeri ile Mask R-CNN (He ve diğ., 2017) ve YOLACT (Bolya ve diğ., 2019) gibi benzer örnek segmentasyonu modellerini geride bırakmıştır. Bu çalışma kapsamında veri setinin üçüncü versiyonuyla eğitilen SOLOv2 modeli en başarılı sonucu ResNet-101 sınıflandırıcısını kullanarak, öğrenme oranı ve batch boyutu parametrelerinin sırasıyla 0,005 ve 4 şeklinde güncellenmesiyle elde etmiştir. Eğitim bir adet NVIDIA Quadro P5000 GPU ile gerçekleştirilmiştir. Modelin uygulanması için araştırmacıların GitHub üzerinden açık kaynaklı paylaştıkları depo kullanılmıştır.

3.4 Değerlendirme Metrikleri

Farklı segmentasyon yöntemleri eğitim sonuçlarını farklı metrikler kullanarak değerlendirmektedir. Semantik segmentasyon için bu yöntem IoU metriğidir. Örnek segmentasyonu ise gerçek maskeler ile tahmin edilenler arasındaki benzerliği değerlendirmek için AP metriğini kullanmaktadır (Kookna, 2022).

3.4.1 Karmaşıklık Matrisi


Karmaşıklık matrisi, makine öğrenmesi ya da derin öğrenme yöntemlerinin çıktılarını değerlendirmek için kullanılan metriklerin hesaplanmasını sağlayan matristir (Caelen, 2017). IoU, AP, doğruluk, duyarlılık, hassasiyet gibi pek çok metrik karmaşıklık matrisi kullanılarak hesaplanmaktadır. Matris içerisinde Gerçek Pozitif (True Positive) (TP), Yanlış Pozitif (False Positive) (FP), Gerçek Negatif (True Negative) (TN) ve Yanlış Negatif (False Negative) (FN) olmak üzere dört farklı bileşen bulunmakta ve m sınıfa sahip bir görevde karmaşıklık matrisi $m \times m$ boyutunda olmaktadır. İki sınıflı bir görev için karmaşıklık matrisi taslağı Çizelge 3.1’de verildiği gibidir.

Çizelge 3.1 Karmaşıklık Matrisi

		Gerçek	
		Doğru	Yanlış
Tahmin	Doğru	TP	FP
	Yanlış	FN	TN

3.4.2 Birleşim Üzerinden Kesişim (Intersection over Union) (IoU)

IoU, orijinal maske ve tahmin edilen maske arasındaki kesişmeyi ölçmek için kullanılan metriktir (Subramanyam, 2021). Literatürde Jaccard İndeksi ya da Jaccard Benzerlik Katsayısı olarakta geçmektedir (Csurka ve diğ., 2013). Maskelerin kesişim bölgesi arttıkça IoU değeri yükselmektedir (Sheremet, 2020). Örneğin iki maske birbiriyle tam olarak örtüştüğünde IoU değeri %100 olmaktadır. Şekil 3.10’da görüldüğü gibi orijinal maske ile tahmin maskesinin kesişiminin yine bu iki maskenin birleşimine bölümü IoU değerini vermektedir.

$$IOU = \frac{\text{area of overlap}}{\text{area of union}} = \frac{\text{area of overlap}}{\text{area of union}}$$


Şekil 3.10 IoU Metriği (Padilla ve diğ., 2020)

Doğrulama setine ait IoU değeri karmaşıklık matrisi içerisindeki değerler kullanılarak hesaplanmaktadır (Karayeğen, 2021). Temel mantığı Denklem 3.1’de verildiği gibi kesişimin birleşime bölünmesinden gelmektedir. Karmaşıklık matrisi kullanarak IoU hesaplanması Denklem 3.2’te verilmiştir.

$$Jaccard(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (3.1) \quad Jaccard = IoU = \frac{TP}{TP + FP + FN} \quad (3.2)$$

3.4.3 Ortalama Kesinlik (Average Precision) (AP)

AP metriği IoU, kesinlik (Precision) ve duyarlılık (Recall) metrikleri kullanarak hesaplanmaktadır (Schütze ve diğ., 2008). Bu sebeple metriğin temeli karmaşıklık matrisine dayanmaktadır. Kesinlik, modelin tüm tahminler arasında gerçek pozitif değerlerin oranını vermektedir (Ay, 2020). Özellikle yanlış pozitif tahminlerin maliyetinin yüksek olduğu durumlarda kesinlik değerinin yüksek olması beklenmektedir. Kesinlik metriğini veren denklem Denklem 3.3’te verilmiştir. Duyarlılık metriği kesinliğe benzemekte ve pozitif olarak etiketlediğimiz verilerin kaçının gerçek pozitif olduğunu hesaplamaktadır. Duyarlılık metriğinin hesaplanması Denklem 3.4’te verilmiştir.

$$Precision = \frac{TP}{TP + FP} \quad (3.3)$$

$$Recall = \frac{TP}{TP + FN} \quad (3.4)$$

AP metriği, Kesinlik Duyarlılık (Precision Recall) (PR) Eğrisi altında kalan alanın hesaplanması ile elde edilmektedir. PR eğrisi altında kalan alan, Denklem 3.5'te formülü verilmiş olan 11 Noktalı İnterpolasyon kullanarak hesaplanmaktadır (Schütze ve diğ., 2008). Bahsedilen denklemde $i = 0, 0.1, 0.2, \dots, 1$ olarak alınmaktadır. PR Eğrisi farklı IoU eşikleri için farklı sonuçlar vermektedir (Anwar, 2022). IoU eşikleri, güven eşikleri şeklinde de isimlendirilmektedir. Örneğin AP_{50} olarak verilen bir değer için IoU eşikliği %50 olarak uygulanmıştır. Genellikle IoU eşikleri ne kadar yüksek olursa eğitilmiş modelin tahminleri o kadar kesin ve güvenilir olmaktadır. Örneğin tahmin IoU değeri 0,4 olan bir görüntü, 0,5 eşik uygulanırsa FP olarak değerlendirilirken 0,3 eşik uygulandığında TP olarak ele alınmaktadır.

