

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

EKO GÖRÜNTÜLERİNDE DERİN ÖĞRENME TABANLI AORT KAPAK İLGİ
BÖLGESİ VE KALSİFİKASYON TESPİTİ

YÜKSEK LİSANS TEZİ

Mervenur ÇAKIR

HAZİRAN 2024
TRABZON



**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**EKO GÖRÜNTÜLERİNDE DERİN ÖĞRENME TABANLI AORT KAPAK İLĞİ
BÖLGESİ VE KALSİFİKASYON TESPİTİ**

Mervenur ÇAKIR

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"BİLGİSAYAR YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih : 21/05/2024
Tezin Savunma Tarihi : 11/06/2024**

Tez Danışmanı : Prof.Dr. Murat EKİNCİ

Trabzon 2024

ÖNSÖZ

Bu tez, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Bilimleri Yüksek Lisans Programı'nda yapılan bir çalışmadır. “Eko Görüntülerinde Derin Öğrenme Tabanlı Aort Kapak İlgili Bölgesi ve Kalsifikasyon Tespiti” adlı çalışmada, TÜBİTAK projesi kapsamında kalpteki aort bölgesi ve bu bölgede bulunan kalsifik alanlara ait görüntülerden oluşturulan veri seti kullanılmıştır. Aort bölgesi yapay zeka kullanılarak belirlenmiş ve ilgili bölgede bulunan kalsifik alanlar çeşitli makine öğrenmesi ve derin öğrenme yöntemleriyle tespit edilmiştir. Elde edilen sonuçlar karşılaştırılarak tanıma ve segmentasyon başarısının artırılması için güncel yaklaşımlar ve bu yaklaşımların segmentasyon performansına olan etkileri araştırılmıştır.

Tez çalışması süresince bana her zaman ufuk katan ve desteğini esirgemeyen danışman hocam Prof. Dr. Murat EKİNCİ'ye tavsiye ve tecrübeleri ile bana yol gösterdiği için teşekkür ediyorum. Ayrıca tez sürecim boyunca tüm aşamalarda bana yardımını hiçbir zaman eksik etmeyen hocam Dr. Öğr. Üyesi Elif BAYKAL KABLAN'a çok teşekkür ederim. Tezimin gerçekleşmesinde 222S110 numaralı proje ile maddi olarak beni destekleyen Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK)'a teşekkür etmeyi bir borç bilirim. Son olarak her koşulda yanımda olan anneme, babama ve kardeşlerime en içten sevgi, saygı ve teşekkürlerimi sunarım

Bu tezin bundan sonraki çalışmalara katkı sağlaması temennisiyle.

Mervenur ÇAKIR

Trabzon 2024

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum "Eko Görüntülerinde Derin Öğrenme Tabanlı Aort Kapak İlgili Bölgesi ve Kalsifikasyon Tespiti" başlıklı bu çalışmayı baştan sona kadar danışmanım Prof.Dr. Murat EKİNCİ'nin sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 11/06/2024

Mervenur ÇAKIR

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ	X
TABLolar DİZİNİ.....	XII
SEMBOLLER DİZİNİ	XIV
1. GENEL BİLGİLER	1
1.1. Giriş	1
1.1.1. Aort Darlığı.....	1
1.1.2. Kalp Kapakçıklarında Kireçlenme	2
1.1.3. Kalp Kapakçıklarında Kireçlenmenin Teşhis ve Tanı Süreci	3
1.1.4. Ultrason ve Bilgisayarlı Tomografi ile Görüntüleme	3
1.1.5. Otomatik Aort Kapak Tespiti.....	4
1.2. Tezin Kapsamı	7
1.3. Tezin Katkıları	8
1.4. Kalp Aort İlgili Bölgesinin Algılanması	9
1.5. Aort İlgili Bölgesinin Otomatik Tespitinde Kullanılan Yöntemler	10
1.5.1. Modern Konvolüsyonel Nesne Algılayıcılar	11
1.6. YOLOv5 (You Only Look Once - Version5) ile Nesne Algılama	14
1.6.1. CSPNet Özellik Çıkarıcı.....	17
1.6.2. Özellik Piramit Ağı (FPN).....	18
1.6.3. Yığın (Batch) Normalizasyon	18
1.6.4. Mish Aktivasyon Fonksiyonu	20
1.7. Makine Öğrenmesi Yöntemlerine Dayalı Görüntü Segmentasyonu	21
1.7.1. K-En Yakın Komşuluk Algoritması	21
1.7.2. Rastgele Ormanlar Sınıflandırıcısı	23

1.7.3. Uyarlanabilir Güçlendirme (AdaBoost)	25
1.7.4. Balanced Bagging (Dengeli Torbalama)	27
1.8. Derin Öğrenme Yöntemlerine Dayalı Görüntü Segmentasyonu.....	28
1.8.1. U-NET.....	28
1.8.2. SegNet	33
1.8.3. FCN	35
2. YAPILAN ÇALIŞMALAR	37
2.1. Ekokardiyografi Görüntülerinde Aort İlgili Bölgesinin Algılanması	39
2.1.1. Nesne Algılama İçin Aort Kapağı Veri Setinin Hazırlanması	39
2.1.2. Önerilen Yöntemin (AVD-YOLOv5) Ağ Mimarisi	42
2.1.3. Küçük Ölçekli Tespit Bileşeninin (Ölçek 1) Kafadan Çıkarılması	42
2.1.4. Standart Konvolüsyonların CSP Bloklarında Derinlemesine Ayrılabilir Konvolüsyonlarla Değiştirilmesi	44
2.1.5. K-Ortalamalar Algoritması Kullanılarak Aort Kapakçığı Tespit Görevi İçin En İyi Çapa Kutularının Oluşturulması	46
2.1.6. Deneysel Çalışmalar.....	47
2.1.7. Eğitim Detayları.....	52
2.2. Aort Bölgesinde Bulunan Kalsifik Alanların Otomatik Segmentasyonu.....	53
2.2.1. Kalsifik Alan Segmentasyonu İçin Aort Kapağı Veri Setinin Hazırlanması	54
2.2.2. Makine Öğrenmesi Yöntemlerine Dayalı Kalsifik Alan Segmentasyonu	56
2.2.3. Derin Öğrenme Yöntemlerine Dayalı Kalsifik Alan Segmentasyonu..	59
2.3. Eğitim Detayları	60
2.4. Değerlendirme Metrikleri	61
3. BULGULAR VE İRDELEME	63
3.1. Kalp Kapakçıklarında Kireçlenmenin Tespiti için Derin Öğrenmeye Dayalı Yaklaşımların Analizi ve Elde Edilen Deneysel Sonuçlar	63
3.1.1. Önerilen AVD-YOLOv5 Modelinin Aort Bölgesi Tespitine Etkisi	63
3.1.2. Uygulanan Makine Öğrenmesi Yöntemlerinin Kalsifikasyon Segmentasyonu Performansı.....	66
3.1.3. Uygulanan Derin Ağ Mimarisinin Kalsifikasyon Segmentasyonu Performansı Üzerindeki Etkisi.....	67

3.1.4. Önerilen AVD-YOLOv5 Yönteminin Literatürdeki Diğer Yöntemlerle Karşılaştırılması	69
3.2. Aort Bölgesinde Bulunan Kalsifik Alanların Derin Öğrenme Yöntemlerine Dayalı Otomatik Tespiti Yaklaşımının Analizi ve Elde Edilen Deneysel Sonuçlar	70
3.2.1. Ağ Derinliğinin Segmentasyon Performansı Üzerindeki Etkisi	70
3.2.2. Veri Setine Tüm verilerin Eklenmesi	71
4. SONUÇLAR	74
5. ÖNERİLER VE TARTIŞMA	76
6. KAYNAKLAR.....	77
7. EKLER	82
ÖZGEÇMİŞ	

ÖZET

EKO GÖRÜNTÜLERİNDE DERİN ÖĞRENME TABANLI AORT KAPAK İLGİ
BÖLGESİ VE KALSİFİKASYON TESPİTİ

Mervenur ÇAKIR

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof.Dr. Murat EKİNCİ
2024, 81 Sayfa, 2 Sayfa Ek

Kalp hastalıklarının otomatik tespiti, kardiyologların ekokardiyografi görüntülerini kullanarak teşhis doğruluğunu artırmak ve teşhis süresini azaltmak için önemlidir. Aort darlığı, kalp hastalıklarının temelini oluşturur ve kalbin aort bölgesinde kalsifik alanların oluşmasıyla gelişir. Yüksek çözünürlüklü BT görüntüleme yaygın olsa da, maliyet ve radyasyon riskleri alternatif yaklaşımları gerekli kılar. Bu nedenle, ultrason görüntüleme tercih edilmektedir. Tez çalışmasında, BT görüntülemeye gerek kalmadan ekokardiyografi görüntüleri üzerinde aort bölgesinin ve kalsifik alanların otomatik tespiti gerçekleştirilmiştir. AVD-YOLOv5 adlı yeni bir hafif model önerilmiştir. Bu model, YOLOv5 mimarisinde geliştirmeler içermekte olup, doğruluk oranı %94,3 ve hassasiyet oranı %86,8 olarak bulunmuştur. Ayrıca, çıkarım süresi %67 oranında azalmıştır. Sonraki adım olarak, tam evrişimli bir sinir ağı ile aort kapak bölgesinde bulunan kalsifik alanları tespit etmek amaçlanmıştır. Bu yöntemle, aort kapak kalsiyum skoru daha objektif, hızlı, kolay, maliyetsiz ve radyasyonsuz bir şekilde hesaplanabilecektir. Yeni veri seti üzerinde %86,3 doğruluk, %80,27 hassasiyet, %76,27 dice katsayısı ve %61,9 Jaccard indeksi elde edilmiştir. Sonuçlar, yöntemin uygulanabilirliğini ve etkinliğini göstermektedir. Önerilen sistem, kardiyologlar tarafından daha verimli ve güvenilir teşhis için kullanılabilir.

Anahtar Kelimeler: Ultrason görüntüleme, Ekokardiyografi, Aort kapağı, Nesne algılama, Derinlik bazlı ayrılabilir konvolüsyon, YOLOv5, Kalsifik alan tespiti, Segmentasyon, Makine öğrenmesi, K-NN, Rastgele Ormanlar, AdaBoost, Dengesiz Torbalama (Balanced Bagging), Derin öğrenme, UNET, SegNet, FCN.

Master Thesis

SUMMARY

DEEP LEARNING BASED AORTIC VALVE REGION OF INTEREST AND
CALCIFICATION DETECTION IN ECHO IMAGES

Mervenur ÇAKIR

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Department of Computer Engineering Graduate Program
Supervisor: Prof.Dr. Murat EKİNCİ
2024, 81 Pages, 2 Pages Appendix

The automatic detection of heart diseases is crucial for increasing diagnostic accuracy and reducing diagnosis time for cardiologists using echocardiography images. Aortic stenosis is a fundamental heart condition that develops with the formation of calcified areas in the aortic region. While high-resolution CT imaging is common, its cost and radiation risks necessitate alternative approaches, making ultrasound imaging preferable. In this thesis, the automatic detection of the aortic region and calcified areas on echocardiography images was performed without the need for CT imaging. A new lightweight model called AVD-YOLOv5 was proposed. This model includes improvements to the YOLOv5 architecture and achieved an accuracy of 94.3% and a sensitivity of 86.8%, with a 67% reduction in inference time. The next step involved using a fully convolutional neural network to detect calcified areas in the aortic valve region. This method allows for the aortic valve calcium score to be calculated more objectively, quickly, easily, cost-effectively, and without radiation. On a new dataset, the method achieved 86.3% accuracy, 80.27% sensitivity, a dice coefficient of 76.27%, and a Jaccard index of 61.9%. These results demonstrate the applicability and potential effectiveness of the method. The proposed system can be used by cardiologists for more efficient and reliable diagnosis.

Key Words: Ultrasound imaging, Echocardiography, Aortic valve, Object detection, Depth-based separable convolution, YOLOv5, Calcific area detection, Segmentation, Machine learning, K-NN, Random Forest, AdaBoost, Balanced Bagging, Deep learning, UNET, SegNet, FCN.

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Kalsifikasyon skoru ölçüm aşamaları	2
Şekil 2. Kalp kasının sistol ve diyastol evreleri sırasında normal ve kalsifik aort kapağının (a) modelleme yapılarak (drzezo, 2022), (b) ekokardiyografi görüntüleri üzerinde gösterimi	4
Şekil 3. Tez kapsamı	7
Şekil 4. YOLOv5 nesne algılayıcı mimarisi	16
Şekil 5. FPN (a) ve PANet (b) özellik çıkarma modüllerinin yapısı.....	18
Şekil 6. Mish aktivasyon fonksiyonu	20
Şekil 7. K-En yakın Komşuluk Algortimasının Çalışma Prensibi.....	22
Şekil 8. Rastgele Orman Algortimasının Çalışma Prensibi	24
Şekil 9. AdaBoost algortimasının çalışma prensibi	26
Şekil 10. Balanced Bagging algortimasının çalışma prensibi	27
Şekil 11. UNET mimarisi.....	34
Şekil 12. SegNET mimarisi.....	35
Şekil 13. FCN mimarisi	35
Şekil 14. Farklı durumları gösteren bazı örnek ekokardiyografi görüntüleri (a) diyastol, (b) sistol, (c) normal (kalsifik olmayan) doku ve (d) anormal (kalsifik) doku	40
Şekil 15. Ekokardiyografi görüntüsünde uzman kardiyolog tarafından aort kapağı bölgesinin etiketlenmesi	41
Şekil 16. Önerilen AVD-YOLOv5 modelinin genel mimarisi. CSP'de derinlik-bazlı ayrılabilir konvolüsyon (DS-Conv) ve dolayısıyla derinlik-bazlı konvolüsyon (DW_Conv) ve nokta-bazlı konvolüsyondan (PW_Conv) oluşan CBL blokları kullanır.	43

Şekil 17.	3×3 çekirdekli ve 3 giriş kanallı standart konvolüsyon, 3×3×3 (koyu mavi) giriş değerlerinden 6 çıkış kanallı 6 renkli çıkışa projeksiyonu gösterir. 3×3 çekirdekli ve 3 giriş kanallı derinlik ayrıştırılabilir konvolüsyonda, bir derinlik konvolüsyonu her giriş kanalının 3×3 pikselini, karşılık gelen bir çıkış pikseline (eşleşen renkler) yansıtır. 1×1 noktasal konvolüsyon daha sonra 6 nihai çıkış pikselini belirlemek için bu 3 çıkış pikselini kullanır.	45
Şekil 18.	Derinlik (a) ve kanal genişliği (b) parametrelerinin ağ yapısı üzerindeki etkisi	49
Şekil 19.	Konvolüsyon katmanındaki kanal sayısının (a) ve CSP BottleNeck bloklarının sayısının (b) ağ yapısı üzerindeki etkisi	51
Şekil 20.	Aort kapak kalsifikasyon bölge sınırlarının piksel etiket türü yardımıyla etiketlenmesi.....	54
Şekil 21.	Manuel etiketleme ve otomatik etiketleme sonuçlarının birleştirilmesi (Yeşil etiketli olan bölgeler kardiyolog tarafından manuel olarak işaretlenen, mavi etiketli bölgeler ise piksellerin parlaklık değerleri göz önüne alınarak, bilgisayar tarafından önerilerek işaretlenen bölgelerdir)	55
Şekil 22.	Piksel etiket türü ile etiketlenmiş aort kapak kalsifikasyon bölge sınırları	56
Şekil 23.	AVD-YOLOv5 ile algılanan aort ilgi bölgesinin gösterimi. Kırmızı kutular uzman kardiyologlar tarafından belirlenen, yeşil kutular ise AVD-YOLOv5 modelinin tespit ettiği aort ilgi bölgesi sınırlarını göstermektedir.....	64
Şekil 24.	Orijinal YOLOv5 modelinin eğitim (ilk satır) ve validasyon (ikinci satır) kümelerine ait sınır kutusu hatası(box loss), nesnellik hatası(obj loss), kesinlik ve duyarlılık değerlerinin zamanla değişimini gösteren grafikler	65
Şekil 25.	Önerilen AVD-YOLOv5 modelinin eğitim (ilk satır) ve validasyon (ikinci satır) kümelerine ait sınır kutusu hatası(box loss), nesnellik hatası(obj loss), kesinlik ve duyarlılık değerlerinin zamanla değişimini gösteren grafikler	66
Şekil 26.	(a) Orijinal girdi görüntüsü, (b) temel gerçeklik maskesi ve (c) UNET ile model eğitiminden sonra oluşturulan tahmini maske.....	68
Şekil 27.	Kalsifik (a satırı) ve kalsifik olmayan (b satırı) görüntülere ait temel gerçeklik maskeleri (1. sütun) ve sırasıyla 2, 3, 4, 5 ve 6. sütun, tablo 16'de belirtilen 1, 2, 3, 4 ve 5 numaralı veri setleri kullanılarak eğitilen UNET modelinin ürettiği tahmin maskeleri	73

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 2. Farklı CSP modül yapılarından oluşan YOLOv5 alt versiyonlarının ağ derinliği karşılaştırması	17
Tablo 3. K-ortalamlar kümeleme algoritması kullanılarak aort kapağı tespiti için varsayılan çapa kutuları ve oluşturulan çapa kutuları.....	47
Tablo 4. YOLOv5-s modelinden küçük ölçeğin kaldırılmasının performans üzerindeki etkisi	48
Tablo 5. Ağ mimarisinde derinlik parametresi değişiminin performansa etkisi ...	49
Tablo 6. Ağ mimarisinde kanal genişliği parametresi değişiminin performansa etkisi	50
Tablo 7. Konvolüsyon katmanında bulunan kanal sayısını değişiminin performansa etkisi	51
Tablo 8. Ağ mimarisinde CSP-Bottleneck katman sayısı değişiminin performansa etkisi	52
Tablo 9. Ağ mimarisinde kullanılan konvolüsyon yönteminin performansa etkisi	52
Tablo 10. Önerilen AVD-YOLOv5 modelinin dört YOLOv5 modeli alt versiyonu ile performans karşılaştırması	64
Tablo 11. Aort ilgi bölgesine odaklanarak ve odaklanmadan yapılan model eğitimlerinin performans karşılaştırması	66
Tablo 12. Kalsifik alanların segmentasyonu amacıyla kullanılan makine öğrenmesine dayalı yöntemlerin performans karşılaştırması	67
Tablo 13. Önerilen veri kümesi üzerinde üç derin öğrenme modelinin performans karşılaştırması.	67
Tablo 14. Önerilen AVD-YOLOv5 modelinin literatürdeki benzer çalışmalarla performans karşılaştırması.....	69
Tablo 15. Önerilen mimari üzerinde katman derinliği değişiminin modelin performansına etkisi	71
Tablo 16. Kalsifik alan bulunduran ve bulundurmeyan görüntülerden oluşan veri seti varyasyonları	71

Tablo 17. Oluřturulan veri seti varyasyonlarının performans karşılařtırma sonuçları 72



SEMBOLLER DİZİNİ

<i>AdaBoost</i>	: Uyarlanabilir Güçlendirme (Adaptive Boosting)
<i>AVD</i>	: Aort Kapağı Tespiti (Aort Valve Detection)
<i>BB</i>	: Dengesiz Kümeleme (Balanced Bagging)
<i>BN</i>	: Yığın Normalizasyonu (Batch Normalization)
<i>BT</i>	: Bilgisayarlı Tomografi
<i>CAD</i>	: Bilgisayar Destekli Tanı (Computer Aided Diagnosis)
<i>CNN</i>	: Konvolüsyonel Sinir Ağları (Convolutional Neural Networks)
<i>Conv</i>	: Konvolüsyon (convolution)
<i>CSPNet</i>	: Çapraz Aşamalı Kısmi Ağ (Cross Stage Partial Network)
<i>Daha Hızlı R – CNN</i>	: Daha Hızlı Bölge Tabanlı Konvolüsyonel Sinir Ağları
<i>DN</i>	: Doğru Negatif
<i>DP</i>	: Doğru Pozitif
<i>DP</i>	: Dijital Patoloji
<i>DS – Conv</i>	: Derinlik Bazlı Ayrılabilir Konvolüsyon (Depth-wise Seperable Convolution)
<i>DVM</i>	: Destek Vektör Makineleri
<i>DW – Conv</i>	: Derinlik Bazlı Konvolüsyon (Depth-wise Convolution)
<i>FC</i>	: Tam-bağlı
<i>FCN</i>	: Tam Konvolüsyonel Ağ (Fully Convolutional Network)
<i>FCNN</i>	: Tam Konvolüsyonel Sinir Ağları (Fully Convolutional Neural Networks)
<i>FPN</i>	: Özellik Piramit Ağı (Feature Pyramid Network)
<i>GFLOPs</i>	: Saniyede Yapılan Bir Milyon Çarpma İşlemi Sayısı (One Billion Floating-Point Operations Per Second)
<i>GPU</i>	: Grafik İşleme Birimi (Graphics Processing Unit)
<i>Hızlı R – CNN</i>	: Hızlı Bölge Tabanlı Konvolüsyonel Sinir Ağları
<i>IoU</i>	: Birleşimlerin Kesişimi (Intersection over Union)

$K - NN$	: K - En Yakın Komşuluk (K Nearest Neighbour)
mAP	: Ortalama Doğrulukların Ortalaması (Mean Average Precision)
NMS	: Maksimum Olmayanı Bastırma (Non-maximum Suppression)
$PANet$	: Yol Toplama Ağı (Path Aggregation Network)
$PW - Conv$	: Nokta Bazlı Konvolüsyon (Point-wise Convolution)
$R - CNN$	: Bölge Tabanlı Konvolüsyonel Sinir Ağları (Region-based Convolutional Neural Networks)
$ReLU$	: Doğrultulmuş Doğrusal Birim (Rectified Linear Unit)
$R - FCN$	: Bölge Tabanlı Tam Konvolüsyonel Ağlar (Region-based Fully Convolutional Networks)
ROI	: İlgi Bölgesi (Region of Interest)
RPN	: Bölge Önerme Ağı (Region Proposal Network)
SSD	: Tek Atış Çoklu Kutu Algılayıcı (Single Shot Multibox Detector)
YN	: Yanlış Negatif
$YOLO$	: Yalnızca Bir Kez Bakarsın (You Only Look Once)
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları


1. GENEL BİLGİLER

1.1. Giriş

1.1.1. Aort Darlığı

Aort darlığı, gelişmiş ülkelerde, özellikle yaşlı nüfusta en sık karşılaşılan kalp kapak hastalığıdır (Iung & Vahanian, 2011; Osnabrugge vd., 2013). Aort darlığı tanısında ekokardiyografik inceleme ilk sıradadır. Ancak bazı hastalarda (yaklaşık %40 oranında) ekokardiyografik tanı da yetersiz olabilmektedir (Clavel vd., 2017). Özellikle düşük gradyanlı aort kapak hastalarında ek tanısal yöntemlere ihtiyaç duyulmaktadır. Kalsifikasyon aort darlığı gelişiminde en önemli faktördür. Kalsifikasyonun miktarı, yaygınlığı ve yoğunluğu aort kapak darlığı ciddiyeti (seviyesi) ile yakından ilişkilidir (Pawade vd., 2015). Ayrıca aort kapak kalsiyum skorunun olumsuz birçok klinik olayla da yakın ilişkili olduğu çeşitli çalışmalarda gösterilmiştir (Rosenhek vd., 2000; Pawade vd., 2018). Örneğin; aort kapak kalsiyum skoru tedavi amaçlı uygulanan protez kapak işlemlerine bağlı gelişebilecek aort yetersizliğinin de bir ön gördürücüsü olduğu bazı çalışmalarda gösterilmiştir (Azzalini vd., 2014; Khaliq vd., 2014). Bu nedenle kardiyolojik tanı ve tedavide yol gösterici olarak yararlanılan kılavuzlar tarafından aort kapak kalsiyum skorunun değerlendirilmesi önerilmektedir Falk vd. (2017). Şekil 1’de Avrupa Kardiyoloji Derneği kılavuzlarının en güncel versiyonunda uygulanması önerilen iş-akış diyagramı verilmiştir.

Aort kapak kalsiyum skoru ölçümünde altın standart yöntem olarak Şekil 1’de gösterildiği gibi bilgisayarlı tomografi (BT) görüntülemesi önerilmektedir. BT görüntülemesi ile kalsiyum miktarının belirlenmesinde en sık kullanılan ölçüm yöntemi Agatston skorlamasıdır (Agatston vd., 1990). Bu yöntem, kalsifiye plak alanı ile elde edilen en yüksek Hounsfield dansitesinin çarpımı sonucu kalsiyum skorlamasını vermektedir. Agatston skorlamasında, birbirine komşu 2–3 pikselde, 1 mm^2 ’den geniş bir alanda, BT dansitesi 130 Hounsfield ünite (HU)’den fazla olan lezyonlar kalsifikasyon olarak yorumlanmaktadır. Uzman radyolog tarafından her bir kesitte segment edilen lezyonların alanı ve dansitesi cihaz yazılımı tarafından otomatik olarak ölçülmektedir. Ancak her bir kesitteki segmentasyon süreci fazla zaman kaybına neden olabilmektedir ve uzman tecrübesine ve becerisine göre sonuçların doğruluğu değişebilmektedir. Ayrıca, her bir BT kesitinde aort ilgi bölgesinin farklı şekil, boyut ve pozisyonunun (açık kapak-kapalı kapak) olması, elle segmentasyon



Şekil 1. Kalsifikasyon skoru ölçüm aşamaları

işlemini daha da zorlaştırmaktadır. Her kalsifik lezyon için kalsiyum skoru, lezyon alanı ile lezyon dansitesine göre belirlenen dansite skorunun çarpılması sonucu hesaplanmaktadır. Lezyonların her biri için kalsiyum skoru saptanarak, o hasta için toplam kalsiyum skoru yarı-otomatik (semi-quantative) olarak hesaplanmaktadır. Bu ölçümde kısmi olarak operatör (uzman radyolog) deneyimi önem kazanmaktadır. Son yıllarda, BT görüntülemeye operatör etkisini azaltmaya yönelik yalnızca BT görüntülerinin irdelenmesine dayalı aort kapak kalsiyum skorunun ölçülmesi ve sınıflandırması amacı ile birkaç çalışma (Wolterink vd., 2016; Lessmann vd., 2017; Chang vd., 2021; van Assen vd., 2021) yapılmıştır.

1.1.2. Kalp Kapakçıklarında Kireçlenme

Kalp kapağı aslında kalbin içerisinde bulunan aort damarı kapakçığıdır. Bu kapakçık sık sık kapanıp açılan bir kastan oluşmaktadır. Kalp kasının kasılma ve gevşeme evreleri sırasıyla sistol ve diyastol olarak adlandırılmaktadır. Bu kasın kireçlenerek görevini tam olarak yapamaması durumunda birçok sorun ortaya çıkmaktadır. Aort bölgesinde kalsifikasyon barındıran bir kalp sistol ve diyastol evlerinde yeterince kasılamaz ve yeterince gevşeyemez. Dolayısıyla kapakçıklar tam kapanamaz ve pompalanan kanın bir kısmında geriye doğru

akma meydana gelir. Bu durum kan basıncını etkilemekle birlikte aort darlığı ve damar tıkanıklığı gibi pek çok hastalığın temelini oluşturur. Normal bir insanda kalp kapakçığı yaklaşık olarak 4 cm^2 boyutlarındadır. Fakat insanlarda kalbin ara ara değişimler göstermesine ve kalsifikasyona bağlı olarak bu kapakçığın boyutunda da değişiklikler göstermektedir. Bu durumlarda kireçlenmiş olan kapakçık iyice görevini yapamaz hale gelebilmektedir (drzezo, 2022).


1.1.3. Kalp Kapakçıklarında Kireçlenmenin Teşhis ve Tanı Süreci

Aort kapağı sol ventrikül ile aort arasında yer alır ve normalde sol ventrikülden aorta atılan kanın sol ventriküle geri dönmesini engeller (Bellhouse & Talbot, 1969). Normalde üç yaprakçıktan oluşur. Bu üç yaprakçık kalp kasıldığında açılır ve gevşediğinde kapanır. Bu koordinasyon kanın kalbe geri kaçmadan vücuda dağılmasını sağlar (Sun vd., 2021; Hyun & Lee, 2023). Birçok kalp kapağı hastalığı aort kapağının normal işlevini etkiler (Yang vd., 2023). Bu hastalıklardan en yaygın olanı, normalde tamamen açılarak kanın ileri doğru geçmesine izin veren aort kapağının çeşitli nedenlerle daralarak kanın ileri doğru geçmesini engellediği aort darlığıdır (Hyun & Lee, 2023). Yaş ortalaması daha yüksek olan gelişmiş ülkelerde aort darlığının yaygın nedeni kapakların yaşla birlikte kireçlenmesidir (Carabello & Paulus, 2009; Zakkar vd., 2016). Şekil 2 normal ve kalsifik aort kapağının kalp kasının sistol ve diyastol evrelerindeki görünümünü göstermektedir. Normal aort kapağı görünümünde, üç yaprakçıkta kalsifikasyon yoktur; yaprakçıklar ince ve iyi sınırlıdır. Kalsifik kapak görünümünde yaprakçıklar kalındır ve kalsifikasyon oluşumu ile düzensiz bir şekilde çevrelenmiştir.

1.1.4. Ultrason ve Bilgisayarlı Tomografi ile Görüntüleme

Uzman kardiyologlar, ekokardiografi görüntüsünde kalsifikasyon oluşumunu sadece aort kapağını oluşturan bu üç yaprakçıkta değerlendirirler. Bu nedenle, ilgilenilen aort bölgelerine (RoIs) odaklanırlar ve daha sonra kalsifikasyon hacmi ve skoru için yaklaşık bir skor oluştururlar. Uzman kardiyologlar tarafından gerçekleştirilen bu manuel değerlendirmenin birkaç dezavantajı vardır:

- Aort kapağı ve üç yaprakçığının değerlendirilmesi, ekokardiografi görüntülerindeki benek gürültüsü ve düşük kontrast ile sınırlıdır (Zhang vd., 2023).



Şekil 2. Kalp kasının sistol ve diyastol evreleri sırasında normal ve kalsifik aort kapağının (a) modelleme yapılarak (drzezo, 2022), (b) ekokardiyografi görüntüleri üzerinde gösterimi

- Görüntülerin yorumlanması öznel olabilir ve bu da kardiyologlar arasında kalsiyum skoru tahminlerinde tutarsızlıklara yol açarak değerlendirmelerin doğruluğunu ve güvenilirliğini etkiler (Al Alwany, 2022).
- Manuel değerlendirme sırasında yorgunluk ve dikkat dağınıklığı gibi faktörler nedeniyle uzman kardiyologlar bile hata yapabilir ve yanlış tanıya yol açabilir.
- Manuel değerlendirme zaman alan bir süreç olduğu için tedavi planlarını geciktirebilir.
- Özellikle uzak ve yetersiz hizmet alan bölgelerde olmak üzere tüm sağlık tesislerinde uzman kardiyolog bulunmayabilir (Shabaan vd., 2020). Bu durum, hastalar için kalsiyum skoru tahmininde gecikmeye neden olabilir.

Bu dezavantajları gidermek için, aort kapak değerlendirmelerinde daha objektif, tutarlı ve verimli kalsiyum skoru tahminleri sağlamak üzere otomatik aort kapak tespit yöntemleri geliştirilmektedir.

1.1.5. Otomatik Aort Kapak Tespiti

Otomatik aort kapak tespit yöntemlerinin çoğu, son yıllarda derin öğrenme tekniklerinin artan popülaritesi ve gücüyle desteklenen derin öğrenmeye dayanır. Derin öğrenme tabanlı yöntemler, ham verilerden ilgili özellikleri otomatik olarak öğrenebilir ve görüntü sınıflandırma, nesne algılama ve segmentasyon gibi görevlerde yüksek doğruluk seviyelerine

ulařabilir. Bu doęruluk, kk bir hatanın bile nemli sonular doęurabileceęi tıbbi tanıda ok nemlidir. Mevcut aort kapaęı tespit yntemleri (bin Ahmad Nizar vd., 2018; Nizar vd., 2020; Lai vd., 2021; Hatfaludi vd., 2022) eřitli CNN tabanlı mimariler kullanarak umut verici sonular gstermiřtir. Literatr taraması, bu zel grev iin yalnızca ařaęıda sunulan sınırlı sayıda yntemin nerildięini ortaya koymuřtur.

Nizar ve ark. (bin Ahmad Nizar vd., 2018) Tek Atıřlı oklu Kutu Dedektr (SSD) ve Daha Hızlı Blgesel Tabanlı Evriřimsel Sinir Aęı (Faster R-CNN) nesne dedektr mimarilerini, farklı hastalardan 23 ekokardiyografi grnts ieren bir veri kmesi zerinde farklı zellik ıkarıcılarla eęitmiřlerdir. Modellerin performansını 5 ekokardiyografi videosu zerinde deęerlendirmiřlerdir. Faster R-CNN nesne dedektr ve Inception v2 zellik ıkarıcı ile %94,9 ile en yksek doęruluęu elde etmiřlerdir. İkinci sırada SSD nesne dedektr ve Inception v2 zellik ıkarıcı ile %86,5 doęruluk elde etmiřlerdir. Tahmin hızı aısından SSD mimarilerinin daha hızlı olduęunu vurgulamıřlardır. Sonular, CNN tabanlı mimarilerin ekokardiyografi alanında kullanılma potansiyelini gstermekte ve bu alanda daha fazla arařtırma yapılması iin temel oluřturmaktadır. Nizar ve ark. (Nizar vd., 2020) daha sonra nerdikleri CNN tabanlı nesne dedektrn 33 farklı hastadan elde edilen daha geliřmiř bir veri kmesi zerinde eęitmiř ve 10 ekokardiyografi videosu zerinde bir performans analizi gerekleřtirmiřlerdir. Faster R-CNN nesne dedektr ve Inception v2 zellik ıkarıcı ile %98,6 ile en yksek doęruluęu elde etmiřlerdir. Ayrıca SSD nesne dedektr ve Mobilenet v2 zellik ıkarıcı ile en dřk Grafik İřlem Birimi (GPU) kullanımını rapor etmiřlerdir. Lai ve ark. (Lai vd., 2021) AlexNet modelini 120 hasta rneęinden oluřan bir veri kmesi zerinde eęitmiřtir. Model, aort kapaęı tespitinde %95 doęruluk elde etmiřtir. Hatfaludi ve ark. (Hatfaludi vd., 2022) parasternal uzun eksen ekokardiyografi grntlerinde aort kapaęını %93,3 doęruluk ve yaklaşık %100 hassasiyetle bir Faster R-CNN nesne dedektr ile tespit etmiřlerdir.

Yukarıda tartıřılan alıřmalar, CNN tabanlı nesne algılama modellerinin otomatik aort kapaęı algılamada umut verici sonular saęladıęını gstermiřtir. Bu bulgular, ekokardiyografi alanında aort darlıęı gibi kardiyovaskler hastalıkların teřhisi ve ynetimi iin nemli etkileri olabilecek daha sofistike ve doęru modellerin geliřtirilmesi iin saęlam bir temel oluřturmaktadır. Bununla birlikte, yukarıda bahsedilen alıřmaların kullandıkları veri kmeleriyle ilgili belirli sınırlamaları olduęunu belirtmek nemlidir. nerilen modeller umut verici doęruluk gstermiř olsa da, bu sonuların daha byk ve daha eřitli bir veri kmesine genelleřtirilmesi endiřelere yol aabilir. Bu nedenle, sonuları etkili bir řekilde

doğrulamak ve genelleştirmek için daha büyük ve daha çeşitli veri kümeleri üzerinde daha fazla araştırma ve değerlendirme yapılması gerekmektedir.

CNN tabanlı nesne algılama modelleri iki gruba ayrılır: bölge tabanlı modeller ve tek aşamalı modeller (Wu vd., 2022). Bölge tabanlı nesne algılama modelleri (R-CNN, Fast R-CNN ve Faster R-CNN) iki adımda gerçekleştirilir: (i) bölge önerilerinin oluşturulması ve (ii) bu bölgelerin sınıflandırılması. Tek aşamalı nesne algılama modelleri olan SSD ve YOLO (Redmon vd., 2016; Redmon & Farhadi, 2017, 2018; Bochkovskiy vd., 2020; Nelson & Solawetz, 2020), hem bölge önerme hem de sınıflandırma işlemlerini tek bir adımda gerçekleştirilir. YOLO mimarilerinin temel özelliği, nesneleri gerçek zamanlı olarak ve yüksek doğrulukla tespit etmek için tasarlanmış olmasıdır. Önce ilgilenilen bölgeleri öneren ve ardından bu bölgeleri sınıflandıran iki aşamalı algılama modellerinin aksine, YOLO tüm görüntüyü tek bir geçişte işleyerek YOLO mimarilerini daha hızlı ve daha verimli hale getirir.


İlk önerilen YOLO modeli olan YOLO (Redmon vd., 2016), görüntüdeki farklı sınıflara ait nesneleri tespit etmek için tek bir CNN kullanmış ve diğer iki aşamalı nesne tespit modellerine kıyasla çok hızlı tespit sağlamıştır. Öte yandan, o dönemdeki bazı iki aşamalı modeller kadar başarılı olamamıştır. YOLOv2 (Redmon & Farhadi, 2017), YOLO modelinin algılama doğruluğunu artırmak için çapa kutuları ve çıktı özellik haritasının çözünürlüğünü artıran UpSample katmanı önermiştir. YOLOv3 (Redmon & Farhadi, 2018), algoritmanın doğruluğunu ve hızını artırmak için önceki modellerde ana iyileştirme olarak, nesne algılama için özel olarak tasarlanmış Artık Ağ (ResNet) mimarisinin bir türevi olan Darknet-53 mimarisini tanıtmıştır. Ayrıca YOLOv3'te, tespit edilen nesnelerin boyut ve şekillerinin farklı ölçekler ve en boy oranları kullanılarak daha iyi eşleştirilebilmesi için bağlantı kutuları geliştirilmiştir. Özellik Piramit Ağları (FPN) ve Gradyan Uyumlaştırılmış Mekanizma (GHM) kayıp fonksiyonunun kullanımı, çok çeşitli nesne boyutları ve en boy oranlarında algılamaya izin verirken, doğruluk ve kararlılık önemli ölçüde geliştirilmiştir. YOLOv4 (Bochkovskiy vd., 2020), YOLOv3 modeline birçok iyileştirme getirmiştir. Bu geliştirmeler arasında yeni bir omurga ağı, eğitim sürecindeki iyileştirmeler ve artan model kapasitesi yer almaktadır. YOLOv4 ayrıca eğitim sürecinin istikrarını artırmak için tasarlanan Çapraz Mini-Yığın Normalleştirme (Cross Mini-Batch Normalization) yöntemini de tanıtmıştır.