$$AP = \frac{1}{11} \sum_{Recall_i} Precision(Recall_i) \quad (3.5)$$

AP değeri her nesne sınıfı için ayrı olarak hesaplanmaktadır (Liu, 2018). Doğrulama setine ait genel bir değer elde etmek için Ortalama AP (Mean Average Precision) (mAP) metriği kullanılmaktadır. COCO tarafından geçerli olarak kabul edilen mAP değeri, farklı eşik değerleri kullanılarak hesaplanmakta ve IoU üzerinden ortalama olarak geçmektedir (Lin, Maire ve diğ., 2014). Eşik değerleri, adım büyüklüğü 0,05 olacak şekilde 0,50 ile 0,95 arasındaki 10 farklı değerden oluşmaktadır. Literatürde eşik değerlerini ifade etmek için mAP metriğinden $mAP_{0,50:0,05:0,95}$ şeklinde de bahsedilmektedir. Verilen AP_{50} örneğinde olduğu gibi eşik değerinden büyük tahmin değerleri TP, küçük tahmin değerleri de FP olarak ele alınmaktadır. Her eşik değeri için Denklem 3.5 kullanılarak AP değeri hesaplanmaktadır. Elde edilen değerlerin ortalaması sınıfa ait AP değerini verirken tüm nesne sınıflarına ait AP değerlerinin aritmetik ortalaması mAP değerini vermektedir.

3.4.4 Sorenson-Dice Katsayısı

Literatürde Dice Katsayısı, F1 puanı ya da Dice Benzerlik Katsayısı olarak geçen metrik iki örneğin benzerliğini ölçmek adına kullanılmaktadır (Guindon ve Zhang, 2017). Özellikle tıbbi görüntü segmentasyonu görevlerinde sıkça tercih edilmekte ve benzerliği ölçülecek iki görüntünün birbirleri ile eşit boyutta olmaları gerekmektedir. Denklem 3.6'da verilen formül ile hesaplanan katsayı ile 0-1 arasında bir değer elde edilmektedir. İşleme alınan görüntülerin benzerliğinin yüksek olması değerlerin bire yakın olması anlamına gelmektedir. Segmentasyon sınıfları için ayrı ayrı hesaplanabileceği gibi genel bir Dice katsayısı hesaplamakta mümkündür.

$$DiceKatsays = \frac{2 * |A \cap B|}{|A| + |B|} \quad (3.6)$$

4. BULGULAR VE TARTIŞMA

Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Hastanesi’nden elde edilen veri setinin ilk versiyonu Mask R-CNN ile eğitilmiştir. Eğitim sonrası veriler için elde edilen AP ve mAP değerleri Çizelge 4.1’de verilen değerlere ulaşılmıştır. Alınan sonuçlara göre Mask R-CNN mimarisi benign nesne sınıfı için %65,11 AP , malign sınıfı için %64,31 AP elde etmiştir. Mimarinin tüm nesne sınıfları üzerindeki mAP değerinin ise %64,71 olduğu görülmüştür. IoU eşiğinin %50 olarak belirlenmesi ile sonuçta %89,03 mAP değerine ulaşılmıştır. Şekil 4.1’de eğitim sonucunda tahmin edilen maskeler, orijinal maskeler ve orijinal görüntüler verilmiştir.


Çizelge 4.1 Veri Setinin Birinci Versiyonu için Eğitim Sonuçları

	<i>AP- Benign</i>	<i>AP- Malign</i>	<i>mAP</i>	<i>mAP₅₀</i>	<i>mAP₇₅</i>
Mask R-CNN	%65,11	%64,31	%64,71	%89,03	%82,69


Veri setinin ikinci versiyonunda P, K ve M kanalları ayrı ayrı eğitilmiştir. Eğitim için Mask R-CNN mimarisi kullanılmıştır. Her kanal aynı parametreler ile eğitilmiştir. Eğitim sonuçları Çizelge 4.2’de verilmiştir. K kanalı benign nesne sınıfı için %72,88 AP değeri ve malign nesne sınıfı için %46,85 AP değeri elde etmiştir. Modelin mAP değeri ise %59,86’dir. P kanalı ise benign nesne sınıfı için %70,46 AP değeri, malign nesne sınıfı için %43,76 AP değeri vermiştir. P kanalı için yapılan eğitimin mAP değeri %57,11’dir. Son kanal olan M kanalı benign tümörleri %54,94 AP değeri ile segmente etmişken malign tümörler üzerinde %57,02 AP başarı elde etmiştir. M kanalı için ulaşılan mAP değeri %55,98’dir. Alınan sonuçlara göre benign tümörleri segmente etmek için K kanalı daha fazla bilgi verirken malign tümörler için M kanalından gelen bilgiler daha faydalı olmaktadır. İkinci versiyon veri setinin eğitimi sonucu K kanalı için alınan maske tahminleri, orijinal görüntü örnekleri Şekil 4.2’de, P kanalı için alınan maske tahminleri, asıl görüntü örnekleri Şekil 4.3’te ve M kanalı için elde edilen maske tahminleri, orijinal maske örnekleri Şekil 4.4’te verilmiştir. Seçilen örnekler, her sıra farklı bir hastayı ifade edecek şekilde toplam dört farklı hastadan seçilmiştir. Örnek olarak Şekil 4.2a, Şekil 4.3a ve Şekil 4.4a’da verilen görüntü aynı hastaya ait görüntünün K, P ve M kanalıdır. Şekil 4.2e, Şekil 4.3e ve Şekil 4.4e’de verilen örnek, malign tümörlerin segmente edilmesi görevinde M kanalının daha başarılı olduğunun bir diğer kanıtıdır. M kanalına göre daha yüksek mAP değerlerine sahip K ve P kanallarından gelen bilgilerle model tarafından




(a) Orijinal




(b) Orijinal Maske




(c) Önerilen Maske




(d) Orijinal




(e) Orijinal Maske




(f) Önerilen Maske



(g) Orijinal




(h) Orijinal Maske




(i) Önerilen Maske



(j) Orijinal



(k) Orijinal Maske



(l) Önerilen Maske


Şekil 4.1 Veri Seti Versiyon-1 için Orijinal Görüntüler, Maskeler ve Tahmin Edilen Maskeler

yakalanamayan malign tümörü M kanalından gelen bilgiler ile başarılı şekilde segmente etmiştir. Sonuçlar mAP değerlerine göre genel olarak ele alındığında K kanalının tümör segmentasyonu için daha çok bilgi sağladığı görülmüştür.