YOLOv5 (Nelson & Solawetz, 2020), 2020 yılında Ultralytics tarafından açık kaynaklı bir proje olarak yayınlanan ve önceki sürümlerin başarısı üzerine inşa edilen bir sürümdür. YOLOv5, EfficientNet ağını omurga olarak kullanan EfficientDet mimarisini kullanmıştır. Ayrıca birçok yeni özellik ve iyileştirme ile gelişmiş nesne algılama performansı elde etmek

için geliştirilmiştir. Python tabanlı esnek yapısıyla YOLOv5, 2020 yılında nesne tespiti için dünyanın önde gelen reposu haline gelmiştir. Bu süreçte yer alan bir çalışmamızda, YOLOv5 modelinin dört alt versiyonu 100 farklı hastaya ait 202 parasternal kısa eksenli ekokardiyografi görüntüsünden oluşan küçük bir Aort Kapak Tespiti veri kümesi üzerinde uygulanmış ve YOLOv5-x modeli ile 99,9% kesinlik ve 97,5% hassasiyet elde edilmiştir (Çakır vd., 2023).

1.2. Tezin Kapsamı

Tıbbi alanda kardiyologlara yardımcı olacak aort ilgi bölgesinin ve ilgili bölgede bulunan kalsifik alanların otomatik algılanması için yaklaşımlarının geliştirilmesi kardiyologların iş yükünü azaltmanın yanı sıra, tanıda objektif değerlendirmeye de katkıda bulunmaktadır. Bu amaçla tez çalışmasında, ekokardiyografi görüntülerinde aort ilgi bölgesinin ve ilgili bölgede bulunan kalsifik alanların algılanmasında yapay zekaya dayalı bilgisayar destekli tanı yaklaşımlarının geliştirilmesi ve uygulanması gerçekleştirilmiştir. Tez kapsamında, Şekil 1’de verilen kalsifikasyon tanı sistemi aşamalarında mevcut yöntemlerin ilgili alanda uygulanması ve değerlendirilmesi ve sonrasında alternatif yeni yöntemler geliştirilmesi hedeflenmektedir. Tezin okunabilirliğini artırabilmek amacıyla, tez kapsamında yapılan çalışmalar aşamalar halinde Şekil 3’de özetlenmiştir.



Şekil 3. Tez kapsamı

Çalışmada aort ilgi bölgesinin algılanması aşamasında kısa parasternal ekokardiyografik görüntülerden oluşan özgün bir veri seti oluşturulmuştur. Oluşturulan veri seti literatürde bu alanda ilk olacağından gelecek çalışmalara da zemin hazırlayacaktır.

Çalışmada ilk olarak ekokardiyografik görüntülerde aort ilgi bölgesinin tespiti için YOLOv5 modeli kullanılarak bir ağ eğitimi yapılmıştır.

Çalışmada aynı zamanda aort ilgi bölgesindeki kalsifik alanların işaretlendiği görüntülerinden ve onlara ait maskelerden oluşan özgün bir veri seti oluşturulmuştur. Oluşturulan veri seti literatürde bu alanda ilk olacağından gelecek çalışmalara da zemin hazırlayacaktır.

Aort bölgesindeki kalsifik alanların belirlenmesi aşamasında, medikal görüntü segmentasyonunda sıklıkla kullanılan UNET, SegNet, FCN gibi derin öğrenme modelleri ve KNN, Random Forest, AdaBoost, Balanced Bagging gibi makine öğrenmesine dayalı sınıflandırma yöntemleri kullanılmıştır. Daha sonra uygulanan modellerin çıktıları üzerinde iyileştirmeler yapılarak kalsifik alanlar segmente edilmiştir.

Tezin genel bilgiler bölümünde Şekil 3'te gösterilen aort ilgi bölgesi tespit etme ve kalsifik alanların belirlenmesi işlemlerinin her aşaması için ayrı ayrı konu tanıtımı, literatür taraması ve kullanılan yöntemlerin kısaca tanımlamaları yapılacaktır. Yapılan çalışmalar bölümünde ise gerçekleştirdiğimiz çalışmalar deney ve sonuçlardan bağımsız olarak özetlenecek ve önerilen yöntemler açıklanacaktır. Bulgular ve irdeleme bölümünde elde edilen sayısal ve görsel sonuçlar irdelenip yorumlanacak ve literatürde bu alanlarda yapılan çalışmalarla karşılaştırılacaktır. Çalışmanın son kısmında ise gelecekte yapılabilecek diğer çalışmalar için bazı öneriler sunulmaktadır.

1.3. Tezin Katkıları

Bu tez çalışması ile literatüre yapılan önemli katkılar aşağıda sıralanmıştır.

(i) Ekokardiyografik görüntülerde aort ilgi bölgesinin tespit edilmesi amacıyla literatürde bu alanda yeni bir veri setinin oluşturulması.

(ii) Ekokardiyografi görüntülerinde aort ilgi bölgesinin otomatik tespit edilebilme kabiliyetine sahip ve uzman tarafından etiketleme gerektirmeyen bir bölge tespiti yönteminin önerilmesi.

(iii) Ekokardiyografi görüntülerinde aort ilgi bölgesinin otomatik tespit etmek amacıyla yeni bir YOLO model mimarisi (AVD-YOLOv5) önerilmesi.

(iv) Ekokardiyografi görüntülerinden aort bölgesindeki kalsifik alanların segmentasyonu problemini çözmek amacıyla literatürde bu alanda ilk olacak bir veri setinin oluşturulması.

(v) Ekokardiyografi görüntülerinden aort bölge tespiti ve ardından kalsifik alan segmentasyonu yapan ilk çalışma olması.

(vi) YOLOv5 nesne algılayıcısını ekokardiyografi görüntülerinden aort bölge tespiti amaçlı kullanan ilk çalışma olması.

(vii) BT görüntülerinde kalsifik alanların segmentasyonu amacıyla kullanılan derin öğrenme ağlarının ultrason görüntülerinde denenmesi.

(viii) Ekokardiyografi görüntülerinden kalsifik alan tespiti yapan ilk çalışma olması.

(ix) Derin öğrenmeye dayalı popüler CNN mimarilerini (UNet, SegNet, FCN) ekokardiyografi görüntülerinden kalsifik alan tespiti amacıyla öneren ilk çalışma olması.

1.4. Kalp Aort İlgili Bölgesinin Algılanması

Kalp hastalıklarının erken teşhisi aynı zamanda tedaviye başlama zamanını da etkilemektedir. Kalpte görülen aort darlığı, çoğu hastalığın da temlini oluşturmaktadır. Aort darlığına sebebiyet veren en önemli etkenlerin başında, aort kapakçığı bölgesinde kalsifik alan oluşumu gelmektedir. Kirecin kapakçıklar üzerinde zamanla birikip plaka haline gelmesi, kalpteki kan akışında kapakçıkların görevini tam olarak yerine getirememesine sebep olur. Aort ilgi bölgesinin belirlenmesi kalbe ait görüntülerin tamamında değil, hastalık bulunma olasılığı yüksek alana öncelik vermeyi sağlar. Normal şartlarda aort darlığı veya kapakçıklarda kireçlenme teşhisi konulurken hasta öncelikle ekokardiyografiye yönlendirilir. Ekokardiyografik görüntülerde doktorlar sonuçları göz yordamıyla değerlendirirler. Eğer kireçli veya yüksek kireçli olmaya aday bölgeler olduğu tespit edilirse bu kireçlenmenin yerinin ve miktarının tam olarak tespit edilmesi amacıyla hasta bilgisayarlı tomografi (BT) görüntülemeye yönlendirilir. BT görüntülerinde kalpte kireçli olan bölgeler belirli eşik değerleri ve alan hesaplamalarıyla ölçülerek, hastanın kireç skoruna dair bir çıktı üretilir. Bu her ne kadar ultrasona göre daha yüksek doğrulukta bilgiler üretse de, BT işleminde X ışınlarıyla görüntüleme yapıldığı için hastanın vücuduna çok fazla radyasyon girmesine sebep olur. Bu durum insan bazlı bakıldığında sağlık açısından ultrasona göre çok daha zararlıdır. Ayrıca hastanelerde ultrason ve BT için randevu alınması da oldukça uzun bir zaman dilimine yayılabilmektedir. Buna ek olarak, BT ile görüntüleme işlemi, kullandığı teknolojik donanım ve yazılım göz önüne alındığında ultrasona göre oldukça maliyetlidir. Bu bakımdan ekokardiyografi görüntüleri üzerinden kalpteki aort ilgi bölgesinin tespitini ve bu bölgede bulunan kireçli alanların belirlenmesini kapsayan tüm sürecin, yapay zeka, makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak tam otomatik hale getirilmesi hem teşhis ve tedavi süresi hem de radyasyona maruz kalmamak ve maliyet açısından önemli faydalar sağlamaktadır.

1.5. Aort İlgili Bölgesinin Otomatik Tespitinde Kullanılan Yöntemler

Aort kapak kalsiyum skoru ölçümünde altın standart yöntem olarak Şekil 1.1’de gösterildiği gibi bilgisayarlı tomografi (BT) görüntülemesi önerilmektedir. BT görüntülemesi ile kalsiyum miktarının belirlenmesinde en sık kullanılan ölçüm yöntemi Agatston skorlamasıdır (Agatston vd., 1990). Bu yöntemde uzman radyolog tarafından her bir kesitte segment edilen lezyonların alanı ve dansitesi cihaz yazılımı tarafından otomatik olarak ölçülmektedir. Ancak her bir kesitteki segmentasyon süreci fazla zaman kaybına neden olabilmektedir ve uzman tecrübesine ve becerisine göre sonuçların doğruluğu değişebilmektedir. Bu ölçümde kısmi olarak operatör (uzman radyolog) deneyimi önem kazanmaktadır. Son yıllarda, BT’de operatör etkisini azaltmaya yönelik yalnızca BT görüntülerinin irdelenmesine dayalı aort kapak kalsiyum skorunun ölçülmesi ve sınıflandırması amacı ile birkaç çalışma yapılmıştır. Derin öğrenme algoritmaları temelli bu çalışmalar (Wolterink vd., 2016; Lessmann vd., 2017; van Assen vd., 2021; Chang vd., 2021; Fu vd., 2020) kısaca şu şekilde özetlenebilir:

Wolterink vd. (2016) BT taramalarından koroner arter kalsifikasyonlarının otomatik ölçümü için Konvolüsyonel Sinir Ağı (Convolutional Neural Network, CNN) mimarisine dayalı bir yöntem önermişlerdir. Yöntem, mevcut yöntemlerde yaygın olarak kullanılan koroner arter bölgesinin çıkarılmasına ihtiyaç duyulmadan kalsifikasyonu doğrudan tanımlamak ve ölçmek için danışmanlı öğrenmeyi kullanmaktadır.

- Veri seti: 250 kardiyak BT taramasından oluşmaktadır. Veri seti iki gruba ayrılmıştır. İlk 50 tarama, kalbin etrafındaki sınırlayıcı kutuları (bounding box) otomatik saptayacak modeli eğitmek için kullanılmıştır. Diğer 200 tarama ise, bu sınırlayıcı kutularda koroner arter kalsifikasyonlarını saptayacak bir voksel sınıflandırma modelini eğitmek ve test etmek için kullanılmıştır.

- Etiketleme: İki uzman gözlemci, taramaların tamamında (gözlemci 1) veya bir alt kümesinde (gözlemci 2) etiketleme gerçekleştirmiştir. İlk 50 taramada sınırlayıcı kutuların ve diğer 200 taramada kalsifikasyonların manuel etiketlenmesi gerçekleştirilmiştir. 100 taramadan oluşan alt küme ise gözlemci 2 tarafından gözlemci içi değişimlerin belirlenmesi için etiketlenmiştir.

- Yöntem: İlk olarak, kalbin etrafında bir sınırlayıcı kutu belirlenmektedir. Bu işlemin amacı, çoğu kalp dışı kalsifikasyonu hariç tutarak yalnızca bu hacim bölgesi (Volume of Interest, VOI) üzerinde daha fazla analiz yapılmasına izin vermektir. Daha sonra, ilgili VOI

içerisindeki vokseller, aynı yapıyı paylaşan ancak farklı şekilde eğitilmiş parametrelere sahip olan bir çift CNN (CNNPair) ile sınıflandırılmaktadır. İlk CNN (CNN 1), tüm aday vokseller arasında kalsifikasyon olması muhtemel vokselleri saptamaktadır. İkinci CNN (CNN 2) ise, kalsifikasyonu, atenüe koroner arter lümeni ve aort kalsifikasyonları gibi benzeri voksellerden ayırmaktadır. Son olarak, tanımlanan kalsifikasyon ölçülmektedir.

- Performans ölçümü ve Sonuç: En iyi performans gösteren bireysel CNNPair, tarama başına ortalama 0.85 yanlış pozitif (FP) hata ile test setindeki lezyonların %72'sini tespit etmiştir. En iyi performans gösteren grup, tüm CNNPair'leri birleştirmiştir ve tarama başına 0,48 FP hatalarında %71 hassasiyet elde etmiştir. Bu grup için, sınıf içi korelasyon katsayısı (ICC, intra-class correlation coefficient) 0.944 [0.918-0.962] olarak elde edilmiştir. Ek olarak, BT'deki Agatston skoruna dayanarak, bu birleştirme hastaların %83'ünü referans kalsifikasyon skorumla ile aynı kardiyovasküler risk kategorisine atamıştır.

Lessmann vd. (2017) düşük doz göğüs BT taramalarından koroner arter kalsifikasyonları alt türleri ve kardiyak kapak kalsifikasyonlarının otomatik tespiti için CNN mimarisine dayalı bir yöntem önermişlerdir. Yöntem, bu kalsifikasyonların hepsini aynı anda tespit eden ilk yöntemdir.

Bu algılayıcılar BT görüntülerinde kalsifikasyon algılama alanında başarılı bir şekilde uygulanmıştır. Ancak, literatürde ekokardiyografi(kalp Ultrason) görüntülerinde kalsifik alan algılama problemine henüz uygulanmadığı görülmüştür. Bu bölümde, öncelikle aort ilgi bölgesi tespit etme problemi üzerine önerilen Faster R-CNN, R-FCN, SSD nesne algılayıcıları irdelenecektir ve tez çalışmasında bu problemi çözmek amacıyla ilk kez kullanılan YOLOv5 nesne algılayıcısından bahsedilecektir. Daha sonra kalsifikasyon algılama problemi üzerine önerilen KNN, SVM, AdaBoosting sınıflandırıcılar gibi makine öğrenmesine dayalı yaklaşımlar irdelenecektir ve çalışmada yararlanılan derin öğrenmeye dayalı yöntemlerden Unet, SegNet ve FCN anlatılacaktır.

1.5.1. Modern Konvolüsyonel Nesne Algılayıcılar

Geleneksel bilgisayarlı görme yöntemleri, nesne algılama problemini çözmek için uzun yıllar boyunca el yapımı özelliklerin çıkarılmasına dayanıyordu. Bu yöntemler genellikle renk, doku ve yönlü gradyan histogramı gibi düşük seviyeli özelliklerin manuel olarak tanımlanmasını içerir. Ancak, bu el yapımı özelliklerin kullanımı genellikle zaman alıcıdır ve genellikle nesnelerin karmaşıklığını tam olarak yakalayamaz. Ayrıca, el yapımı özelliklerin

genelleme yetenekleri sınırlı olabilir ve farklı veri kümesi yapılarına adapte olmaları zor olabilir. Bu nedenle, geleneksel yöntemlerin performansı genellikle değişkenlik gösterebilir ve ölçeklenebilirlik açısından sınırlı olabilir.

Bu zorluklarla başa çıkmak için, bilgisayarlı görme alanında derin öğrenme yöntemleri, özellikle de modern konvolüsyonel sinir ağları (CNN'ler), önemli bir ilerleme sağlamıştır. CNN'ler, girdi verilerinden özellikleri otomatik olarak öğrenmek için katmanlararası filtreler kullanır. Bu filtreler, özelliklerin hiyerarşik bir şekilde öğrenilmesini sağlar ve nesnelerin daha karmaşık özelliklerini de yakalamaya imkan tanır. Geleneksel yöntemlerin aksine, CNN'ler el yapımı özelliklerin yerini alır ve giriş verilerinin yüksek seviyeli özelliklerini otomatik olarak belirler. Bu da nesne algılama ve sınıflandırma görevlerinde daha iyi performans ve doğruluk sağlar. CNN'ler ayrıca, büyük veri setleri üzerinde eğitilerek genelleme yeteneklerini artırabilir ve farklı veri yapılarına daha iyi adapte olabilirler. Bu sayede, nesne algılama ve diğer bilgisayarlı görme görevlerinde daha tutarlı ve güvenilir sonuçlar elde edilebilir.

YOLO (You Only Look Once), nesne algılama alanında önemli bir adım olan modern bir derin öğrenme mimarisidir. YOLO, nesne algılama görevini tek bir end-to-end derin sinir ağı olarak formüle eder ve bir görüntüdeki nesnelerin koordinatlarını ve sınıflarını doğrudan tahmin etmek için bir model oluşturur. Bu özgün yaklaşımı sayesinde, YOLO hem daha hızlı hem de daha basit bir yapıya sahiptir, bu da nesne algılama sürecini büyük ölçüde hızlandırır ve basitleştirir.

You Only Look Once (YOLO), aynı anda sınırlayıcı kutuların ve sınıf olasılıklarının tahminlerini yapan bir uçtan uca sinir ağı kullanmayı önerir. Bu, önceki nesne tespiti algoritmalarının yaklaşımından farklıdır; çünkü bu algoritmalar sınıflandırıcıları tespit yapmak için tekrar kullanmıştır. Nesne tespiti konusunda temelde farklı bir yaklaşım benimseyen YOLO, diğer gerçek zamanlı nesne tespiti algoritmalarını büyük ölçüde geride bırakan bir performans elde etmiştir.

Faster RCNN gibi algoritmalar, Bölge Öneri Ağı'nı kullanarak olası ilgi alanlarını tespit eder ve ardından bu bölgeler üzerinde tanımayı ayrı ayrı gerçekleştirirken, YOLO, tüm tahminlerini tek bir tam bağlantılı katmanın yardımıyla yapar. Bölge Öneri Ağlarını kullanan yöntemler, aynı görüntü için birden çok iterasyon gerçekleştirirken, YOLO tek bir iterasyonla yetinir.

YOLO'nun ilk sürümünün 2015 yılında yayımlanmasından bu yana, aynı modelin birkaç yeni sürümü önerildi ve her biri öncekini temel alarak geliştirildi. YOLO (You Only Look Once), nesne algılamak için tasarlanmış bir derin öğrenme algoritmasıdır. Bu algoritma,

görüntüdeki nesneleri tek bir aşamada algılamak üzere optimize edilmiştir. YOLO'nun temel prensibi, bir görüntüyü bir ızgara (grid) sistemi üzerine bölmek ve her hücrenin birden çok sınırlayıcı kutu ve sınıf olasılıkları için tahminler yapmasını sağlamaktır. YOLO mimarisinin başlangıçtaki ve daha sonra geliştirilen versiyonlarında sahip olduğu yapıyı ve gelişmeleri kısaca şu şekilde özetlenebilir:

- YOLOv1 (You Only Look Once version 1): YOLO'nun orijinal sürümü, bir görüntüyü ızgara hücrelerine böler ve her hücreden sınırlayıcı kutuların ve sınıf olasılıklarının tahminlerini yapar. Ancak, küçük nesneleri algılamada zorlanabilir ve ölçek uyumsuzluğu sorunları yaşayabilir.
- YOLOv2 (YOLO9000): Bu sürüm, YOLO'nun orijinal zayıflıklarını gidermeye yönelik geliştirmeler içerir. Çeşitli sınıfları içeren daha geniş bir veri kümesinde eğitilmiş ve küçük nesneleri daha iyi algılamak için özel bir detektör eklenmiştir.
- YOLOv3: YOLOv3, önceki sürümlere kıyasla daha fazla özellik içerir. "Feature Pyramid Network (FPN)" ve "Path Aggregation Network (PAN)" gibi mimari geliştirmeleri içerir. Ayrıca farklı ölçeklerdeki özellik haritalarını birleştirmek için "skip connections" kullanır. Bu sayede, nesnelerin farklı boyutlarda daha iyi algılanabilmesini sağlar.
- YOLOv4: YOLOv4, YOLO'nun performansını daha da artırmak ve çeşitli detayları iyileştirmek için geliştirilmiştir. Yenilikler arasında CSPDarknet53 mimarisi, PANet, YOLOv3'e göre daha fazla öğrenme ve daha etkili tespit algoritmaları yer alır....