Çizelge 4.2 Veri Setinin İkinci Versiyonu için Eğitim Sonuçları

	P Kanalı	K Kanalı	M Kanalı
<i>Mimari</i>	Mask R-CNN		
<i>mAP</i>	%57,11	%59,86	%55,98
<i>AP- Benign</i>	%70,46	%72,88	%54,94
<i>AP- Malign</i>	%43,76	%46,85	%57,02


Nihai veri seti olan üçüncü versiyon veri seti Mask R-CNN, YOLACT, DeepLabv3+ ve SOLOv2 segmentasyon modelleri ile eğitilmiştir. Mask R-CNN ve SOLOv2 mimarileri tek NVIDIA Quadro P5000 GPU ile eğitilmiştir. YOLACT ve DeepLabv3+ modelleri 4 adet NVIDIA Quadro P5000 GPU kullanarak eğitilmiştir. Elde edilen sonuçların değerlendirilmesi için mAP, AP, IoU ve Dice katsayısı olmak üzere dört farklı metrik kullanılmıştır. Eğitimler için alınan sonuçlar Çizelge 4.3'te verilmiştir. Küçük nesnelerin tespiti konusunda en iddialı model olan YOLACT mimarisi Çizelge 4.3'te görüldüğü gibi %73,54 mAP değeri ile en başarılı sonucu vermiştir. YOLACT mimarisini Mask R-CNN %67,16 mAP değeri ile takip etmektedir. Ardından SOLOv2 mimarisıyla %62,70 mAP değerine ve DeepLabv3+ mimarisıyla %36,81 mAP değerine ulaşılmıştır. Nispeten büyük obje içeren veri setlerinde başarı sonuçlar veren DeepLabv3+ segmentasyon mimarisi (L.-C. Chen, Zhu ve diğ., 2018), tümörün sınırlarının belirlenmesinde %36,81 mAP ile en az başarının elde edildiği ağ olmuştur. DeepLabv3+, etiket sınıflarını doğru tahmin etse de tümörlerin sınırlarının doğru belirlememesi ve özellikle küçük tümör içeren görüntülere bir maske üretmemesiyle düşük olarak tanımlanabilecek bir performans göstermiştir. Mask R-CNN eğitimi sonucu elde edilen maske, orijinal maske ve görüntü örnekleri Şekil 4.5'te verilmiştir. YOLACT eğitimi sonucu ulaşılmış olan maske, orijinal maske ve görüntü örnekleri Şekil 4.6'da verilmiştir. SOLOv2 mimarisine ait sonuçlar Şekil 4.7'de ve DeepLabv3+ semantik segmentasyon ağına ait örnek görüntü, tahmin ve maskeler Şekil 4.8'de verilmiştir. Şekil 4.5, Şekil 4.6 ve 4.7'de verilmiş olan orijinal maske görüntülerinde kırmızı renk benign ve beyaz renk malign akciğer tümörünü ifade etmektedir. Ek olarak Şekil 4.8'de orijinal maske görüntülerinde bulunan pudra rengi benign, fuşya ise malign akciğer tümörünü ifade etmektedir.




(a) Orijinal




(b) Önerilen Maske




(c) Orijinal



(d) Önerilen Maske



(e) Orijinal




(f) Önerilen Maske


Şekil 4.2 Veri Seti Versiyon-2 K Kanalı için Orijinal Görüntüler ve Tahmin Edilen Maskeler




(a) Orijinal




(b) Önerilen Maske




(c) Orijinal



(d) Önerilen Maske



(e) Orijinal




(f) Önerilen Maske


Şekil 4.3 Veri Seti Versiyon-2 P Kanalı için Orijinal Görüntüler ve Tahmin Edilen Maskeler




(a) Orijinal




(b) Önerilen Maske




(c) Orijinal



(d) Önerilen Maske



(e) Orijinal



(f) Önerilen Maske


Şekil 4.4 Veri Seti Versiyon-2 M Kanalı için Orijinal Görüntüler ve Tahmin Edilen Maskeler

Çizelge 4.3 Veri Setinin Üçüncü Versiyonu için Örnek Segmentasyonu Modellerinin Eğitim Sonuçları


	<i>AP- Benign</i>	<i>AP- Malign</i>	<i>mAP</i>	<i>IoU</i>	<i>Dice</i>
<i>Mask R-CNN</i>	%74,14	%60,17	%67,16	%75,60	%79,25
<i>YOLACT</i>	%77,40	%69,70	%73,54	%76,28	%81,89
<i>SOLOv2</i>	%62,89	%62,43	%62,70	%61,31	%73,15
<i>DeepLabv3+</i>	%58,69	%14,94	%36,81	%53,76	%59,28

Mimari sabit tutularak veri setinin farklı ayrımlarından gelen sonuçlar objektif olarak gözlenebilmiştir. Çizelge 4.1 ve Çizelge 4.3'te verilmiş olan Mask R-CNN mimarisinin sonuçlarına bakıldığında kanalların birleştirilmesiyle elde edilen üçüncü versiyon veri seti %2,45 mAP değeriyle daha yüksek başarı göstermiştir. Aradaki boşluk nesne sınıfı bazında değerlendirildiğinde benign tümörler için başarı %9,03 AP artarken malign sınıfı için bu değer %4,14 AP düşmüştür. Başarıyı yükseltmek amacıyla oluşturulan üçüncü versiyon veri setinin yapılan deneyler sonucunda AP- Benign ve mAP değerleri ile beklentiyi doğruladığı görülmüştür.