Her bir YOLO sürümü, önceki sürümlerin zayıflıklarını gidermek ve algı performansını artırmak amacıyla öncekilerin üzerine inşa edilmiştir. Bu sürümler arasındaki seçim, kullanım senaryosu ve ihtiyaçlara bağlı olarak değişebilir.

YOLO mimarisi, özellikle nesne algılama alanında derin öğrenmenin önemli bir adımı olarak kabul edilir ve birçok uygulama alanında başarıyla kullanılmaktadır. Bu çalışmada, YOLO mimarilerinden biri olan YOLOv5'in detaylarına daha ayrıntılı bir şekilde odaklanılacak ve nasıl çalıştığı daha geniş bir perspektiften incelenecektir.

1.6. YOLOv5 (You Only Look Once - Version5) ile Nesne Algılama

YOLOv5 mimarisi, YOLOv1 (Redmon vd., 2016), YOLOv2 (Redmon & Farhadi, 2017) ve YOLOv3 (Redmon & Farhadi, 2018) ve YOLOv4 nesne algılayıcılar üzerinde yapılan gelişmeler sonucunda ortaya çıkan hızlı ve doğruluğu yüksek gerçek zamanlı bir nesne algılayıcıdır.

YOLO mimarileri ImageNet veri kümesi üzerinde eğitilmiş ağlara dayanmaktadır, ancak YOLOv5 bu geleneksel yapıdan ayrılmaktadır. YOLOv5, ImageNet veri seti üzerinde eğitilmemiş ve kendi veri kümesi üzerinde eğitilmiştir. Bu, YOLOv5'in daha özgün ve genelleyici bir model olmasını sağlar.

YOLOv5, temel mimari olarak önceki sürümlerden farklı bir yapı kullanır. DarkNet yerine YOLOv5, CSPDarknet53 ve CSPDarknet19 mimarilerini kullanır. CSPDarknet53, geleneksel DarkNet mimarisine benzer şekilde birbirini takip eden çeşitli konvolüsyon katmanlarından oluşur, ancak ağırlık bağlantılarını örneklemek için çapa bağlantıları kullanır. Bu, ağı daha hızlı ve daha az bellek tüketen bir hale getirir. Ayrıca, CSPDarknet19, daha küçük veri setleri veya daha hızlı hesaplamalar için tercih edilebilir.

YOLOv5, YOLOv3 mimarisine benzer bir yaklaşımı sürdürürken, çeşitli iyileştirmeler ve değişiklikler içerir. Örneğin, YOLOv5, YOLOv3'teki 75 konvolüsyon katmanına kıyasla daha hafif bir mimariye sahiptir. YOLOv5 giriş görüntüsünü belirli adım sayısı ile $S \times S$ adet ızgara hücrelerine bölmektedir. Örneğin, giriş görüntü boyutu 608x608 ve adım sayısı 32 ise YOLOv5 giriş görüntüsünü 32x32 adet ızgara hücrelerine böler. Dolayısıyla çıkış ızgara boyutu 19×19 olmaktadır. YOLOv5 mimarisinde 3 farklı ölçekte algılama yapılabilmesi için ağı farklı katmanlarında adım sayısı sırasıyla 8, 16 ve 32 olarak uygulanmaktadır. 3.ölçekte adım sayısı 8 alınarak görüntü 76×76 boyutlu ızgara hücrelerine bölünerek küçük boyutlu nesnelerin algılanması için kullanılmaktadır. Bu, daha yüksek çözünürlüklü görüntülerde daha iyi performans sağlar. YOLOv5 mimarisindeki ölçekler arasında algılama yapabilmek için adım sayıları da ayarlanabilir, ancak bu adımlar YOLOv3'teki gibi sabit değildir. Her bir hücre, YOLOv5'te de birçok sınırlayıcı kutu ve bunlarla ilişkili özellikler üretir. Ancak YOLOv5, özellik çıkarmanın ve tahmin yapmanın daha verimli ve optimize edilmiş bir yolunu benimser.

Her bir hücre B adet sınırlayıcı kutu ve sınırlayıcı kutu içerisinde nesne bulunup bulunmadığına dair güven skoru üretmektedir. Her bir sınırlayıcı kutu (t_x, t_y, t_w, t_h) kutu koordinatları, p_o nesnellik skoru ve $(p_1, p_2, \dots, p_C)$ nesne sınıf olasılıkları olmak üzere $4+1+C$

adet özelliğe sahiptir. p_o sınırlayıcı kutu içerisinde herhangi bir nesne olup olmama olasılığını $(p_1, p_2, \dots, p_C)$ ise sınırlayıcı kutu içerisindeki nesnenin tüm sınıflara ait olma olasılıklarını göstermektedir. Dolayısıyla çıkış boyutu her bir ölçekte B sınırlayıcı kutu olacak şekilde $N \times N \times [B * (4 + 1 + C)]$ olmaktadır. C sınıf sayısını göstermektedir.

Sınırlayıcı kutu tahmini yapılırken çapa kutuları kullanılmaktadır. En iyi çapa kutuları k -ortalama kümeleme yöntemi ile belirlenmektedir. k -ortalama uygulanırken, kümeleme için Öklid uzaklığı yerine IoU ölçütü kullanılmaktadır. Üretilen çapa kutuları boyutlarına göre her bir ölçeğe dağıtılmaktadır. Kesin referans nesnenin merkezini içeren hücre, nesnenin tahmini için sorumlu olmaktadır. Ağ, sınırlayıcı kutuların koordinatlarını elde etmek için çapalar ile kesin referans kutular arasındaki öteleme değerlerini öğrenmektedir. Olası öteleme aralığını sınırlamak için sigma fonksiyonu kullanılmaktadır. Eşitlik 1.1, sınırlayıcı kutu tahmini için ağ çıkışına uygulanan dönüşümü göstermektedir.


$$b_x = \sigma(t_x) + c_x \quad b_y = \sigma(t_y) + c_y \quad b_w = p_w e^{t_w} \quad b_h = p_h e^{t_h} \quad (1.1)$$

Burada (t_x, t_y, t_w, t_h) sırasıyla sınırlayıcı kutunun başlangıç koordinatları ile genişlik ve yüksekliği olmak üzere ağ çıkışını göstermektedir. (b_x, b_y, b_w, b_h) ise sınırlayıcı kutu tahminlerini göstermektedir. (c_x, c_y) çapanın sol-üst köşe koordinatlarını (p_w, p_h) ise çapanın genişlik ve yüksekliğini göstermektedir.

Her bir sınırlayıcı kutu için, lojistik regresyon kullanılarak nesnellik skoru hesaplanmaktadır. Sınırlayıcı kutu ile kesin referans arasındaki IoU değeri diğer sınırlayıcı kutular ile IoU değerinden büyükse nesnellik skoru 1 olarak elde edilmektedir. Her bir sınırlayıcı kutu çoklu etiket sınıflandırma kullanarak içerebileceği sınıfları tahmin etmektedir. Nesnenin etikete sahip olma olasılığını hesaplamak için lojistik sınıflandırıcı kullanılmaktadır.

YOLOv3 nesne algılayıcısı özellik çıkarıcı DarkNet-53, YOLOv4 ise CSPDarnet-53 mimarisini kullanır. YOLOv5 bu mimariler yerine CSPNet'i kullanarak bir özellik çıkarma ağı olarak öne çıkmaktadır. CSPNet, ağıın özellik çıkarma aşamasında kullanılan temel mimariyi ifade eder.

YOLOv5 (Nelson & Solawetz, 2020) mimarisi, Şekil 4'de gösterildiği gibi omurga, boyun ve kafa olmak üzere üç ana bölümden oluşan bir ağ yapısına dayalı olarak tasarlanmıştır. Omurga, verilen bir giriş görüntüsünden temel özellikleri çıkarmak için kullanılır. Çıkarılan özellikler kullanılarak bir özellik haritası oluşturulur. Yüksek doğruluk sağlarken üst düzey özellikleri çıkarmayı ve modellerin işlem süresini azaltmayı amaçlayan Çapraz Aşamalı



Şekil 4. YOLOv5 nesne algılayıcı mimarisi

Kısmi Ağ (CSPNet) (Wang vd., 2020) mimarisine dayalı olarak tasarlanmıştır. Boyun, özellik piramitleri oluşturmak için model omurgasının farklı aşamalarından özellik haritaları toplar. Özellik piramitlerini elde etmek için Yol Toplama Ağı (PANet) mimarisini kullanır (Liu vd., 2018). Özellik piramitlerinin katkısı, modelin farklı boyut ve ölçeklerde aynı türden nesneleri tespit etmesine yardımcı olmaktır. YOLOv5'in nihai nesne algılama kısmı olan kafa, YOLOv3 ve YOLOv4 ile aynı mimari üzerine tasarlanmıştır. Nihai özellik haritalarına bağlantı kutuları uygular ve nesnellik puanları, sınıf aidiyet olasılıkları ve tespit edilen nesneleri çevreleyen sınırlayıcı kutuların koordinatlarını içeren nihai çıktı vektörlerini oluşturur. YOLOv5 omurga, boyun ve baş kısımları birçok anahtar modülden oluşmaktadır. Bu modüller aşağıdaki gibi özetlenebilir:

Tablo 2. Farklı CSP modül yapılarından oluşan YOLOv5 alt versiyonlarının ağ derinliği karşılaştırması

CSP Module	YOLOv5-s	YOLOv5-m	YOLOv5-l	YOLOv5-x
CSP1	CSP1_1	CSP1_2	CSP1_3	CSP1_4
CSP1	CSP1_3	CSP1_6	CSP1_9	CSP1_12
CSP1	CSP1_3	CSP1_6	CSP1_9	CSP1_12
CSP2	CSP2_1	CSP2_2	CSP2_3	CSP2_4
CSP2	CSP2_1	CSP2_2	CSP2_3	CSP2_4
CSP2	CSP2_1	CSP2_2	CSP2_3	CSP2_4
CSP2	CSP2_1	CSP2_2	CSP2_3	CSP2_4
CSP2	CSP2_1	CSP2_2	CSP2_3	CSP2_4

- Focus modülü: Giriş görüntüsünü aynı en-boy oranına sahip 4 paralel dilime böler ve ardından bu dilimleri derinlik bazında birleştirir. Özellik haritaları oluşturmak için çıktıyı CBL modülüne aktarır.
- CBL modülü: Sırasıyla konvolüsyon işlemi (Conv), toplu normalizasyon (BN) ve sızdıran düzeltilmiş doğrusal birim (LeakyReLU) aktivasyon fonksiyonundan oluşan temel düzeyde bir özellik çıkarma modülüdür.
- CSP modülü: Daha üst düzey özellikler çıkararak modelin öğrenme kapasitesini artırmayı amaçlayan CSPNet tabanlı bir modüldür. YOLOv5, CSP1 ve CSP2 olmak üzere iki tür CSP modülü içerir. CSP1 modülü omurga kısmında kullanılırken CSP2 modülü boyun kısmında kullanılır. CSP1_X bir CBL modülü ve X RES (artık) bloğu içerir. CSP2_X ise $X + 1$ CBL modülü içerir. Daha fazla RES bloğu ve CBL modülü ağ mimarisinin derinliğini artırır. Tablo 2, YOLOv5 modelinin dört alt versiyonunda kullanılan CSP modül yapılarını göstermektedir.
- SPP modülü: Omurgada uzamsal özellikleri karıştırmak ve havuzlamak için kullanılır. Giriş özelliklerini üç paralel maksimum havuzlama katmanı aracılığıyla aşağı örnekledikten sonra ilk özelliklerle birleştirir.

1.6.1. CSPNet Özellik Çıkarıcı


CSPNet, ağın derinlik ve genişliğini dengeli bir şekilde artıran bir ağ bileşenidir. YOLOv5’de CSPNet, ağın başlangıç bölümlerindeki hesaplama yükünü azaltarak ve özellik haritalarının daha iyi özelliklerle zenginleştirilmesini sağlayarak verimliliği artırır. CSPNet,

özellik haritalarının bir kısmını işlemek için paralel bloklar kullanır ve ardından bu özellik haritalarını birleştirir. Bu, ağın hem daha hızlı hem de daha doğru tahminler yapmasına yardımcı olur.

1.6.2. Özellik Piramit Ağı (FPN)

FPN, nesne algılama sistemlerinde ölçek dengesizliklerini ele almak için kullanılan bir yapıdır. Yüksek düzeyli özellik haritalarının (daha küçük ölçekli ve daha yüksek seviyede özellikleri temsil eden) daha düşük düzeyli özellik haritalarıyla birleştirilmesiyle oluşturulan bir piramit yapısı kullanır. FPN, farklı özellik ölçeklerinden gelen bilgileri entegre ederek, hem büyük hem de küçük nesneleri algılamak için ağın daha etkili olmasını sağlar ayrıca nesnelerin ölçeklenme invariyanlığını artırır.

Şekil 5'te klasik FPN (a) ve YOLOv5'de kullanılan özellik çıkarma modülü PANet (b) gösterilmiştir. Klasik FPN yapısından farklı olarak YOLOv5'de özellik çıkarma modülü olarak PANet (Yol Birleştirme Ağı), farklı ölçeklerdeki özellik haritalarını daha iyi bir şekilde birleştirmek için tasarlanmış bir yapıdır. Özellikle, düşük ölçekli özellik haritalarının yüksek ölçekli özellik haritalarına daha iyi bir şekilde bağlanmasını sağlayan bir yol birleştirme mekanizması kullanır ve bu, nesne algılama performansını artırır. PANet, birleştirilmiş özellik haritalarını daha sonra ağın sonraki katmanlarına iletmek için kullanılır. Böylece daha kapsamlı ve zengin özellikler elde edilir.



Şekil 5. FPN (a) ve PANet (b) özellik çıkarma modüllerinin yapısı

1.6.3. Yığın (Batch) Normalizasyon

YOLOv5'de kullanılan Batch Normalization (BN), derin sinir ağlarının eğitimini hızlandırmak ve daha iyi performans elde etmek için yaygın olarak kullanılan bir

normalizasyon tekniğidir. BN, her bir mini-batch'teki her bir aktivasyon haritasının ortalamasını ve varyansını hesaplayarak aktivasyon değerlerini normalize eder. Bu, ağı daha hızlı ve daha kararlı bir şekilde eğitilmesine yardımcı olur.

Batch Normalization, her bir mini-batch içindeki her bir aktivasyon haritasının piksel değerlerini normalize ederek, aktivasyonların dağılımını stabilize eder ve ağı daha istikrarlı bir şekilde eğitilmesini sağlar. Her bir aktivasyon kanalının ortalaması ve varyansı, mini-batch içindeki tüm örneklerin değerlerinden yararlanılarak eşitlik (1.2 - 1.3)'de verilen şekilde hesaplanır.

$$Ortalama = \frac{1}{H \times W \times C} \times \sum_{i=1}^H \sum_{j=1}^W \sum_{k=1}^C x_{ijk} \quad (1.2)$$

$$Varyans = \frac{1}{H \times W \times C} \times \sum_{i=1}^H \sum_{j=1}^W \sum_{k=1}^C (x_{ijk} - Ortalama)^2 \quad (1.3)$$

Burada H, W ve C sırasıyla aktivasyon haritasının yüksekliği, genişliği ve kanal sayısını temsil eder. x_{ijk} , aktivasyon haritasındaki i numaralı satır, j numaralı sütun ve k numaralı kanaldaki piksel değerini belirtir.

Bu denklemler, her bir mini-batch içindeki tüm piksel değerlerinin toplamını alarak ortalama değeri hesaplar ve piksel değerlerinin ortalama etrafında nasıl dağıldığını ölçmek için varyansı hesaplar. Bu değerler, aktivasyon haritasının her bir kanalı için ayrı ayrı hesaplanır.


Hesaplanan değerler aktivasyon kanallarının dağılımını standardize etmek için kullanılır. Hesaplanan ortalamalar ve varyanslar kullanılarak, her bir aktivasyon haritasındaki piksel değerleri normal dağılıma göre yeniden ölçeklenir, böylece aktivasyonların daha kararlı bir şekilde dağılması sağlanır ve ağı daha hızlı eğitilmesine yardımcı olur. BN katmanı, normalizasyon işlemi için öğrenilebilir iki parametre içerir: ölçekleme ve kayma. Bu parametreler, aktivasyonların ölçeklenmesi ve kaydırılması için kullanılır ve ağı öğrenme kapasitesini artırır. Eğitim sırasında hesaplanan mini-batch istatistikleri, test sırasında kullanılmaz. Bunun yerine, genellikle test sırasında ağı tamamı boyunca hesaplanan toplu istatistikler kullanılır, bu da modelin daha iyi genelleme yapmasına ve daha iyi performans göstermesine yardımcı olur.

1.6.4. Mish Aktivasyon Fonksiyonu

YOLOv5'te kullanılan "Mish" aktivasyon fonksiyonu, daha önce ReLU (Rectified Linear Unit), Sızıntı (Leaky) ReLU ve Sigmoid gibi popüler aktivasyon fonksiyonlarının yerini almayı hedefleyen bir tür aktivasyon fonksiyonudur. Mish, tanh fonksiyonuna benzer bir şekilde yumuşak bir şekilde sıfıra yakınsar ve bu nedenle negatif değerlerle daha iyi başa çıkar.

$$Mish(x) = x \times \tanh(\text{softplus}(x)) \quad (1.4)$$

Mish fonksiyonunun matematiksel formülü denklem 1.4'de verilmiştir. Burada $\text{softplus}(x)$ fonksiyonu, x değerinin yumuşak (soft) ReLU ($\text{ReLU}(x) = \log(1 + e^x)$) aktivasyon fonksiyonuna karşılık gelen eğrisel bir versiyonudur.



Şekil 6. Mish aktivasyon fonksiyonu

Şekil 6'da gösterilen Mish aktivasyon fonksiyonunun avantajlarından biri, modelin eğitim sürecinde daha istikrarlı bir şekilde davranmasıdır. Ayrıca, aktivasyon fonksiyonunun türevi olan Mish'in, daha sık kullanılan aktivasyon fonksiyonlarından daha yumuşak olması nedeniyle, gradient patlaması veya kaybolma sorunlarına karşı daha dirençlidir.

YOLOv5, bu aktivasyon fonksiyonunu kullanarak daha hızlı ve daha dengeli bir şekilde eğitilmiş modeller elde etmeyi amaçlamaktadır.

1.7. Makine Öğrenmesi Yöntemlerine Dayalı Görüntü Segmentasyonu

Makine öğrenimiyle segmentasyon, bir görüntüyü farklı bölgelere veya segmentlere ayırma işlemidir. Bu işlem, bir görüntüdeki piksellerin belirli özelliklere (renk, parlaklık, kenarlar vb.) göre gruplandırılması ve benzer özelliklere sahip piksellerin aynı segmente atanmasıyla gerçekleştirilir. Genel olarak, makine öğrenmesi tabanlı segmentasyon yöntemleri şu adımları içerir:


- **Veri Hazırlığı:** İlk adım, görüntünün yüklenmesi ve ön işleme adımlarının uygulanmasıdır. Bu adımlar arasında gürültü giderme, renk dönüşümü ve boyut düşürme bulunabilir.
- **Özellik Çıkarma:** Her piksel için belirli özelliklerin hesaplanması gereklidir. Bu özellikler, renk, parlaklık, kenarlar veya dokular gibi pikselleri tanımlayan özellikler olabilir.
- **Kümeleme:** Elde edilen özellikler kullanılarak pikseller kümeler ayrılır. Kümeleme algoritması, piksellerin benzer özelliklere sahip olanları bir araya getirir. Bu adımda yaygın olarak kullanılan algoritmalar arasında K-means, K-en yakın komşu (KNN) ve Hiyerarşik Kümeleme bulunur.
- **Sonuçların İyileştirilmesi:** Elde edilen segmentasyon sonuçları, bir dizi filtreleme ve düzeltme adımından geçirilir. Bu adımlar, segmentler arasındaki sınırları düzeltmek ve sonuçları daha tutarlı hale getirmek için kullanılır.

Bu bölümde görüntü segmentasyonu amacıyla sıklıkla kullanılan klasik makine öğrenmesi yöntemleri (KNN) ve sınıf dengesizliği bulunan veri kümeleri için kullanılan makine öğrenmesi yöntemleri (Random Forest, Adaptive Boosting, Balanced Bagging) anlatılacaktır.

1.7.1. K-En Yakın Komşuluk Algoritması

K-En Yakın Komşu (K-NN) (Peterson, 2009) algoritması, sınıflandırma ve regresyon problemleri için kullanılan, veri noktalarının benzerliğine dayalı olarak tahminler yapan basit ve etkili bir makine öğrenmesi algoritmasıdır. Bir veri noktasının sınıfını veya değerini

belirlemek için, bu noktaya en yakın K komşuyu bulur. Ardından, bu komşuların sınıflarının çoğunluğunu veya değerlerinin ortalamasını kullanarak tahminde bulunur. Örneğin şekil 7’de verilen A,B ve C sınıfına ait örneklerden oluşmuş bir yapıda herhangi P_x noktası için, noktanın diğer kümelerdeki K=6 adet en yakın komşularına bakılır. Bu yakınlık hesaplanırken ek 7(A)’da bulunan mesafe hesaplama denklemleri kullanılır. P_x noktası komşuluk sayısının daha fazla olduğu kümeye dahil edilir. Bu yaklaşım, algoritmanın farklı veri yapılarına uyum sağlamasını sağlar ve verilerin yerel yapısına dayalı olarak tahminlerde bulunmasına imkan tanır.



Şekil 7. K-En yakın Komşuluk Algoritmasının Çalışma Prensipleri

Öncelikle, öğrenme aşamasında, K-NN algoritması veri kümesini belleğe yükler ve eğitim verileri ile etiketlerini içeren bir veri seti kullanır. Ardından, tahmin aşamasında, algoritma test verileri için en yakın k komşuları belirler ve bu komşuların sınıflarını veya değerlerini kullanarak test verilerinin sınıfını veya değerini tahmin eder. K değeri, komşuların sayısını belirler ve genellikle çapraz doğrulama tekniği ile belirlenir.

K-NN algoritması, segmentasyon için kullanılan bir makine öğrenmesi algoritmasıdır. Her pikselin belirli özelliklere (örneğin, renk değeri) göre bir uzayda temsil edildiği bir eğitim veri setine dayanır. Ardından, her pikselin sınıfını veya segmentini tahmin etmek için en yakın K adet komşusuna bakar.

K-NN algoritması uygulanırken eğitim veri seti yüklendikten sonra, her piksel için belirli özelliklerin hesaplanması aşamasına geçilir. Bu özellikler, genellikle renk, parlaklık, kenarlar gibi görüntünün karakteristik özellikleridir. Özelliklerin hesaplanması, her pikselin

benzersiz özellik vektörünü oluşturur ve bu vektörler eğitim veri setindeki her görüntü için elde edilir.

Test görüntüsündeki her piksel için de aynı özellikler hesaplanır. Bu adım, test verilerinin hazırlanması olarak adlandırılır. Test verileri, genellikle eğitim veri setinden farklı görüntülerden oluşur ve algoritmanın performansını değerlendirmek için kullanılır.

En yakın komşuların bulunması adımı, her test pikseli için eğitim veri setindeki en yakın K adet komşusu belirlenir. Bu komşuların sınıfı veya segmenti, test pikselinin tahmin edilen sınıfı veya segmenti olarak kullanılır. En yakın komşular, genellikle öklid mesafesi veya benzer bir mesafe ölçütü kullanılarak belirlenir.


Son olarak, elde edilen segmentasyon sonuçları bir dizi filtreleme ve düzeltme adımından geçirilir. Bu adımlar, segmentler arasındaki sınırları düzeltmek ve sonuçları daha tutarlı hale getirmek için kullanılır. Özellikle, gürültüyü azaltmak, küçük segmentleri birleştirmek veya büyük segmentleri bölerek daha doğru sonuçlar elde etmek için filtreleme teknikleri kullanılabilir. Bu iyileştirme adımları, genellikle algoritmanın başarımını artırmak için gereklidir.

1.7.2. Rastgele Ormanlar Sınıflandırıcısı

Rastgele Orman (Random Forest) Breiman (2001), temelde birden fazla karar ağacının bir araya gelerek güçlü bir sınıflandırıcı veya regresyon modeli oluşturduğu bir makine öğrenimi algoritmasıdır. Bu algoritma, veri setinin farklı alt kümeleri ve özelliklerinin rastgele seçilerek her bir karar ağacının eğitiminde kullanılmasını içerir.

Rastgele Orman algoritmasının çalışma prensibi Şekil 8'da verilen diyagramla açıklanmıştır. Diyagramda n adet karar ağacından oluşan rastgele bir orman ve ilk 5 ağacın tahminleriyle birlikte gösterilmiştir ("Sınıf A" veya "Sınıf B"). Her ağaç farklı sayıda özelliğe ve orijinal veri kümesinin farklı bir örneğine maruz kalır ve bu nedenle her ağaç farklı olabilir. Her ağaç bir tahminde bulunur. İlk 5 ağaca bakıldığında, ağaçların örneklerin 4/5'inin A sınıfına ait olduğunu tahmin ettiği görülmektedir. Yeşil daireler, ağacın kararına ulaşmak için izlediği varsayımsal yolu göstermektedir. Rastgele orman, A sınıfı ve B sınıfı için karar ağaçlarından tahminlerin sayısını sayar ve en popüler tahmini seçer.

Rastgele Orman algoritması, veri setini işlemek için bir dizi adımdan oluşur. İlk adım, veri setinin rastgele alt kümelerinin oluşturulmasıdır. Bu alt kümeler, genellikle çekilme (bootstrap) yöntemi ile rastgele örneklenir ve her biri orijinal veri setinden farklı örnekler



Şekil 8. Rastgele Orman Algoritmasının Çalışma Prensibi

içerir. Böylece her bir karar ağacı, farklı bir veri alt kümesiyle eğitilir. Ardından, özellik seçimi yapılır. Karar ağaçları oluşturulurken, her düğümde kullanılacak özellikler rastgele seçilir, bu da her bir karar ağacının farklı özellikler üzerinde eğitilmesini sağlar. Her bir alt küme ve rastgele seçilen özellikler kullanılarak birçok karar ağacı oluşturulur. Her bir karar ağacı, veri setinin farklı bir alt kümesi üzerinde eğitilir ve her düğümde en iyi bölünmeyi yapacak özelliği seçerek sınıflandırma veya regresyon yapar. Test verileri geldiğinde, her bir karar ağacı için ayrı ayrı tahminler yapılır. Sınıflandırma için, her ağaç test örneğini sınıflandırır ve en popüler sınıf tahmin edilir. Regresyon için ise, her ağaç test örneğini tahmin eder ve bu tahminlerin ortalaması alınarak nihai tahmin elde edilir. Son olarak, her bir karar ağacının tahminleri ek 7(B)'de anlatılan şekilde bir araya getirilerek toplu bir tahmin yapılır. Bu, sınıflandırma durumunda en popüler sınıfın seçilmesi veya regresyon durumunda ortalama değer hesaplanması anlamına gelir.

Rastgele Orman algoritması, her bir karar ağacının kendi içindeki varyansı azaltarak ve birlikte çalışarak daha güçlü ve kararlı bir model oluşturarak sınıflandırma veya regresyon problemlerinde genellikle başarılı sonuçlar verir.

Random Forest sınıflandırıcı, makine öğrenimi alanında yaygın olarak kullanılan ve özellikle sınıflandırma problemlerinde etkili olan bir algoritmadır. Ancak, doğrudan görüntü segmentasyonu için kullanılması nadirdir. Görüntü segmentasyonu genellikle derin öğrenme modelleriyle gerçekleştirilirken, Random Forest sınıflandırıcının görüntü segmentasyonunda kullanılması için farklı bir yaklaşım gerekmektedir. Bu nedenle, Random Forest sınıflandırıcı

ile görüntü segmentasyonunu anlatmak, geleneksel segmentasyon tekniklerine dayalı bir yaklaşım gerektirir.


Görüntü segmentasyonu, bir görüntüyü farklı bölgelere veya nesnelere ayırmak için kullanılan bir işlemdir. Random Forest sınıflandırıcı, bu segmentasyon sürecinde kullanılabilecek çeşitli özelliklerle eğitilmiş bir sınıflandırıcıdır. Genellikle, bir görüntüyü segmente etmek için aşağıdaki adımlar izlenir:

Görüntü segmentasyonu için, öncelikle eğitim verileri hazırlanmalıdır. Bu adımda, görüntüler ve bu görüntülerin sahip olduğu etiketler (segmentasyon maskeleri) kullanılır, her pikselin ait olduğu sınıfı belirten etiketler özellikle eğitim veri setinde gereklidir. Daha sonra, her piksel için özellik vektörleri çıkarılır. Bu özellikler, pikselin rengi, parlaklığı, kenar bilgileri gibi özelliklerden oluşabilir ve pikselleri farklı sınıflara ayırmak için kullanılır. Ardından, eğitim veri seti Random Forest sınıflandırıcıya giriş olarak verilir ve algoritma bu veri setini kullanarak birçok karar ağacı oluşturur. Her ağaç, rastgele seçilen alt özellikler ve veri noktalarının alt kümeleriyle eğitilir. Test görüntüsündeki her piksel için, özellik vektörleri hesaplanır ve bu vektörler Random Forest sınıflandırıcıya verilir. Algoritma, her pikselin hangi sınıfa ait olduğunu tahmin etmek için bu özellik vektörlerini kullanır ve her pikselin tahmin edilen sınıfı, görüntü segmentasyonunu oluşturmak için kullanılır. Son olarak, elde edilen segmentasyon sonuçları bir dizi filtreleme ve düzeltme adımından geçirilir. Bu adımlar, segmentler arasındaki sınırları düzeltmek, gürültüyü azaltmak ve sonuçları daha tutarlı hale getirmek için kullanılır.

Random Forest sınıflandırıcı, her pikselin sınıfını bağımsız olarak tahmin ettiği için, genellikle daha basit görüntü segmentasyon problemleri için kullanılır. Ancak, derin öğrenme tekniklerinin kullanılabilirliği arttıkça, daha karmaşık ve doğru sonuçlar veren modellerle yer değiştirmiştir. Bu nedenle, Random Forest sınıflandırıcının görüntü segmentasyonunda kullanımı genellikle basit veya hızlı çözümler için tercih edilir.

1.7.3. Uyarlanabilir Güçlendirme (AdaBoost)

AdaBoost (Adaptive Boosting), iteratif bir yaklaşımla her bir zayıf öğrencinin gücünü ve daha önce hatalı sınıflandırılan örneklerin ağırlıklarını artırarak yeni öğrenciler oluşturan bir makine öğrenimi algoritmasıdır. Zayıf öğrencileri bir araya getirerek güçlü bir sınıflandırıcı elde etmekte ve genellikle yüksek doğruluk oranlarına ulaşabilmektedir.



Şekil 9. AdaBoost algoritmasının çalışma prensibi

AdaBoost, genellikle sınıflandırma problemleri için kullanılan bir topluluk (ensemble) yöntemidir ve özellikle ikili sınıflandırma görevlerinde etkilidir.


Şekil 9’de gösterilen AdaBoost algoritması ile eğitim yapılırken, başlangıçta, tüm eğitim veri setine eşit ağırlıklar atanır. Her bir veri noktası, modelin eğitilmesinde aynı derecede öneme sahiptir. İlk adım olarak zayıf öğrenici oluşturulur ve eğitilir. Bu zayıf öğrenici, veri setindeki gözlemleri en iyi şekilde sınıflandırmaya çalışır. Daha sonra zayıf öğrenicinin performansı değerlendirilir ve hatalı sınıflandırılan örneklerin ağırlıkları artırılır. Böylece, hatalı sınıflandırılan örneklerin daha fazla dikkate alınması sağlanır. İkinci adımda olarak ikinci zayıf öğrenici oluşturulur ve eğitilir. Ancak bu sefer, hatalı sınıflandırılan örneklerin ağırlığı daha fazla olduğu için, bu öğrenici daha fazla bu örnekleri doğru sınıflandırmaya çalışır. İlk ve ikinci adımlar, belirlenen bir maksimum sayıya veya bir performans ölçütüne ulaşılan kadar tekrarlanır. Her bir zayıf öğrenici, önceki öğrenicilerin hatalarını düzeltmeye odaklanır. En sonunda tüm zayıf öğreniciler bir araya getirilerek, her bir öğrenicinin tahminlerine göre ağırlıklı bir oylama yapılır. Bu şekilde, tüm zayıf öğrenicilerin katkısı bir araya getirilerek güçlü bir sınıflandırıcı elde edilir.

1.7.4. Balanced Bagging (Dengeli Torbalama)

Balanced Bagging sınıflandırıcısı, dengesiz sınıflandırma problemleriyle başa çıkmak için tasarlanmış bir topluluk (ensemble) öğrenme yöntemidir. Dengesiz sınıflandırma problemleri, sınıflar arasında gözlemlenen farkların oranı büyük olduğunda ortaya çıkar. Bu durumda, modelin sayıca çoğunluğu olan sınıfı tanımlaması ve diğer nadir sınıfı ihmal etmesi mümkündür. Bu tür dengesizlikler, modelin yanlış sınıflandırma yapmasına ve düşük performans göstermesine neden olabilir.

Balanced Bagging sınıflandırıcısı, dengesizlik problemlerini ele almak için Bagging (Bootstrap Aggregating) yöntemini kullanır. Bagging, farklı alt örneklemeler (bootstrap samples) kullanarak birden çok modelin eğitilmesini içeren bir topluluk öğrenme tekniğidir. Her bir alt örneklem, orijinal veri setinden rastgele seçilen gruptan oluşur. Bagging'in temel amacı, farklı veri alt kümelerinde eğitilen modellerin çeşitliliğini artırarak modelin genelleme performansını iyileştirmektir.

Balanced Bagging sınıflandırıcısı, Bagging'in bu temel prensibini kullanarak, dengesiz sınıflandırma problemlerini ele almak için özelleştirilmiş bir yaklaşım sunar. Bu algoritma, her alt örneklemde dengeli bir sınıflandırma problemi oluşturmak için sınıflar arasında dengeleyici ağırlıklar kullanır. Yani, her bir alt örneklemde nadir sınıfın daha fazla temsil edilmesi sağlanır.



Şekil 10. Balanced Bagging algoritmasının çalışma prensibi

Şekil 10'da verilen Balanced Bagging sınıflandırıcısı işlemlere veri setinin seçilmesiyle başlar. Veri seti, dengeli bir sınıflandırma problemi oluşturmak için alt örneklemeler halinde

rastgele seçilir. Her bir alt örneklem, nadir sınıfın daha fazla temsil edildiği şekilde oluşturulur. Her bir alt örneklem üzerinde bir zayıf öğrenici eğitilir. Bu zayıf öğreniciler genellikle karar ağaçları veya destek vektör makineleri gibi basit modellerdir. Tüm zayıf öğrenicilerin tahminleri bir araya getirilir ve toplu bir tahmin yapılır. Sınıflandırma problemlerinde, genellikle tahminlerin modu alınır veya ağırlıklı bir oylama yapılır.

Balanced Bagging sınıflandırıcısı, Bagging'in temel avantajlarını korurken, aynı zamanda dengesiz sınıflandırma problemlerini ele almak için etkili bir yaklaşım sunar. Bu sayede, nadir sınıfın doğru şekilde sınıflandırılması ve modelin genel performansının artırılması sağlanır.

1.8. Derin Öğrenme Yöntemlerine Dayalı Görüntü Segmentasyonu

1.8.1. U-NET

UNET (Ronneberger vd., 2015) mimarisi, özellikle biyomedikal görüntü segmentasyonunda oldukça karakteristik ve yaygın olarak kullanılan bir derin öğrenme modelidir. Şekil 11'de verilen UNET mimarisinin aşamaları aşağıdaki gibidir:

- **Giriş:** UNET'in giriş katmanı, segmentasyon işlemi için işlenecek görüntünün boyutlarına sahiptir. Bu görüntü RGB formatında veya tek kanallı (örneğin siyah beyaz) olabilir.
- **Kodlayıcı (Encoder):** Kodlayıcı kısmı, giriş görüntüsünün boyutunu azaltır ve özelliklerini öğrenir. Tipik bir UNet kodlayıcı, konvolüsyon katmanları, aktivasyon fonksiyonları (genellikle ReLU), havuzlama katmanları ve toplu normalleştirme katmanları içerir. Konvolüsyon katmanları, giriş görüntüsünden yerel özellikler çıkarırken, özellik haritasının derinliğini artırırken boyutunu azaltır. Tipik olarak, her konvolüsyon katmanından sonra bir toplu normalleştirme ve aktivasyon fonksiyonu bulunur. Havuzlama katmanları, özellik haritasının boyutunu azaltarak hesaplama maliyetini azaltır.
- **Atlamalı Bağlantılar (Skip Connections):** UNet'in benzersiz bir özelliği, her kodlayıcı katmanının karşılık gelen bir dekode katmanına bağlanmasıdır. Bu bağlantılar, ağır temel yapısını oluşturur ve daha yüksek çözünürlüklü özellikleri korur. Atlamalı

bağlantılar, bir kodlayıcı katmanından gelen özellik haritasını karşılık gelen dekoder katmanının çıkış özellik haritasına ekler. Bu, daha derin katmanlarda kaybolan önemli detayları geri getirmeye yardımcı olur. Atlamalı bağlantılar, daha keskin ve daha doğru segmentasyon sonuçları elde etmek için oldukça önemlidir. Ayrıca eğitimi hızlandırabilir ve aşırı uyum riskini azaltabilirler.

- **Kod Çözücü (Decoder):** Kod çözücü kısmı, kodlayıcı tarafından öğrenilen özellikleri kullanarak giriş görüntüsünün segmentasyonunu gerçekleştirir. Dekodlayıcıda kullanılan transpoz konvolüsyon veya konvolüsyon katmanları, özellik haritasının boyutunu arttırarak görüntüyü orijinal boyutuna geri getirir. Her dekodlayıcı katmanında, atlamalı bağlantılar aracılığıyla eklenen özellik haritası, kodlayıcıdan gelen özellik haritasıyla birleştirilir. Bu, daha yüksek çözünürlüklü özellikleri korur. Dekodlayıcı genellikle segmentasyonu daha da iyileştirmek için konvolüsyon katmanları, aktivasyon fonksiyonları ve toplu normalleştirme katmanları içerir.
- **Çıkış:** UNET'in çıkış katmanı tamamen bağlı (fully connected) bir katmandır ve sonuç segmentasyon haritasını oluşturur. Bu durumda, her pikselin hangi sınıfa ait olduğunu belirten bir olasılık değeri alır.