Literatürde daha başarılı tümör segmentasyonu için görüntünün tümör konumuna göre kırılması sıklıkla tercih edilmektedir. Ancak yeni tanı alacak pekçok tümör bahsi geçen görüntülerde sahip olduğu kadar büyük alan kaplamamaktadır. Bu sebeple çalışma kapsamında görüntüler tümöre göre kırılmamıştır ve bu işlem atlandığından elde edilen sonuçların benzerlerine göre düşük olması beklenen bir durumdur. Elde edilen değerler ile küçük nesne içeren veri setlerinin ön işlemsiz kodlayıcı-kod çözücü mimarileri beslemek için kullanılması önerilmemektedir. Bu tip mimarilerin kodlayıcı kısımlarında sürekli olarak aşağı örnekleme yapılmakta ve bu ise önemli bilgi kaybetmeye sebep olmaktadır. Nesne sınırlarının geniş olmaması kaybedilen her bilgiyi daha önemli kılmaktadır. Bu nedenle YOLACT gibi ayrıntıları yakalamakta daha başarılı olan modeller (Bolya ve diğ., 2019) kullanıldığında daha kaliteli çıktılar elde edilmektedir. Ek olarak daha düzgün sınırlara sahip benign tümörlerin (CCS, 2020b), dağınık şekilde görünen malign tümörlere (NHS, 2019) göre daha yüksek başarı gösterdiği Çizelge 4.1, Çizelge 4.2 ve Çizelge 4.3'te verilen sonuçlarda görülmektedir. Çünkü maskelerin doğrulukları hesaplanırken segmente edilmiş alan kullanılmaktadır. Tümörün yeri ve etiketi doğru olarak tahmin edilse dahi sınırlarının hatalı olması başarıyı etkilemektedir. Alanın dağınıklaşması ise sınırların gerçeğe yaklaşma olasılığını olumsuz etkilemektedir. Tümörün segmente edilmesinin tümör sınıfına göre yapılması başarıyı etkileyen diğer bir faktördür. Doğru segmente edilip yanlış sınıf etiketi atanan ya da doğru sınıf etiketine sahip ancak doğru sınırlar ile segmente




Şekil 4.5 Veri Seti Versiyon-3 için Mask R-CNN Mimarısının Ürettiği Orijinal Görüntüler, Maskeler ve Tahmin Edilen Maskeler




(a) Orijinal




(b) Orijinal Maske




(c) Önerilen Maske




(d) Orijinal




(e) Orijinal Maske




(f) Önerilen Maske




(g) Orijinal




(h) Orijinal Maske




(i) Önerilen Maske



(j) Orijinal




(k) Orijinal Maske




(l) Önerilen Maske


Şekil 4.6 Veri Seti Versiyon-3 için YOLACT Mimarısının Ürettiği Orijinal Görüntüler, Maskeler ve Tahmin Edilen Maskeler




(a) Orijinal




(b) Orijinal Maske




(c) Önerilen Maske




(d) Orijinal




(e) Orijinal Maske




(f) Önerilen Maske




(g) Orijinal




(h) Orijinal Maske




(i) Önerilen Maske



(j) Orijinal




(k) Orijinal Maske



(l) Önerilen Maske


Şekil 4.7 Veri Seti Versiyon-3 için SOLOv2 Mimarisinin Ürettiği Orijinal Görüntüler, Maskeler ve Tahmin Edilen Maskeler



(a) Orijinal




(b) Orijinal Maske




(c) Önerilen Maske




(d) Orijinal



(e) Orijinal Maske




(f) Önerilen Maske




(g) Orijinal



(h) Orijinal Maske




(i) Önerilen Maske



(j) Orijinal



(k) Orijinal Maske



(l) Önerilen Maske

Şekil 4.8 Veri Seti Versiyon-3 için DeepLabv3+ Mimarisinin Ürettiği Orijinal Görüntüler, Maskeler ve Tahmin Edilen Maskeler

edilememiş görüntüler de segmentasyon sonucunu olumsuz etkilemektedir. İleride veri setinin farklı ön işlemlere tabi tutulması ve daha güçlü GPU kullanımı ile modellerinin başarısının arttırılması ihtimal dahilindedir. Aynı zamanda kanalların ayrı ayrı eğitilerek üretilen sonuçların birleştirilmesi ya da görüntülere boyut azaltma işlemi uygulanmadan görüntüyü ızgaralara bölerek parça parça ele alacak şekilde ağı eğitmek daha güçlü maske tahmini sağlayabilir.



5. SONUÇ VE ÖNERİLER

Bu tezde akciğer tümör segmentasyonu için yeni ve gerçek MR görüntülerinden oluşan bir veri seti önerilmiştir. Veri seti, Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Hastanesi'nden sağlanmış ve dört kanallı MR görüntüsünün P, K ve M kanalı çalışmaya dahil edilmiştir. Veri seti toplam 84 farklı hastaya ait verileri içermektedir. Bu hastaların 32 tanesi benign tanısı, kalan 52 adeti malign tümörü tanısı almıştır. Veri seti toplam üç farklı versiyonda eğitilmiştir. İlk versiyon, veri setinin elde edildiği işlemsiz halidir. Her kanal farklı birer görüntü olarak veri setinde varlık göstermektedir. İkinci versiyon, görüntü kanallarını birbiri ile kıyaslamak için oluşturulmuştur. Bu amaçla veri seti üç alt parçaya bölünmüştür ve kanallar ayrı ayrı eğitilmiştir. Son versiyon ise kanalların birleşmesinin segmentasyon başarısını arttıracak hipotezi ile düzenlenmiştir. P, K ve M kanalları birleştirilerek üç kanallı yeni bir görüntü elde edilmiştir. Tüm versiyonların içerdiği görüntülere ait detaylar Çizelge 5.1'de verildiği gibidir.