Bu şekilde, UNET mimarisi, kodlayıcı ve kod çözücü arasındaki bağlantılar sayesinde kodlanmış özelliklerin daha yüksek çözünürlüklü kod çözücü aşamalarına iletilmesini sağlar. Bu simetrik yapı ve atlamalı bağlantılar, ağıın öğrenme yeteneğini artırır ve yüksek seviyeli evrimsel özellikleri ayrıntılı sınırlar. Sonra bunları yapısal bilgilerle birleştirerek daha hassas ve doğru segmentasyon sonuçları elde etmeyi sağlar.

UNET mimarisinin katmanlarının işlevleri detaylı bir şekilde aşağıda verilmiştir:

- **Konvolüsyon Katmanı:** UNet mimarisinde, konvolüsyon katmanı özellik çıkarma ve temsil öğrenme için temel yapı taşıdır. Konvolüsyon katmanının UNet içinde kullanılma nedenleri ve ilişkilendirilen amaçlar şunlardır:
 - **Özellik Çıkarma:** Konvolüsyon katmanı, giriş görüntülerinden özellikleri çıkarmak için öğrenilebilir filtrelerin (çekirdeklerin) küçük bölgelere uygulanmasıyla kullanılır. Bu filtreler, kenarlar, dokular, şekiller ve daha yüksek seviyeli yapılar gibi farklı uzamsal ölçeklerde desenleri ve özellikleri algılar.

- Yerel Bağlantılılık: Konvolüsyon katmanı, giriş verisinin yerel bağlantılılığını kullanır. Her bir nöronun önceki katmandaki tüm nöronlara bağlanması yerine, konvolüsyon katmanında seyrek bağlantılar bulunur; her bir nöron yalnızca girişin küçük bir yerel bölgesine bağlanır. Bu yerel bağlantılılık, uzamsal bağımlılıkları yakalamaya ve parametre paylaşımını teşvik etmeye yardımcı olur, bu da daha etkili öğrenmeye yol açar.
- Çevirimsel Özdeşlik: Konvolüsyon katmanı, ağı giriş görüntüsündeki desenleri, desenlerin konumundan bağımsız olarak tanımasını sağlar. Bu özellik, nesne tanıma ve sınıflandırma gibi görevler için önemlidir, çünkü görüntü içindeki nesnelerin konumu değişebilir.
- Hiyerarşik Temsil: Bilgi, ardışık konvolüsyon katmanları boyunca aktıkça, ağ giriş verisinin giderek soyut ve hiyerarşik temsillerini öğrenir. Alt katmanlar, kenarlar ve dokular gibi düşük seviyeli özellikleri yakalarken, üst katmanlar daha karmaşık ve soyut özellikleri, örneğin nesne parçalarını ve anlamsal kavramları yakalar.
- Parametre Paylaşımı: Konvolüsyon katmanları, aynı filtre setinin girişin farklı uzamsal konumlarına uygulandığı parametre paylaşımını kullanır. Bu parametre paylaşımı düzeni, ağıdaki parametre sayısını azaltır, ağı daha verimli hale getirir ve özellikle eğitim verisi sınırlı olduğunda aşırı uydurmayı önler.

Genel olarak, UNet içindeki konvolüsyon katmanları, giriş görüntülerinden hiyerarşik özellikler çıkarmak, çevirimsel özdeşlik sağlamak, yerel bağlantılılığı kullanmak ve etkili bir parametre paylaşımı yapmak için kritik bir rol oynar. Bu özellikler, görüntü segmentasyonu gibi görevler için konvolüsyon katmanlarını uygun hale getirir, çünkü giriş verisinin uzamsal yapısını ve bağlamını anlamak önemlidir.

- Toplu normalizasyon (BN): Eğitim hızını, kararlılığı ve performansı artırmak için UNet mimarisi dahil derin sinir ağlarında yaygın olarak kullanılan bir tekniktir. Eğitim sırasında genellikle her mini-batch için katmanların aktivasyonlarını ayarlayarak ve ölçeklendirerek normalleştirir. Toplu normalizasyonun çeşitli amaçları ve getirdiği birkaç faydası aşağıda özetlenmiştir:

- Eğitimi Hızlandırma: Toplu normalizasyon, eğitim sırasında kaybolan veya patlayan gradyanların sorununu azaltarak daha hızlı yakınsamaya olanak tanır.

Her katmana girişleri normalleştirerek, aktivasyonları uygun bir aralıkta tutarak aktivasyon fonksiyonlarının doymasını önler ve kararlı gradyanlar sağlar.

- Regularizasyon: Toplu normalizasyon, her katmanın aktivasyonlarına biraz gürültü ekleyerek bir tür düzenleme olarak hareket eder. Bu gürültü, aşırı uyumu azaltarak modelin daha iyi genelleme yapmasına olanak tanır.
- Kovaryans Kayması Azaltma: Kovaryans kayması, önceki katmanların parametreleri değiştikçe ağ aktivasyonlarının dağılımında meydana gelen değişikliği ifade eder. Toplu normalizasyon, her katmandaki aktivasyonları normalleştirerek kovaryans kaymasını azaltır, bu da eğitim sürecini daha istikrarlı hale getirir ve daha yüksek öğrenme hızları kullanılmasına olanak tanır.
- Daha Yüksek Öğrenme Oranları Sağlama: Toplu normalizasyon ile ağlar genellikle kararsızlık sorunları yaşamadan daha yüksek öğrenme oranları kullanabilir. Bu, eğitim sürecini hızlandırır ve daha hızlı yakınsamaya yol açabilir.
- Gradyan Akışını İyileştirme: Aktivasyonları normalleştirerek, toplu normalizasyon gradyanların ağ boyunca düzgün bir şekilde akmasını sağlayarak geriye yayılım sürecini daha verimli hale getirir.

Genel olarak, toplu normalizasyon, derin sinir ağlarını eğitirken karşılaşılan çeşitli zorlukları ele almak ve daha hızlı yakınsama, daha iyi genelleme ve daha kararlı eğitim dinamikleri sağlamak için UNet gibi derin modellerde önemli bir bileşendir.

- Aktivasyon Fonksiyonu: UNet mimarisinde olduğu gibi, birçok derin sinir ağında aktivasyon işlevleri birkaç önemli amaç için kullanılır ve her katmanın önemli bileşenleridir. Bir aktivasyon işlevinin temel rolü, ağın giriş ve çıkış arasında karmaşık eşlemeleri öğrenmesini sağlayarak ağa doğrusal olmayanlık kazandırmaktır. UNet'te aktivasyon fonksiyonu kullanımının amaçları ve sonuca etkileri aşağıda verilmiştir:
 - Doğrusal Olmayanlık: Aktivasyon işlevleri, ağa doğrusal olmayanlık kazandırarak giriş özellikleri ile çıkış tahminleri arasındaki karmaşık ilişkileri modellemesine olanak tanır. Aktivasyon işlevleri olmadan, tüm sinir ağı bir doğrusal işlev haline gelir ve verinin karmaşık desenlerini öğrenme yeteneği ciddi şekilde sınırlanır.
 - Karmaşık Temsillerin Öğrenilmesini Sağlama: Doğrusal olmayan dönüşümler aracılığıyla, aktivasyon işlevleri ağın giriş verilerinin karmaşık temsillerini

öğrenmesini sağlar. Bu özellik özellikle pikseller veya özellikler arasındaki ilişkilerin oldukça doğrusal olmayan olduğu görüntü segmentasyonu gibi görevlerde önemlidir ve sofistike modellenmeye ihtiyaç duyar.

- Gradyan Yayılımı: Aktivasyon işlevleri, eğitim sırasında gradyanların geriye yayılmasını kolaylaştırarak iyi tanımlanmış türevler sağlar. Bu, ağı stokastik gradyan iniş (SGD) gibi gradyan tabanlı optimizasyon algoritmalarını veya Adam gibi türevlerini kullanarak parametrelerini verimli bir şekilde güncellemesine olanak tanır.
- Eğitimi Stabilize Etme: Aktivasyon işlevleri, eğitim sürecini istikrarlı hale getirme rolü oynar ve kaybolan veya patlayan gradyanlar gibi sorunları önler. Doğrusal olmayanlık kazandırarak, aktivasyon işlevleri ağı üzerinden yayılan gradyanların büyüklüğünü kontrol etmeye yardımcı olur ve daha stabil ve verimli bir eğitim sağlar.
- Çıkış Aralığını Kontrol Etme: Aktivasyon işlevleri, her bir nöronun ürettiği çıkış değerlerinin aralığını kontrol edebilir. Örneğin, sigmoid veya tanh gibi aktivasyon işlevleri, çıkış değerlerini belirli bir aralığa (örneğin, sigmoid için 0 ile 1 arası) sıkıştırabilir, bu da belirli türdeki görevler veya ağı mimarileri için faydalı olabilir.

Özellikle UNet’te, yaygın olarak kullanılan aktivasyon işlevleri ReLU (Doğrusal Birim Düzeltme) gibi, basitliği ve etkililiği nedeniyle standart bir seçenek haline gelmiştir. Bu aktivasyon işlevi, UNet’in biyomedikal görüntülerde karmaşık ilişkileri etkili bir şekilde modellemesine ve ilgi alanlarını yüksek doğrulukla segmente etmesine yardımcı olur.

- Havuzlama: UNet mimarisindeki havuzlama (pooling) katmanı, birkaç amaç için kullanılır ve stratejik olarak yerleştirilirler, bu da örnekleme işlemlerini gerçekleştirmek için. UNet’te havuzlama katmanının neden kullanıldığı ve ilişkilendirilen amaçları aşağıda verilmiştir:


- Boyut Azaltma: Havuzlama katmanları, özellik haritalarının (genişlik ve yükseklik) mekansal boyutlarını azaltmak için kullanılırken, önemli bilgilerini korurlar. UNet’te bu azaltma, bağlamı etkili bir şekilde yakalamak ve hesaplama karmaşıklığını azaltmak için kritiktir.

- Çeviri Bağımsızlığı: Havuzlama, belirli bir dereceye kadar çeviri bağımsızlığı elde etmede yardımcı olur. Yakındaki pikselleri tek bir temsilci değere (örneğin, maksimum veya ortalama) toplamak, havuzlama katmanlarının ağı girdi görüntüsündeki küçük mekansal çevirilere karşı daha az duyarlı hale getirir. Bu özellik, anlamsal bölütleme gibi kesin konumlandırmanın gerekli olmadığı görevlerde yararlıdır.
- Özellik Konumlandırma: Mekansal boyutları azaltmasına rağmen, havuzlama katmanları yerel komşuluklardan en uygun bilgiyi seçerek önemli özellikleri korumaya yardımcı olur. Bu özellik konumlandırma yeteneği, nesnelerin kesin konumlandırmasının gerektiği anlamsal bölütleme gibi görevler için önemlidir.
- Parametre Azaltma: Özellik haritalarının mekansal boyutlarını azaltarak, havuzlama katmanları ağıdaki parametre sayısını azaltmaya katkıda bulunur. Bu parametrelerin azaltılması, aşırı uyumu kontrol etmeye ve ağı hesaplama verimliliğini artırmaya yardımcı olur.
- Alıcı Alanı Artırma: Havuzlama katmanları, özellikle maksimum havuzlama, ağı alıcı alanını genişletir. Bu, özellik haritasındaki her bir birimin, girdi görüntüsünün daha büyük bir alanını kapsadığı anlamına gelir, bu da ağı daha fazla genel bağlam bilgisini yakalamasına olanak tanır.

Genel olarak, havuzlama katmanları, mekansal boyutları azaltarak, çeviri bağımsızlığını artırarak, önemli özellikleri koruyarak, aşırı uyumu kontrol ederek ve alıcı alanı genişleterek, UNet mimarisinde önemli bir rol oynar. Bu özellikler, biyomedikal görüntü bölütleme ve mekansal bağlamın ve kesin konumlandırmanın önemli olduğu diğer görevlerde UNet'in etkinliğine katkıda bulunur.


1.8.2. SegNet

SegNet (Badrinarayanan vd., 2017), görüntü segmentasyonu için kullanılan bir derin öğrenme mimarisidir. Temel olarak, giriş bir görüntüdür, ve çıkışta her pikselin ait olduğu sınıfı belirten bir etiket haritasıdır. SegNet Şekil 12'de gösterildiği gibi mimarisi, özellikle yol ve trafik sahnelerinin segmentasyonu gibi görevlerde kullanılmak üzere tasarlanmıştır. SegNet mimarisinin ana özellikleri şu şekildedir:



Şekil 11. UNET mimarisi

- **Kodlayıcı -Kod Çözücü (Encoder-Decoder) Yapısı:** SegNet, diğer segmentasyon ağırları gibi bir "kodlayıcı-kod çözücü" mimarisine sahiptir. Kodlayıcı, giriş görüntüyü temsil eden özellik haritalarını üretir. Bu özellik haritaları, görüntünün önemli özelliklerini öğrenir. Kod çözücü, bu özellik haritalarını kullanarak her pikselin sınıfını belirten bir etiket haritasını üretir.
- **Yapay Sinir Ağları (CNN) Kullanımı:** SegNet, derin öğrenme modeli olarak temel olarak Convolutional Neural Network'leri (CNN) kullanır. CNN'ler, özellikle görüntü işleme görevleri için başarılı olan katmanlardan oluşan bir mimari sunar.
- **Maksimum Havuzlama:** SegNet'in dikkate değer bir özelliği, "maksimum havuzlama" (max-pooling) ve havuzlama sırasında öğrenilen en büyük değerleri kullanarak "havuzdan çıkarma" (unpooling) işlemidir. Bu, özellik haritalarını küçültmek ve ardından tekrar genişletmek için kullanılır.
- **Atlama Bağlantıları:** SegNet, skip bağlantılarını kullanarak farklı katmanlardan bilgileri birleştirir. Bu, düşük seviyeli özelliklerin, yüksek seviyeli özelliklerle birleştirilerek daha iyi bir segmentasyon performansı elde edilmesine yardımcı olur.
- **Softmax Aktivasyonu:** Çıkış katmanında genellikle Softmax aktivasyonu kullanılır. Bu, her pikselin sınıf olasılıklarını üretir.




Şekil 12. SegNET mimarisi

SegNet, özellikle görüntü segmentasyonu görevlerinde iyi performans gösteren bir mimaridir.

1.8.3. FCN

Tam evrişimli ağ (FCN), görüntü segmentasyonu için özel olarak tasarlanmış bir derin öğrenme mimarisidir. Giriş olarak bir görüntü alır ve çıkış olarak her pikselin ait olduğu sınıfı belirten bir etiket haritasını üretir. Şekil 13'de gösterilen FCN mimarisinin ana özellikleri şu şekildedir:



Şekil 13. FCN mimarisi

- Pooling ve Unpooling İşlemleri: FCN’de özellikle pooling ve unpooling işlemleri kullanılır. Max-pooling işlemi, özellik haritasını küçültmek için kullanılırken, unpooling işlemi, bu küçültülmüş haritayı yeniden orijinal boyutuna getirmek için kullanılır. Bu sayede, netlik ve lokalizasyon yetenekleri artar.
- Atlama Bağlantıları: FCN, geleneksel CNN’lerden farklı olarak, skip connection’lar veya bağlantıları kullanır. Bu bağlantılar, düşük seviyeli özellikleri daha yüksek seviyeli özelliklerle birleştirir. Bu, ağın hem detaylı hem de genel özellikleri öğrenmesine yardımcı olur.
- Transpoze Konvolüsyonlar: FCN, transpoze konvolüsyon katmanları kullanarak özellik haritasını genişletir. Bu katmanlar, özellik haritasını yeniden boyutlandırmak için kullanılır ve girişin daha düşük çözünürlükteki bir temsilini oluşturur.
- Softmax Aktivasyonu: FCN’nin çıkış katmanında genellikle Softmax aktivasyonu kullanılır. Bu, her pikselin sınıf olasılıklarını üretir.

FCN, özellikle yüksek çözünürlüklü görüntülerde segmentasyon görevlerinde başarılıdır. Bu tip mimariler, geleneksel olarak sınıf etiketlemesi için kullanılan CNN mimarilerini, piksel düzeyinde segmentasyon görevlerine adapte eder.

2. YAPILAN ÇALIŞMALAR

Bu çalışmada, ekokardiyografik görüntüler üzerinde aort ilgi bölgesinin tespiti ve ekokardiyografi görüntülerinden aort bölgesinde bulunan kalsifik alanların belirlenmesi için kullanılan makine öğrenmesine ve derin öğrenmeye dayalı bilgisayar destekli tanı yaklaşımları irdelenmiştir. Ekokardiyografi görüntülerinden kalsifik alan tespiti için daha önce gerçekleştirilen çalışmalar analiz edildiğinde tez çalışmasında temel olarak sırasıyla aşağıda verilen unsurların iyileştirilmesi hedeflenmiştir:

- Ekokardiyografi görüntüleri üzerinde aort ilgi bölgesi tespitinde genel olarak CNN tabanlı mimariler kullanılmıştır. Bu çalışmada aort bölgesinin tespiti için ilk kez YOLOv5 mimarisi kullanılmıştır.
- Literatürde açık veya özel veri setleri üzerinde yapılan çalışmalara bakıldığında genellikle aort ilgi bölgesinde kalsifikasyon segmentasyonu işleminin sadece BT görüntüleri kullanılarak yapıldığı görülmüştür. Literatürdeki bu boşluğu doldurmak amacıyla, ilk kez ekokardiyografi görüntüleri üzerinden kalsifik alanların segmentasyonu gerçekleştirilmiştir.
- Aort ilgi bölgesinin tespit edilmesi için kullanılan model üzerinde değişiklikler yapılmış ve yeni bir model önerilmiştir. Önerilen modelin diğer modele göre katman sayısının az olması, tahmin bileşeninde daha az ölçek kullanılması ve daha etkili bir konvolüsyon yöntemi kullanılması ağ performansını olumlu yönde etkilemiş ve test süresini oldukça kısaltmıştır. Modelin basitleştirilmesi ve test süresinin kısaltılması, önerilen yöntemin gerçek zamanlı uygulamalarda kullanılabilmesi için büyük avantaj sağlamıştır.
- Literatürde aort bölge tespiti için ekokardiyografi görüntüleri ile oluşturulmuş açık bir veri seti bulunmamaktadır. Aort bölge tespiti için ekokardiyografi görüntülerinden oluşan yeni büyük bir veri seti önerilmesi elde edilecek sonuçları daha doğru ve güvenilir hale getirecektir.
- Literatürde aort bölgesinde bulunan kalsifik alan tespiti için ekokardiyografi görüntüleri ile oluşturulmuş bir veri seti bulunmamaktadır. Aort bölgesinde bulunan kalsifik alan tespiti için ekokardiyografi görüntülerinden oluşan yeni büyük bir veri seti önerilmesi elde edilecek sonuçları daha doğru ve güvenilir hale getirecektir.

Kalp kapakçıklarında kalsifikasyon tespit edilmesinde, literatüründe araştırmacılar tarafından üzerinde durulan problemlerin iyileştirilmesi ve boşlukların doldurulması tez kapsamında yapılan çalışmaların hedeflerini belirlemektedir. Bu bölümde genel bilgiler kısmında verilen kalpte aort ilgi bölgesinin algılanmasında ve aort bölgesinde bulunan kalsifik alanların tespit edilmesinde bilgisayar destekli tanı yaklaşımlarına yönelik önerilen yaklaşımlar irdelenerek verilen hedefler doğrultusunda iyileşme sağlayacak makine öğrenmesine ve derin öğrenmeye dayalı yeni yaklaşımlar önerilmektedir.

Kalsifik alanlar barındıran görüntülere öncelikle makine öğrenmesine dayalı ve genellikle sınıflandırma problemleri için kullanılan yöntemler veri setine göre uyarlanarak segmentasyon amacıyla kullanılmıştır.

Tam Konvolüsyonel Sinir Ağları semantik segmentasyon amacıyla konvolüsyonel sinir ağlarından uyarlanmışlardır. FCN, SegNet ve U-Net biyomedikal görüntülerin segmentasyonu amacıyla yaygın olarak kullanılan FCNN ağlarından olup birçok görüntü segmentasyonu problemine başarıyla uygulanmıştır (An & Liu, 2019; Zambrano-Vizute vd., 2022).

Tez çalışmasında popüler FCNN ağ modellerinden FCN, SegNet ve U-Net aort bölgesinde bulunan kalsifik alanları barındıran, ekokardiyografi görüntülerinden oluşan veri seti üzerinde sıfırdan eğitilmiştir. Bu modeller ile elde edilen segmentasyon başarısının makine öğrenmesine dayalı klasik ve topluluk modellerinin elde ettiği başarıyı geçtiği görülmüştür. Elde edilen sonuçlar bu alanda yapılan önceki çalışmalarla karşılaştırılmıştır.

Konvolüsyonel Sinir Ağları'nın nesne algılama alanında kullanılmaya başlanması ile birlikte Daha Hızlı R-CNN, R-FCN, SSD ve YOLO gibi birçok nesne algılayıcı önerilmiştir. Bu algılayıcılar genellikle büyük boyutlu nesnelerin (yüz, yaya, araç vb.) algılanmasında uygulanmıştır ve başarılı sonuçlar verdiği görülmüştür. Yapılan çalışmalardan anlaşıldığı üzere herhangi bir alanda hangi algılayıcının daha uygun olduğunu bilmek zordur ve yöntemlerin küçük boyutlu nesneler üzerinde çalışabilmesi için nasıl uygulanmaları gerektiği literatürde boşluk olarak görülmektedir. Elde edilen sonuçlar neticesinde gerçek zamanlı uygulamalar için en hızlı algılama sağlayan YOLOv5 mimarisinin başarısını belirli seviyede tutmayı hedefleyerek daha hızlı çalışması için YOLOv5 mimarisinde iyileştirmeler yapılmış ve farklı ağ mimarisi önerilmiştir. Bu çalışma aort ilgi bölgesinin tespit literatüründe pek çok karşılaştırmanın yapıldığı ve yüksek başarılı performans gösteren çalışma olma özelliğini taşımaktadır.

Tez çalışmasında aort ilgi bölgesinin tespiti için etkin ve basit bir model mimarisi (AVD-YOLOv5) önerilmiştir. Önerilen modelin basitliği, bilgisayar destekli tanı uygulamaları

için oldukça önemlidir, çünkü, kalpte aort bölgesinin belirlenmesi ve hastalıkların teşhisinde yaşanan sürecin hızlandırılması gerçek zamanlı uygulamalarda oldukça önemlidir. Model öğrenilebilir parametre sayısını en aza indirgeyerek test süresini de önemli ölçüde azaltmıştır.

Kalp kapakçıklarında kalsifik alanların belirlenmesinde ekokardiyografi görüntülerinden oluşan veri seti olmadığından çalışmada uygulanan tüm yöntemler ilk defa uygulanmıştır.


Literatürdeki aort ilgi bölgesinin algılanması ve kalsifik alan segmentasyonu için ekokardiyografi görüntülerinden oluşan veri seti eksikliğini doldurmak amacıyla tez çalışmasında her iki işlem için de özgün veri setleri oluşturulmuştur. Bu veri setleri diğer araştırmacıların bu alanda çalışabilmesini sağlayacak öncül bir çalışma olarak önem kazanmaktadır.

2.1. Ekokardiyografi Görüntülerinde Aort İlgi Bölgesinin Algılanması

2.1.1. Nesne Algılama İçin Aort Kapağı Veri Setinin Hazırlanması

Literatürde her biri farklı ayarlarla oluşturulan veri setleri önerilmesine rağmen herkese açık paylaşılan bir veri seti mevcut değildir. Bu çalışmada önerilen aort kapağı veri seti Karadeniz Teknik Üniversitesi, Tıp Fakültesi, Kardiyoloji Bölümü'nde 169 farklı hastadan alınan 320 parasternal kısa eksen ekokardiyografi görüntüsünden oluşmaktadır. Tüm hastalardan alınan ekokardiyografi görüntülerinin standardizasyonu için parasternal kısa eksen görüntüde her 3 aort yaprakçığının aynı anda en net görüldüğü kesit uzman kardiyolog tarafından belirlenerek alınmıştır.

Aort kapağının görünümünün diyastol, sistol, normal veya anormal (kalsifik) doku koşullarında olmasına bağlı olarak önemli ölçüde değiştiği unutulmamalıdır. Bu çeşitlilik, ekokardiyografi görüntülerinden aort kapağı ilgi bölgesinin (ROI) otomatik olarak tespit edilmesini zorlaştırmaktadır. Bununla birlikte, veri setimizin bahsedilen tüm koşulları içerdiği için sağlam olduğunu vurgulamak önemlidir. Bu, farklı koşullar altında aort kapağı tespitinde doğruluk elde etme yeteneğimizi göstermektedir. Ayrıca, Şekil 14'de her bir koşula karşılık gelen örnek görüntüler verilmiştir. Şekil 14(d)'de görülebileceği gibi, Şekil 14(c)'de gösterilen normal görüntülere kıyasla yaprakçık üzerinde kalsifikasyon mevcut olduğunda ROI'nin tespiti daha zor hale gelmektedir. Bunun nedeni, bazı görüntülerde kalsifiye alanın aort duvarına doğru uzanarak ana yapının şeklini belirlemeyi zorlaştırmasıdır. Buna ek olarak, Şekil 14(a)'da gösterildiği gibi diyastol sırasında ROI'yi belirlemek Şekil 14(b)'de gösterildiği




Şekil 14. Farklı durumları gösteren bazı örnek ekokardiyografi görüntüleri (a) diyastol, (b) sistol, (c) normal (kalsifik olmayan) doku ve (d) anormal (kalsifik) doku

gibi sistol sırasında belirlemekten daha kolay olabilir, çünkü diyastol fazı genellikle ilgilenilen bölge için daha net bir sınır sağlar.

Etiketleme işlemi iki uzman kardiyolog tarafından Matlab 2022a Image Labeler görüntü etiketleme araç kutusu kullanılarak gerçekleştirilmiştir. Matlab görüntü etiketleme aracı, ROI etiketleri atanabilen ilgi bölgeleri çizerek görüntülere açıklama eklemek için hızlı ve kolay bir yol sağlar. Veri setindeki tüm görüntüler iki uzman kardiyolog tarafından etiketlenmiştir. Şekil 15, veri kümesindeki örnek ekokardiyografi görüntülerinde uzman bir kardiyolog tarafından dikkörtgen etiket tipiyle etiketlenen aort kapakçığı ilgi bölgelerini göstermektedir.

Sınırlayıcı kutu $[x, y, \text{genişlik}, \text{yükseklik}]$ formatında bir vektördür ve bu vektörün bileşenleri sırasıyla ilgilenilen aort kapak bölgesinin sol üst köşesinin yatay ve dikey



Şekil 15. Ekokardiyografi görüntüsünde uzman kardiyolog tarafından aort kapağı bölgesinin etiketlenmesi

koordinatları, ilgilenilen aort kapak bölgesinin genişliği ve yüksekliğidir. Bu etiketler PASCAL VOC veya YOLO formatında.txt dosyaları olarak kaydedilir. ImageNet ve MS COCO veri kümelerinin etiketleri PASCAL VOC formatında kaydedildiğinden, bu çalışmada LabelImg aracı ile elde edilen etiketler PASCAL VOC formatında kaydedilmiştir. Görüntüdeki sınırlayıcı kutu, ilgili.txt dosyasında saklanan veri satırına karşılık gelir. Satırdaki bu sayısal değerler, görüntü üzerindeki sınırlayıcı kutunun bilgilerini temsil etmektedir. Bunlar sırasıyla (a) sınıf adı, (b) normalleştirilmiş merkez x koordinatı, (c) normalleştirilmiş merkez y koordinatı, (d) normalleştirilmiş genişlik ve (e) normalleştirilmiş yüksekliği temsil etmektedir. Sol alt köşe koordinatının değerleri (x_1, y_1) , sağ üst köşe koordinatları (x_2, y_2) , görüntü genişliği w ve sınırlayıcı kutunun yüksekliği h eşitlik (2.1-2.4)'de verildiği gibi hesaplanmıştır.

$$b = \frac{(x_1 + x_2)/2.0}{w} \quad (2.1)$$

$$c = \frac{(y_1 + y_2)/2.0}{h} \quad (2.2)$$

$$d = \frac{x_2 - x_1}{w} \quad (2.3)$$

$$e = \frac{y_2 - y_1}{h} \quad (2.4)$$


Veri seti %80-%5-%15 oranında eğitim, doğrulama ve test olmak üzere üç bölüme ayrılmıştır. Eğitim ve doğrulama seti, derin ağ parametre ayarlamasını gerçekleştirmek için kullanılmıştır. Ardından, önerilen AVD-YOLOv5 modelinin performansını elde etmek için test gerçekleştirilmiştir.

2.1.2. Önerilen Yöntemin (AVD-YOLOv5) Ağ Mimarisi

Tez kapsamında ekokardiyografi görüntülerinden yüksek hızlı aort kapakçığı tespiti için daha hafif bir ağ modeli olarak AVD-YOLOv5 modeli önerilmiştir. Çakır vd. (2024). Şekil 16’te gösterildiği gibi, orijinal YOLOv5 mimarisinde çeşitli iyileştirmeler yapılmıştır: (1) aort kapakçığı ilgi bölgesi (RoI) tüm giriş görüntüsünün boyutuna göre aşırı küçük ayrıntılar içermediğinden, küçük ölçekli algılama yapılandırma dosyasından çıkarılmıştır; (2) CSP bloklarında standart konvolüsyon işleminden farklı olarak derinlik bazlı ayrılabilir konvolüsyon (DS-Conv) kullanılmıştır; (3) mevcut bağlantı kutularını kullanmak yerine, aranan nesneye (aort kapağı) en iyi uyan bağlantı kutularının boyutunu belirlemek için bir K-ortalama algoritması kullanılmıştır. Yapılan iyileştirmeler bölüm (2.1.3-2.1.5) kısmında detaylı olarak anlatılmıştır.

2.1.3. Küçük Ölçekli Tespit Bileşeninin (Ölçek 1) Kafadan Çıkarılması

Şekil 16’teki başlık bölümünde verilen "Ölçek 1", "Ölçek 2" ve "Ölçek 3" terimleri, farklı çözünürlüklerde nesne tespiti için ağ tarafından oluşturulan farklı özellik haritaları seviyelerini ifade eder. Ölçek 1, tipik olarak en yüksek çözünürlüğe sahip olan özellik haritalarının ilk ölçeğini ifade eder. Ölçek 2, Ölçek 1’e kıyasla daha düşük çözünürlüğe




Şekil 16. Önerilen AVD-YOLOv5 modelinin genel mimarisi. CSP’de derinlik-bazlı ayrılabilir konvolüsyon (DS-Conv) ve dolayısıyla derinlik-bazlı konvolüsyon (DW_Conv) ve nokta-bazlı konvolüsyondan (PW_Conv) oluşan CBL blokları kullanır.

sahip olan ikinci özellik haritaları ölçeğini ifade eder. Ölçek 3, Ölçek 2'ye kıyasla daha da düşük çözünürlüğe sahip olan özellik haritalarının üçüncü ölçeğini ifade eder. Dolayısıyla, Ölçek 1 76×76 , Ölçek 2 38×38 ve Ölçek 3 19×19 çözünürlüğe sahip olacaktır. Bu farklı ölçeklerdeki özellik haritaları, giriş görüntüsündeki farklı boyutlardaki nesneleri tespit etmek için kullanılır. Nispeten küçük boyutlu nesneler Ölçek 1'de daha iyi algılanırken, orta ve büyük boyutlu nesneler sırasıyla Ölçek 2 ve Ölçek 3'te daha iyi algılanacaktır. Birden fazla ölçeğin kullanılması, YOLOv5'in nesne algılama görevlerinde çeşitli boyutlardaki (küçük, orta ve büyük) nesneleri verimli bir şekilde işlemesine yardımcı olur. Bununla birlikte, aort kapakçığı bölgesi söz konusu olduğunda, tespit edilecek aşırı küçük ayrıntılar veya nesneler yok gibi görünmektedir. Aort bölgesi esas olarak tüm giriş görüntüsüne kıyasla makul boyutta yapılar ve özellikler içerir. Bu nedenle, küçük ölçekli algılama bileşeni (Ölçek 1) bu özel uygulama için YOLOv5'in yapılandırma dosyasında hariç tutulmuştur. Bu şekilde, YOLOv5 modeli aort bölgesindeki daha büyük ve daha önemli özellikleri tespit etmeye odaklanacak şekilde optimize edilerek daha iyi genel performans ve hesaplama verimliliği elde edilir.

2.1.4. Standart Konvolüsyonların CSP Bloklarında Derinlemesine Ayrılabilir Konvolüsyonlarla Değiştirilmesi

Makul performansı korurken hesaplama maliyetini ve model boyutunu azaltmak için, MobileNet Howard vd. (2017)'te önerilen derinlik-bilge ayrılabilir konvolüsyon genellikle standart konvolüsyon yerine kullanılır. Bunun nedeni, derinlik-bilge konvolüsyonun gerekli parametre ve hesaplama sayısı açısından oldukça verimli olmasıdır. Standart bir konvolüsyon ile derinliğe göre ayrılabilir bir konvolüsyon arasındaki karşılaştırma Şekil 17'de gösterilmektedir.

Derinlik açısından ayrılabilir konvolüsyon (DS-Conv), uzamsal etkileşimleri (görüntü yüksekliği ve genişliği) kanal etkileşimlerinden (örneğin renkler) ayırmayı önermektedir. Standart konvolüsyon bunu hem birkaç uzamsal piksel hem de tüm kanallar üzerindeki değerleri birlikte çarparak yaparken, DS-Conv ilk olarak yalnızca uzamsal ve kanaldan bağımsız bir derinlik-bilge konvolüsyon (DW_Conv) kullanır. Pratikte bu, her kanal için bağımsız bir konvolüsyona sahip olduğumuz anlamına gelir. Daha sonra kanal etkileşimlerini modelleyen noktasal bir konvolüsyon (PW_Conv) uyguluyoruz. PW_Conv 1×1 boyutunda bir çekirdek kullanır, bu nedenle herhangi bir uzamsal etkileşimi modellemez.



Şekil 17. 3×3 çekirdekli ve 3 giriş kanallı standart konvolüsyon, $3 \times 3 \times 3$ (koyu mavi) giriş değerlerinden 6 çıkış kanallı 6 renkli çıkışa projeksiyonu gösterir. 3×3 çekirdekli ve 3 giriş kanallı derinlik ayrıştırılabilir konvolüsyonda, bir derinlik konvolüsyonu her giriş kanalının 3×3 pikselini, karşılık gelen bir çıkış pikseline (eşleşen renkler) yansıtır. 1×1 noktasal konvolüsyon daha sonra 6 nihai çıkış pikselini belirlemek için bu 3 çıkış pikselini kullanır.

Görüntünün boyutunun $W \times H$, konvolüsyon filtresinin boyutunun $K \times K \times Cin$ ve konvolüsyon filtrelerinin sayısının N_{conv} olduğunu varsayalım. Daha sonra, standart konvolüsyonun (Conv) hesaplama maliyeti Eşitlik 2.5'deki gibi ifade edilir .

$$Cost_{Conv} = H * W * K * K * Cin * N_{conv} \quad (2.5)$$

Derinlemesine ayrılabilir konvolüsyon kullanırsak, hesaplama maliyeti eşitlik (2.6-2.9)'de verildiği gibi derinlemesine konvolüsyon (DW_Conv) ve noktasal konvolüsyonun (PW_Conv) toplamı şeklinde ifade edilebilir.

$$Cost_{DW_Conv} = H * W * Cin * K * K \quad (2.6)$$

$$Cost_{PW_Conv} = H * W * Cin * N_{conv} \quad (2.7)$$

$$Cost_{DS-Conv} = Cost_{DWConv} + Cost_{PWConv} \quad (2.8)$$

$$Cost_{DS-Conv} = H * W * Cin * K * K + H * W * Cin * Nconv \quad (2.9)$$

Yukarıda belirtilen eşitliklerden yola çıkılarak, Conv ve DS-Conv'un hesaplama oranı Eşitlik (2.10)'da verilmiştir, bu da DS-Conv kullanımının hesaplama maliyetini etkili bir şekilde azalttığını ve tespit hızını artırdığını göstermektedir.

$$\frac{Cost_{DS-Conv}}{Cost_{Conv}} = \frac{1}{Nconv} + \frac{1}{K^2} \quad (2.10)$$

2.1.5. K-Ortalamlar Algoritması Kullanılarak Aort Kapakçığı Tespit Görevi İçin En İyi Çapa Kutularının Oluşturulması

Çapa kutuları, YOLOv5 mimarisinin kafa bileşenindeki tahmin kutularıdır ve aranan nesnenin olası koordinatlarına atanır. Her görüntüde her ölçek için 3 adet olmak üzere toplam 9 adet çapa kutusu hesaplanır. En yüksek olasılık değerine sahip kutu çıktıya aktarılır. Başlangıçta her bir ağdaki kutuların ölçekleri varsayılan olarak belirlenmiştir. Ancak farklı veri kümelerindeki görüntülerin içeriği ve yapısı rastgele kutu ölçekleri ile tam olarak uyumlu değildir. Bu çalışmada, K-ortalamlar kümeleme algoritması aort kapak veri kümesine uygulanmış ve aranan nesneye en iyi uyan çapa kutularının boyutları belirlenmiştir.

K-ortalamlar algoritması, nesne boyutlarını kümelere ayırmak ve küme merkezlerini bulmak için kullanılır. Algoritma uygulanırken başlangıç merkezleri rastgele seçilir. Uzaklık metriği genellikle Öklid uzaklığıdır. Atama adımında, her nesne en yakın merkeze atanır. Bu adımda, her nesnenin boyutları ve merkezler arasındaki mesafe hesaplanır. Merkez güncelleme adımında, küme içindeki nesnelerin boyutlarına göre her küme için yeni merkezler hesaplanır. Daha sonra atama adımı tekrarlanır ve nesnelerin merkezlere atanması güncellenir. Algoritma, merkezlerdeki değişimin çok küçük olduğu bir noktada, yani yakınsamada tamamlanır. Elde edilen küme merkezleri (çapa kutuları) eğitim veri setindeki nesnelerin boyutlarını temsil eder. Bu, nesne algılama modelinde kullanılmak üzere uygun boyutlara sahip bağlantı kutuları

Tablo 3. K-ortalamlar kümeleme algoritması kullanılarak aort kapağı tespiti için varsayılan çapa kutuları ve oluşturulan çapa kutuları

Nesne ölçeği	Varsayılan bağlantı kutuları	Üretilen bağlantı kutuları
19 (P3/8)	[10,13, 16,30, 33,23]	[91,88, 98,85, 99,100]
38 (P4/16)	[30,61, 62,45, 59,119]	[108,96, 109,111, 115,106]
76 (P5/32)	[116,90, 156,198, 373,326]	[128,108, 120,116, 134,124]

sağlar. Tablo 3 sırasıyla aort kapakçığı tespiti için varsayılan bağlantı kutularını ve oluşturulan bağlantı kutularını göstermektedir.