Çizelge 5.1 Veri Setinin Birinci, İkinci ve Üçüncü Versiyonlarında Veri Dağılımı

		Benign	Malign	Eğitim	Doğrulama	Toplam
Versiyon-1		920	1113	1633	400	2033
Versiyon-2	P	306	370	546	130	676
	K	306	370	546	130	676
	M	306	370	546	130	676
Versiyon-3		307	373	543	137	680

Her versiyon, objektif olarak karşılaştırabilmek için aynı mimariyi ve sınıflandırıcıyı kullanarak eğitilmiştir. Bu görev için Mask R-CNN mimarisi ile ResNet-101 sınıflandırıcısı seçilmiştir. Yapılan deneyler doğrultusunda üçüncü versiyon veri seti ile %2,45 mAP daha yüksek sonuç elde edilmiş ve hipotezi doğrulamıştır. Ek olarak ikinci versiyonda her kanala ait set yine Mask R-CNN mimarisi ve ResNet-101 sınıflandırıcısı kullanarak eğitime tabi tutulmuştur. Alınan sonuçlara göre K kanalı görüntülerindeki tümörler %2,75 mAP ile P kanalı ve %3,79 mAP ile M kanalı görüntülerindeki tümörlerden daha başarılı segmente edilmiştir. Hesaplanan AP değerlerine göre K kanalı görüntüleri benign ve M kanalı görüntüleri malign tümörlerin segmente edilmesinde daha iyi sonuçlar vermiştir.

Son olarak veri setinin nihai versiyonunu eğitmek için Mask R-CNN'le beraber diğer popüler mimariler olan SOLOv2, YOLACT ve DeepLabv3+ mimarileri seçilmiştir. Bahsi geçen mimarilerden Mask R-CNN, SOLOv2 ve YOLACT örnek segmentasyon mimarileri ve DeepLabv3+ ise semantik segmentasyon mimarisidir. Ağları değerlendirmek için AP, mAP ve IoU metrikleri kullanılmıştır. En başarılı sonuç YOLACT mimarisi ile elde edilmiş ve alınan sonucun en yakını olan Mask R-CNN'den %6,30 mAP daha yüksek olduğu görülmüştür. Yapılan deneyler sonucunda yoğun şekilde aşağı örnekleme yapan modellerin küçük tümörleri doğru segmente etmek konusunda başarısının yeterli olmadığı görülmüştür. Benign tümörlerin düzgün sınırları sayesinde malign tümörlere oranla daha kolay segmente edildiği çıkarımları yapılmıştır.

Bu çalışmada literatürde bulunmayan akciğer benign ve malign tümör segmentasyonu görevine çözüm aranmıştır. Kullanılan veri seti çalışma kapsamında hazırlanmış olup gerçek tümörlerden oluşmaktadır. Veri setinin yeni oluşturulması ile bu çalışma, literatürdeki benzer çalışmalardan ayrılmıştır. Ek olarak literatürde bulunan birçok tümör segmente çalışmasında görüntüler tümör çevresinden kırılmaktadır. Bu ise görüntüde daha büyük tümör alanı yakalanmasını ve tümörün daha kolay segmente edilmesini sağlamaktadır. Bu çalışmada örnek segmentasyonu modellerine kırpma işlemi uygulanmamıştır.

KAYNAKLAR DİZİNİ

Anwar, Aqeel (2022). *What is Average Precision in Object Detection & Localization Algorithms and How to Calculate It?* URL: <https://towardsdatascience.com/what-is-average-precision-in-object-detection-localization-algorithms-and-how-to-calculate-it-3f330efe697b>. (Erişim Tarihi: 24.11.2022).

Ay, Şevket (2020). *Model Performansını Değerlendirmek — Metrikler*. URL: <https://medium.com/deep-learning-turkiye/model-performans%C4%B1n%C4%B1-de%C4%9Ferlendirmek-metrikler-cb6568705b1>. (Erişim Tarihi: 24.11.2022).

Baeldung (2022). *How ReLU and Dropout Layers*. URL: <https://www.baeldung.com/cs/ml-relu-dropout-layers#:~:text=As%20a%20consequence%2C%5C%20the%20usage,adding%20extra%20ReLUs%20increases%20linearly..> (Erişim Tarihi: 22.10.2022).

Bilyk, Volodymyr (2020). *Computer vision opportunities in Medical Imaging Explained*. URL: <https://volodymyrbilyk.medium.com/computer-vision-opportunities-in-medical-imaging-explained-9e046f9e2d88>. (Erişim Tarihi: 06.04.2022).

Biswal, Avijeet (2022). *Top 10 Deep Learning Algorithms You Should Know in 2023*. URL: <https://www.simplilearn.com/tutorials/deep-learning-tutorial/deep-learning-algorithm>. (Erişim Tarihi: 18.10.2022).

Bolya, Daniel, Chong Zhou, Fanyi Xiao ve Yong Jae Lee (2019). “Yolact: Real-time instance segmentation”. İçinde: *Proceedings of the IEEE/CVF international conference on computer vision*, ss. 9157–9166.

KAYNAKLAR DİZİNİ (devam)

Brooks, James W. ve Thomas M. Krummel (2006). “Chapter 50 - Tumors of the Chest”. İçinde: *Kendig's Disorders of the Respiratory Tract in Children (Seventh Edition)*. Ed. Victor Chernick, Thomas F. Boat, Robert W. Wilmott ve Andrew Bush. Seventh Edition. Philadelphia: W.B. Saunders, ss. 705–732. ISBN: 978-0-7216-3695-5. DOI: <https://doi.org/10.1016/B978-0-7216-3695-5.50054-7>. URL: <https://www.sciencedirect.com/science/article/pii/B9780721636955500547>.

Brown, Robert W., Yu-Chung N.Cheng, E. Mark Haacke, Micheal R. Thompson ve Ramesh Venkatesan (2014). *Magnetic Resonance Imaging: Physical Principles and Sequence Design*. New Jersey: Wiley Blackwell.

Caelen, Olivier (2017). “A Bayesian interpretation of the confusion matrix”. İçinde: *Annals of Mathematics and Artificial Intelligence* 81.3, ss. 429–450.

CCS (2020a). *Cancerous Tumours of The Lung*. URL: <https://cancer.ca/en/cancer-information/cancer-types/lung/what-is-lung-cancer/cancerous-tumours>. (Erişim Tarihi: 30.09.2022).

— (2020b). *Non-Cancerous Lung Tumours*. URL: <https://www.webmd.com/lung/benign-lung-tumors-and-nodules#:~:text=A%5C%20benign%5C%20lung%5C%20tumor%5C%20is,of%5C%20cancer%5C%20is%5C%20very%5C%20important..> (Erişim Tarihi: 29.09.2022).

Charles, Shamar (2019). *Tümör nedir? Benign ve Malign Tümörlerin Özellikleri ve Belirtileri*. URL: [https://www.verywellhealth.com/lung-neoplasms-definition-types-causes-and-treatment-5204884#:~:text=A%5C%20malignant%5C%20neoplasm%5C%20or%5C%20lung,the%5C%20body%5C%20\(metastatic%5C%20neoplasm\).](https://www.verywellhealth.com/lung-neoplasms-definition-types-causes-and-treatment-5204884#:~:text=A%5C%20malignant%5C%20neoplasm%5C%20or%5C%20lung,the%5C%20body%5C%20(metastatic%5C%20neoplasm).) (Erişim Tarihi: 05.08.2022).

KAYNAKLAR DİZİNİ (devam)

Chen, Liang-Chieh, George Papandreou, Iasonas Kokkinos, Kevin Murphy ve Alan L Yuille (2017). “Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs”. İçinde: *IEEE transactions on pattern analysis and machine intelligence* 40.4, ss. 834–848.

Chen, Liang-Chieh, Yukun Zhu, George Papandreou, Florian Schroff ve Hartwig Adam (2018). “Encoder-decoder with atrous separable convolution for semantic image segmentation”. İçinde: *Proceedings of the European conference on computer vision (ECCV)*, ss. 801–818.

Chen, Michael YM ve Christopher T Whitlow (2011). “Scope of diagnostic imaging”. İçinde: *Basic radiology. Pope TL, Ott DJ. 2nd ed, Lange. New York*, ss. 1–14.

Chollet, Francois (2018). *Deep learning mit python und keras: das praxis-handbuch vom entwickler der keras-bibliothek*. MITP-Verlags GmbH & Co. KG.

Csurka, Gabriela, Diane Larlus, Florent Perronnin ve France Meylan (2013). “What is a good evaluation measure for semantic segmentation?”. İçinde: *Bmvc*. C. 27. 2013. Bristol, ss. 10–5244.

Çakıcı, Emine (2019). *Tümör nedir? Benign ve Malign Tümörlerin Özellikleri ve Belirtileri*. URL: <https://www.medikalakademi.com.tr/tumor-nedir-benign-ve-malign-tumorlerin-ozellikleri-ve-belirtileri/>. (Erişim Tarihi: 05.08.2022).

Dumane, Govinda (2020). *Introduction to Convolutional Neural Network (CNN) using Tensorflow*. URL: <https://towardsdatascience.com/introduction-to-convolutional-neural-network-cnn-de73f69c5b83>. (Erişim Tarihi: 22.10.2022).

KAYNAKLAR DİZİNİ (devam)

Dutande, Prasad, Ujjwal Baid ve Sanjay Talbar (2022). “Deep Residual Separable Convolutional Neural Network for lung tumor segmentation”. İçinde: *Computers in Biology and Medicine* 141, s. 105161. ISSN: 0010-4825. DOI: <https://doi.org/10.1016/j.compbiomed.2021.105161>. URL: <https://www.sciencedirect.com/science/article/pii/S0010482521009550>.

Everingham, Mark, Luc Van Gool, Christopher KI Williams, John Winn ve Andrew Zisserman (2010). “The pascal visual object classes (voc) challenge”. İçinde: *International journal of computer vision* 88.2, ss. 303–338.

FDA (2020a). *Medical X-ray Imaging*. URL: <https://www.fda.gov/radiation-emitting-products/medical-imaging/medical-x-ray-imaging>. (Erişim Tarihi: 09.05.2022).

— (2020b). *Radiography*. URL: <https://www.fda.gov/radiation-emitting-products/medical-x-ray-imaging/radiography#:~:text=Radiography%5C%20is%5C%20a%5C%20type%5C%20of,fluoroscopy%5C%20and%5C%20computed%5C%20tomography%5C%20procedures..> (Erişim Tarihi: 03.10.2022).

Ferlay, Jacques, Hai-Rim Shin, Freddie Bray, David Forman, Colin Mathers ve Donald Maxwell Parkin (2010). “Estimates of worldwide burden of cancer in 2008: GLOBOCAN 2008”. İçinde: *International journal of cancer* 127.12, ss. 2893–2917.

Girshick, Ross, Jeff Donahue, Trevor Darrell ve Jitendra Malik (2014). “Rich feature hierarchies for accurate object detection and semantic segmentation”. İçinde: *Proceedings of the IEEE conference on computer vision and pattern recognition*, ss. 580–587.

KAYNAKLAR DİZİNİ (devam)

Girshick, Ross, Ilija Radosavovic, Georgia Gkioxari, Piotr Dollár ve Kaiming He (2018). *Detectron*. <https://github.com/facebookresearch/detectron>.

Gonzalez, Rafael C. ve Richard E. Woods (2008). *Digital Image Processing*. USA: Pearson Prentice Hall.

Guindon, Bert ve Ying Zhang (2017). “Application of the dice coefficient to accuracy assessment of object-based image classification”. İçinde: *Canadian Journal of Remote Sensing* 43.1, ss. 48–61.

Haqq, M. Gadal (2016). *Digital Image Processing: Introduction*. <https://www.slideshare.net/MostafaGMMostafa/digital-image-processing-an-introduction>. (Erişim Tarihi: 04.10.2022).

Hassan, Zubait (2022). *Instance Segmentation Vs. Object Detection: 3 Things You Need To Know*. URL: <https://www.folio3.ai/blog/instance-segmentation-vs-object-detection/>. (Erişim Tarihi: 24.10.2022).

He, Kaiming, Georgia Gkioxari, Piotr Dollár ve Ross Girshick (2017). “Mask r-cnn”. İçinde: *Proceedings of the IEEE international conference on computer vision*, ss. 2961–2969.

Herrera, Luis J, Hiran C Fernando, Yaron Perry, William E Gooding, Percival O Buenaventura, Neil A Christie ve James D Luketich (2003). “Radiofrequency ablation of pulmonary malignant tumors in nonsurgical candidates”. İçinde: *The Journal of Thoracic and Cardiovascular Surgery* 125.4, ss. 929–937.

KAYNAKLAR DİZİNİ (devam)

Hofmann, Hans-Stefan, Gesine Hansen, Stefan Burdach, Babett Bartling, Rolf-Edgar Silber ve Andreas Simm (2004). “Discrimination of human lung neoplasm from normal lung by two target genes”. İçinde: *American journal of respiratory and critical care medicine* 170.5, ss. 516–519.

Howard, Andrew G, Menglong Zhu, Bo Chen, Dmitry Kalenichenko, Weijun Wang, Tobias Weyand, Marco Andreetto ve Hartwig Adam (2017). “Mobilenets: Efficient convolutional neural networks for mobile vision applications”. İçinde: *arXiv preprint arXiv:1704.04861*.

HSGM (2017). *Computer vision opportunities in Medical Imaging Explained*. URL: <https://hsgm.saglik.gov.tr/tr/kanser-turleri/kanser-turleri/akci%5C%C4%5C%9Fer-kanseri.html>. (Erişim Tarihi: 21.09.2022).

Karayeğen, Gökay (2021). “Segmentation on brain MR images by using deep learning network and 3d modelling”. İçinde.

Klingler, Nico (2022). *Image Segmentation with Deep Learning*. URL: <https://viso.ai/deep-learning/image-segmentation-using-deep-learning/>. (Erişim Tarihi: 24.10.2022).

Kookna, Vikas (2022). *Semantic vs. Instance vs. Panoptic Segmentation*. URL: <https://pyimagesearch.com/2022/06/29/semantic-vs-instance-vs-panoptic-segmentation/>. (Erişim Tarihi: 24.11.2022).

Lauterbur - *Facts Nobel Prize Outreach* (2022). URL: <https://www.nobelprize.org/prizes/medicine/2003/lauderbur/facts/>. (Erişim Tarihi: 24.05.2022).

KAYNAKLAR DİZİNİ (devam)

- Li, Jiaxin, Houjin Chen, Yanfeng Li, Yahui Peng, Naxin Cai ve Xuyang Cao (2021). “AMRSegNet: adaptive modality recalibration network for lung tumor segmentation on multi-modal MR images”. İçinde: *Multimedia Tools and Applications* 80.25, ss. 33779–33797.
- Li, Jiaxin, Houjin Chen, Yanfeng Li, Yahui Peng, Jia Sun ve Pan Pan (2022). “Cross-modality synthesis aiding lung tumor segmentation on multi-modal MRI images”. İçinde: *Biomedical Signal Processing and Control* 76, s. 103655.
- Lin, Tsung-Yi, Priya Goyal, Ross Girshick, Kaiming He ve Piotr Dollár (2017). “Focal loss for dense object detection”. İçinde: *Proceedings of the IEEE international conference on computer vision*, ss. 2980–2988.
- Lin, Tsung-Yi, Michael Maire, Serge Belongie, James Hays, Pietro Perona, Deva Ramanan, Piotr Dollár ve C Lawrence Zitnick (2014). “Microsoft coco: Common objects in context”. İçinde: *European conference on computer vision*. Springer, ss. 740–755.
- Liu, Yanfeng (2018). *The Confusing Metrics of AP and mAP for Object Detection / Instance Segmentation*. URL: <https://yanfengliux.medium.com/the-confusing-metrics-of-ap-and-map-for-object-detection-3113ba0386ef>. (Erişim Tarihi: 24.11.2022).
- Mitchell, Tom M ve Tom M Mitchell (1997). *Machine learning*. C. 1. 9. McGraw-hill New York.
- Mohri, Mehryar, Afshin Rostamizadeh ve Ameet Talwalkar (2018). *Foundations of machine learning*. MIT press.

KAYNAKLAR DİZİNİ (devam)

Moradi, Elaheh, Antonietta Pepe, Christian Gaser, Heikki Huttunen, Jussi Tohka, Alzheimer's Disease Neuroimaging Initiative ve diğ. (2015). "Machine learning framework for early MRI-based Alzheimer's conversion prediction in MCI subjects". İçinde: *Neuroimage* 104, ss. 398–412.

Müller, Andreas C ve Sarah Guido (2016). *Introduction to machine learning with Python: a guide for data scientists.* " O'Reilly Media, Inc."

Müller, Dominik ve Frank Kramer (2021). "MIScnn: a framework for medical image segmentation with convolutional neural networks and deep learning". İçinde: *BMC medical imaging* 21.1, ss. 1–11.

NCI (2022). *Cancer Stat Facts*. URL: <https://seer.cancer.gov/statfacts/>. (Erişim Tarihi: 30.09.2022).

NHS (2019). *Lung Cancer*. URL: <https://www.nhs.uk/conditions/lung-cancer/>. (Erişim Tarihi: 30.09.2022).

O'Shea, Keiron ve Ryan Nash (2015). "An introduction to convolutional neural networks". İçinde: *arXiv preprint arXiv:1511.08458*.

Otterlo, Martijn van ve Marco Wiering (2012). "Reinforcement Learning and Markov Decision Processes". İçinde: *Reinforcement Learning: State-of-the-Art*. Ed. Marco Wiering ve Martijn van Otterlo. Berlin, Heidelberg: Springer Berlin Heidelberg, ss. 3–42. ISBN: 978-3-642-27645-3. DOI: 10.1007/978-3-642-27645-3_1. URL: https://doi.org/10.1007/978-3-642-27645-3_1.

KAYNAKLAR DİZİNİ (devam)

Padilla, Rafael, Sergio Netto ve Eduardo da Silva (Tem. 2020). “A Survey on Performance Metrics for Object-Detection Algorithms”. İçinde: DOI: 10.1109/IWSSIP48289.2020.

Padma, T, Ch Usha Kumari, Dommeti Yamini, Kapilavai Pravallika, Konduru Bhargavi ve Mula Nithya (2022). “Image Segmentation using Mask R-CNN for Tumor Detection from Medical Images”. İçinde: *2022 International Conference on Electronics and Renewable Systems (ICEARS)*. IEEE, ss. 1015–1021.

Paszke, Adam, Sam Gross, Soumith Chintala, Gregory Chanan, Edward Yang, Zachary DeVito, Zeming Lin, Alban Desmaison, Luca Antiga ve Adam Lerer (2017). “Automatic differentiation in PyTorch”. İçinde.

Rana, Kartikeya (2020). *Pooling Layer — Short and Simple*. URL: <https://ai.plainenglish.io/pooling-layer-beginner-to-intermediate-fa0dbdce80eb>. (Erişim Tarihi: 22.10.2022).

Ren, Shaoqing, Kaiming He, Ross Girshick ve Jian Sun (2015). “Faster r-cnn: Towards real-time object detection with region proposal networks”. İçinde: *Advances in neural information processing systems* 28.

Schütze, Hinrich, Christopher D Manning ve Prabhakar Raghavan (2008). *Introduction to information retrieval*. C. 39. Cambridge University Press Cambridge.

Sheremet, Oleksii (2020). *Intersection over union (IoU) calculation for evaluating an image segmentation model*. URL: <https://towardsdatascience.com/intersection-over-union-iou-calculation-for-evaluating-an-image-segmentation-model-8b22e2e84686>. (Erişim Tarihi: 24.11.2022).

KAYNAKLAR DİZİNİ (devam)

Solaguren-Beascoa, Ana (2020). *Active Learning in Machine Learning*. URL: <https://towardsdatascience.com/active-learning-in-machine-learning-525e61be16e5>. (Erişim Tarihi: 14.10.2022).

Solawetz, Jacob (2020). *How to Train Detectron2 on Custom Object Detection Data*. (Erişim Tarihi: 03.05.2022).

Stuart, Annie (2021). *Benign Lung Tumors and Nodules*. URL: <https://www.webmd.com/lung/benign-lung-tumors-and-nodules#:~:text=A%5C%20benign%5C%20lung%5C%20tumor%5C%20is,of%5C%20cancer%5C%20is%5C%20very%5C%20important..> (Erişim Tarihi: 29.09.2022).

Subagja, Iwan (Eyl. 2019). “Integrating Big Data with Medical Imaging”. İçinde: *International Journal of Engineering and Advanced Technology* 8, s. 722. DOI: 10.35940/ijeat.F1133.0986S319.

Subramanyam, Vineeth (2021). *IOU (Intersection over Union)*. URL: <https://medium.com/analytics-vidhya/iou-intersection-over-union-705a39e7acef>. (Erişim Tarihi: 24.11.2022).

Suetens, Paul (2009). *Fundamentals of Medical Imaging*. The Edinburgh Building, Cambridge CB2 8RU, UK: Cambridge University Press.

SuperAnnotate (2021). *Complete Guide to Semantic Segmentation*. URL: <https://blog.superannotate.com/guide-to-semantic-segmentation/>. (Erişim Tarihi: 24.10.2022).

KAYNAKLAR DİZİNİ (devam)

Temiz, Göktan ve Suat Gezer (2016). “Pulmoner Kistik Hamartom.” İçinde: *Respiratory Case Reports* 5.1.

VainF (2022). *DeepLabv3Plus-Pytorch*. URL:
<https://github.com/VainF/DeepLabV3Plus-Pytorch>. (Erişim Tarihi: 29.07.2022).

Van Rossum, Guido ve Fred L Drake Jr (1995). *Python reference manual*. Centrum voor Wiskunde en Informatica Amsterdam.

Wada, Kentaro (2018). *labelme: Image Polygonal Annotation with Python*.
<https://github.com/wkentaro/labelme>.

Wang, Chuang, Neelam Tyagi, Andreas Rimner, Yu-Chi Hu, Harini Veeraraghavan, Guang Li, Margie Hunt, Gig Mageras ve Pengpeng Zhang (2019). “Segmenting lung tumors on longitudinal imaging studies via a patient-specific adaptive convolutional neural network”. İçinde: *Radiotherapy and Oncology* 131, ss. 101–107.

Wang, Xinlong, Rufeng Zhang, Tao Kong, Lei Li ve Chunhua Shen (2020). “Solov2: Dynamic and fast instance segmentation”. İçinde: *Advances in Neural information processing systems* 33, ss. 17721–17732.

Worp, Wouter RPH van de, Brent van der Heyden, Georgios Lappas, Ardy van Helvoort, Jan Theys, Annemie MWJ Schols, Frank Verhaegen ve Ramon CJ Langen (2021). “Deep learning based automated orthotopic lung tumor segmentation in whole-body mouse CT-scans”. İçinde: *Cancers* 13.18, s. 4585.

KAYNAKLAR DİZİNİ (devam)

Zacharaki, Evangelia I, Sumei Wang, Sanjeev Chawla, Dong Soo Yoo, Ronald Wolf, Elias R Melhem ve Christos Davatzikos (2009). “Classification of brain tumor type and grade using MRI texture and shape in a machine learning scheme”. İçinde: *Magnetic Resonance in Medicine: An Official Journal of the International Society for Magnetic Resonance in Medicine* 62.6, ss. 1609–1618.