Bu üç önemli iyileştirme ile modelin parametre sayısının, test sırasında görüntü başına tespit süresinin ve saniye başına kayan nokta işlem sayısının (GFLOPs) önemli ölçüde azaldığı görülmüştür.

2.1.6. Deneysel Çalışmalar

Önerilen AVD-YOLOv5 modelini değerlendirmek ve performansını doğrulamak için, aşağıdaki değişiklikler de dahil olmak üzere farklı parametre ayarlarıyla birkaç ablasyon çalışması gerçekleştirilmiştir. 1) Yapılandırma Dosyasından Küçük Ölçeğin Kaldırılması 2) Ağ Derinliği ve Kanal Genişliğinin Değiştirilmesi 3) Konvolüsyon Katmanlarındaki Kanal Sayısının Azaltılması 4) CSP-BottleNeck Katman Sayısının Değiştirilmesi 5) Derinliğe Göre Ayrılabilir Konvolüsyon Eklenmesi. Çeşitli bileşenlerde bu değişiklikler yapılarak, daha yüksek algılama doğruluğu ile verimli ve yüksek hızlı bir ağ mimarisi elde edilmesi amaçlanmıştır. Yapılan değişiklikler aşağıdaki şekilde özetlenmiştir:

Yapılandırma dosyasından küçük ölçeğin kaldırılması YOLOv5'in kafa bileşeninde, son adımda yapılan tahminleri çıktıya aktarmak için kullanılan 3 farklı boyutta ölçek bulunmaktadır. Bu ölçekler, ağın giriş görüntülerindeki büyük, orta ve küçük ayrıntıları daha iyi tespit etmesini sağlar. Ultrason veri setindeki aortik ilgi bölgesi, tüm girdi görüntü boyutuna kıyasla aşırı küçük detaylar içermediğinden, küçük ölçek ağ mimarisinden çıkarılmıştır. Tablo 4'de görülebileceği gibi, küçük ölçeğin kaldırılmasının sonuçlar üzerindeki etkisi, parametre sayısının yaklaşık 7 milyondan 5 milyona düşürülmesi, görüntü başına çıkarım süresinin 7,95 ms'den 6,15 ms'ye düşürülmesi ve kayan nokta işlemlerinin (GFLOP) sayısının 15,9'dan 14,5'e düşürülmesidir.

Tablo 4. YOLOv5-s modelinden küçük ölçeğin kaldırılmasının performans üzerindeki etkisi

#ölçek	#katman	#parametre	Kesinlik	Hassasiyet	mAP	GFLOPs	Çıkarım Süresi (ms)
3-ölçek YOLOv5-s	214	7022326	0.965	0.871	0.903	15.9	7.95
2-ölçek YOLOv5-s	191	5240036	0.96	0.903	0.961	14.5	6.15


Ağ derinliğini ve kanal genişliğini değiştirme: YOLOv5'te, YAML yapılandırma dosyasındaki derinlik parametresi, modelin genel derinliğini kontrol eden ve YOLOv5 modelindeki katman sayısını belirleyen bir ölçeklendirme faktörüdür. Toplam kanal sayısının ne kadarının hesaplamalara dahil olduğunu belirten bir yüzde parametresidir. Model mimarisinde belirtilen modül sayısına uygulanır. Daha sıkı veya daha derin bir ağ elde etmek için modül sayısını ölçeklendirir. 1,0'dan küçük bir değer (örneğin 0,33) derinlik için katman sayısını azaltır ve daha sıkı bir ağla sonuçlanır. Derinlik için 1.0'dan büyük bir değer (örn. 1.5) katman sayısını artırarak daha derin bir ağa yol açar. Ağın derinliğini ayarlamak için model mimarisinde tanımlanan katman sayısı ile çarpılır. Örneğin, derinlik 0,33 olarak ayarlanırsa, modeldeki toplam katman sayısının orijinal sayının yaklaşık üçte birine düşürüleceği anlamına gelir. Dolayısıyla, bu parametrenin oranının azaltılması modelin karmaşıklığını, bellek kullanımını, çıkarım süresini, katman sayısını ve eğitim ve test için kullanılan parametre sayısını önemli ölçüde azaltır.

Bu çalışmada, mimarideki ağın derinliğini kontrol eden "depth_multiple" parametresi küçük versiyon için üç farklı değerle test edilmiştir. Derinlik parametresine bağlı olarak, toplam kayan noktalı işlem sayısı ve çıkarım süresi Şekil 18(a)'da gösterilmiştir. Tablo 5 ayrıca derinlik parametresinin değiştirilmesinin ağdaki diğer parametreleri ve performansı nasıl etkilediğini göstermektedir. Şekil 18(a) ve Tablo 5'da görüldüğü gibi, "depth_multiple" değeri azaltıldığında, çıkarım süresi ve kayan noktalı işlem sayısı azalmıştır. Bu sayede model performansının iyileşmesine olumlu katkılar gözlemlenmiştir. Modelin çıkarım süresi açısından çok fazla fark olmaması ve hassasiyet değerinin daha iyi olması nedeniyle derinlik değerinin 0,2 olarak seçilmesine karar verilmiştir. Yapılan deneyler sonucunda derinlik parametresi optimum bir değere ayarlanarak önerilen AVD-YOLOv5 modelinin derinliği kontrol edilmiş, özel kullanım durumu ve kaynak kısıtlarına göre model performansı ve hesaplama verimliliği arasında bir denge kurulmuştur.

Kanal genişliği, toplam kanal sayısının ne kadarının hesaplamalara dahil edileceğini belirten bir yüzde parametresidir. Yapılandırma dosyasında width_multiple olarak adlandırılan

Tablo 5. Ağ mimarisinde derinlik parametresi değişiminin performansa etkisi

Ağ Derinliği	#katman	#parametre	Kesinlik	Hassasiyet	mAP	GFLOPs	Çıkarım Süresi (ms)
0.1	193	6652406	0.818	0.87	0.926	14.2	6.57
0.2	200	6816758	0.931	0.903	0.909	14.9	6.65
0.3	214	7022326	0.952	0.871	0.903	15.95	7.95



Şekil 18. Derinlik (a) ve kanal genişliği (b) parametrelerinin ağ yapısı üzerindeki etkisi

bu parametre, modeldeki katmanların kanal genişliğini kontrol eder ve YOLOv5 modelinin katmanlarındaki kanal sayısını (genişlik olarak da adlandırılır) belirleyen bir ölçeklendirme faktörüdür. Çalışma zamanında model, mimaride tanımlanan her katmandaki kanal sayısına uygulanır. Ağın genel genişliğini ayarlamak için kanal sayısını ölçeklendirir, ağın genişliğini ayarlamak için her katmanda tanımlanan kanal sayısı ile çarpılır. Örneğin, width_multiple için 1,0'dan küçük bir değer (örneğin 0,50) kanal sayısını azaltarak daha sıkı bir ağa neden olur. Ağ genişliği 0,50 olan bir ağ yapısında, giriş görüntüsünün işlendiği kanallar mimarideki tüm kanalların yarısı genişliğindedir. Bu, model karmaşıklığını, bellek kullanımını veya hesaplama gereksinimlerini azaltmak için kullanışlıdır. Tersine, width_multiple için 1.0'dan büyük bir değer (örneğin 1.50) kanal sayısını artırarak daha derin bir ağa yol açar. Bu, daha karmaşık özellikleri yakalamak için modelin temsil kapasitesini potansiyel olarak artırabilir, ancak aynı zamanda hesaplama taleplerini de artırabilir.

Bu çalışmada ağ mimarisinde kanal genişliğini kontrol eden "width_multiple" parametresi küçük versiyon için beş farklı değer ile test edilmiş ve genişlik parametresine bağlı olarak toplam çarpma işlemi sayısı ve test süresindeki değişim Şekil 18(b)'de verilmiştir. Tablo 6 ayrıca genişlik parametresinin değiştirilmesinin ağdaki diğer parametreleri ve performansı nasıl etkilediğini göstermektedir. Şekil 18(b) ve Tablo 6'de görüldüğü gibi, bu parametrenin "width_multiple" oranı azaltıldığında, eğitim ve test için kullanılan katman ve parametre

Tablo 6. Ağ mimarisinde kanal genişliği parametresi değişiminin performansa etkisi


Kanal Genişliği	#katman	#parametre	Keskinlik	Hassasiyet	mAP	GFLOPs	Çıkarım Süresi (ms)
0.1	214	328622	0.926	0.871	0.909	1	4.8
0.2	214	1190214	0.895	0.871	0.893	3.2	5.2
0.3	214	2685326	0.932	0.903	0.913	6.4	6.0
0.4	214	4652070	0.95	0.871	0.92	11.2	6.5
0.5	214	7022326	0.952	0.871	0.903	15.95	7.95

sayısı önemli ölçüde azalmaktadır. Sonuç olarak, çıkarım süresi 7,95 ms'den 4,8 ms'ye ve kayan nokta işlemlerinin sayısı 15,95'ten 1'e düşürülür. Bu nedenle, kabul edilebilir performans ve model boyutu göz önüne alındığında, ağ kanalı genişliği 0,1 olarak ayarlanır.

Konvolüsyon katmanlarındaki kanal sayısını azaltma: Konvolüsyon katmanı, derin öğrenmenin en temel aşamalarından biri olan girdi verilerinden özellik haritaları çıkarmak için kullanılır. Konvolüsyon katmanlarının ağ mimarisinde kanal sayısının azaltılması parametreler ve test süresi açısından avantajlı, ancak model belleği açısından dezavantajlıdır. Daha az konvolüsyon katmanı kanal boyutu, model için daha az parametre ve daha az hesaplama gücü gerektirir, böylece modelin belleği ve hesaplama gücü azalır. Bu, modelin daha hızlı çalışmasını sağlar, ancak aynı zamanda daha karmaşık özellikleri öğrenme yeteneğini sınırlayabilir ve modelin daha az öğrenme kapasitesine sahip olacağı anlamına gelir. Ayrıca modelin daha basit ve daha düşük karmaşıklıkta veri modellerini öğrenme kabiliyetini de sınırlar. Daha karmaşık veri setleri için bu durum modelin verimsiz olmasına neden olabilir. Öte yandan, konvolüsyon katmanındaki kanal sayısını azaltmak eğitim ve test aşamalarını hızlandırır. Bu, büyük veri setlerinin daha hızlı işlenmesi veya uygulamanın gerçek zamanlı gereksinimlerini karşılamak için kullanışlıdır. Ağ üzerindeki tüm bu etkileri gözlemlemek için omurga ve kafa bileşenlerindeki odak konvolüsyonu hariç tüm konvolüsyon katmanlarının kanal boyutu yarıya indirilerek model yeniden eğitilmiştir. Tablo 7 ve Şekil 19(a)'da gösterildiği gibi, konvolüsyon kanal boyutunun yarıya indirilmesi eğitimde kullanılan parametre sayısını, çarpma işlemi sayısını ve test süresini azaltmaktadır. Ancak bu işlem aynı zamanda modelin hafızasını ve öğrenme kabiliyetini de azalttığından hassasiyet değerinin oransal olarak çok fazla düştüğü gözlemlenmektedir. Bu sebeplerden dolayı modelin performansı ve verimliliği göz önünde bulundurularak ana mimarideki konvolüsyon katmanlarının kanal boyutunun yarıya indirilmemesine karar verilmiştir.

Tablo 7. Konvolüsyon katmanında bulunan kanal sayısını değişiminin performansa etkisi

#konvolüsyon katmanında bulunan kanal	#katman	#parametre	Kesinlik	Hassasiyet	mAP	GFLOPs	Çıkarım Süresi (ms)
8768	214	7022326	0.965	0.871	0.903	15.9	7.95
4672	214	1853814	0.89	0.9	0.926	4.9	5.40



Şekil 19. Konvolüsyon katmanındaki kanal sayısının (a) ve CSP BottleNeck bloklarının sayısının (b) ağ yapısı üzerindeki etkisi

Ağ içerisindeki CSP-BottleNeck bloklarının sayısının değiştirilmesi: Temel olarak C3 olarak adlandırılan omurga ve boyun bileşenlerinde kullanılan CSP BottleNeck modülü Şekil 4'de detaylandırılmıştır. CBL, BottleNeck, Konvolüsyon (Conv) ve Birleştirme (Concatenation) bloklarını içeren bir yapıdır. CBL, Konvolüsyon (Conv), Batch-Normalization (BN) ve Activation Function (Sigmoid Leaky-Relu, SILU) bloklarından oluşur. BottleNeck ise 2 CBL bloğu ve bir artık (residual) atlama bağlantısından oluşur. Bu nedenle, CSP_BottleNeck katmanında yapılan herhangi bir değişiklik dolaylı olarak birçok sıralı bağlantıyı etkiler. CSP_BottleNeck yapısı böl ve yönet mantığı temelinde çalışır. Tüm girdiyi belirli oranlarda parçalara böler, her birini dahili olarak işler ve ardından bunları belirli bir hiyerarşiye göre birleştirir. Bu, hesaplama süresini kısaltır, görüntülerin boyutunu küçültür ve onları ifade anlamı açısından daha yoğun hale getirir. Ağdaki CSP katmanlarının değer parametreleri üzerindeki etkisini gözlemlemek için CSP katmanlarının sayısı azaltılarak deneyler yapılmıştır. Şekil 19(b)'de görülebileceği gibi, CSP katmanlarının sayısının azaltılması, çoklu iç içe geçmiş yapıların oranını azalttığı için kayan nokta işlemlerinin sayısını ve çıkarım süresini azaltmıştır. Tablo 8'de sunulan sonuçlara göre CSP katmanlarının sayısının azaltılması eğitim ve test süresini hızlandırırken doğruluk (precision) değerindeki başarıyı da korumuştur. Yapılan değişiklikler ve ağ üzerindeki etkileri göz önüne alındığında, modelin performansını artırırken hassasiyet değerinde önemli bir düşüşe neden olmadığı için omurga ve kafa

Tablo 8. Ağ mimarisinde CSP-Bottleneck katman sayısı değişiminin performansa etkisi

#CSP Katmanları	#katman	#parametre	Kesinlik	Hassasiyet	mAP	GFLOPs	Çıkarım Süresi (ms)
3,6,9,3 3,3,3,3	214	7022325	0.952	0.871	0.903	15.95	7.95
2,4,6,2 3,3,3,3	200	6816758	0.818	0.87	0.909	14.7	6.76
2,4,6,2 2,2,2,2	200	6816756	0.818	0.87	0.909	14.7	6.74
1,2,3,1 3,3,3,3	193	6652406	0.931	0.903	0.926	14.2	6.66
1,2,3,1 1,1,1,1	193	6652406	0.931	0.903	0.926	14.2	6.58

Tablo 9. Ağ mimarisinde kullanılan konvolüsyon yönteminin performansa etkisi

Konvolüsyon Yöntemi	#katman	#parametre	Kesinlik	Hassasiyet	mAP	GFLOPs	Çıkarım Süresi (ms)
Conv	214	7022325	0.952	0.871	0.903	15.9	7.95
DS-Conv	214	4697910	0.94	0.997	0.988	11.2	5.8

bileşenlerindeki CSP BottleNeck katmanlarının sayısının 1/3 oranında azaltılarak sırasıyla 1,2,3,3,3,3,3 olarak belirlenmesine karar verilmiştir

Derinlik Açısından Ayrılabilir Konvolüsyon Ekleme: Derinlik bazında ayrılabilir konvolüsyon (DS-Conv), standart konvolüsyondan (Conv) farklı olarak önce giriş görüntüsünü istenen çıkış boyutunda gruplara böler ve ardından her biri için filtre geçişi gerçekleştirir. Bu grupta işlemi görüntünün boyutunu küçültür. Daha sonra nokta-bilge kısmında elde edilen çıktı boyutuna göre bir çekirdek boyutu seçilir ve standart konvolüsyon uygulanır. Tablo 9’da görülebileceği gibi, görüntü başına çıkarım süresi 7,95’ten 5,8’e ve kayan noktalı işlem sayısı 15,9’dan 11,2’ye önemli ölçüde azaltılmıştır. Hassasiyet değeri, standart konvolüsyona kıyasla hassasiyet açısından önemli bir dezavantaja (0,012) sahip değildir. Ayrıca geri çağırma değerini 0,871’den 0,997’ye önemli ölçüde iyileştirmiştir.

2.1.7. Eğitim Detayları

Ağ eğitiminde, varsayılan çapa kutuları yerine aort kapak bölgesini tespit etmek için oluşturulan yeni çapa kutuları kullanılmıştır. Bu nedenle tüm modeller sıfırdan eğitilmiştir. Modeller, doğrulama kaybının değişmediği noktaya kadar stokastik gradyan inişi (SGD) optimizasyon algoritması ile eğitilmiş ve adil karşılaştırma için aynı test veri kümesi üzerinde test edilmiştir. Tüm deneyler Jupyter notebook tabanlı Google Colaboratory (Colab) üzerinde gerçekleştirilmiştir. Colab, Tesla K80 GPU ve 12 GB RAM kullanma imkanı sunmaktadır. Tüm modifikasyonlar YOLOv5’in alt versiyonlarından biri olan YOLOv5-s (small) modeli (yolov5s.pt) üzerinde gerçekleştirilmiştir. Parametreler ve değerleri epok

sayısı 500, yığın boyutu (batch size) 16, girdi görüntü boyutu 768, momentum katsayısı (momentum coefficient) 0.937, ağırlık azalma değeri (weight decay) 0.0005 ve öğrenme oranı (learning rate) 0.01 olarak belirlenmiştir. Test parametresi olan IOU eşiği 0,9 olarak belirlenmiştir. Girdi boyutu belirlenirken, bilgi kaybını en aza indirmek için veri setinin uygun şekilde boyutlandırıldığından emin olunmuştur. Model eğitimi her versiyon için belirlenen parametrelerle başlatılmış ve eğitim sonunda ve eğitim sırasında elde edilen en iyi sonuçlar bir ağırlık dosyası olarak kaydedilmiştir. Diğer tüm ayarlar varsayılan değerlerde bırakılmıştır ("hyp.scratch-low.yaml" YOLOv5 dosyasında belirtilmiştir).

Önerilen ağ modeli üzerinde gerçekleştirilen tüm deneyler Windows 64 bit sistemde CPU @ 4 GHz, 32GB RAM ve NVIDIA GeForce GTX 3060 GPU karta sahip bir bilgisayarda gerçekleştirilmiştir. Ağ mimarilerinin oluşturulması ve eğitilmesi Visual Studio Code ortamında, Pytorch kütüphanesi gerçekleştirilmiştir. Visual Studio Code, CNN ağ katmanlarının her birinin etkin şekilde uygulanmasını, çeşitli aktivasyon fonksiyonlarının ve optimizasyon yöntemlerinin kullanımını ve ağ eğitimlerinin GPU'lar üzerinde gerçekleştirilmesini desteklemektedir.


2.2. Aort Bölgesinde Bulunan Kalsifik Alanların Otomatik Segmentasyonu

Aort ilgi bölgesinde bulunan kalsifik alanlar ekokardiyografi ve BT ile tespit edilir. Ekokardiyografik görüntülerde kalsifik alanlar her zaman net olarak görüntülenemez ve kalsifikasyon oranı hesaplanamaz. bu sebeple hasta hem daha net görüntü alabilmek hem de kalsifikasyon skorunun belirlenmesi amacıyla BT'ye yönlendirilir. Bu işlemlerin tamamlanması için gereken süre fazladır. Ayrıca hastaların ultrasondan sonra BT'ye yönlendirilmesi hem hastayı daha fazla radyasyona mecbur bırakır hem de hastane açısından maliyetlidir. Dolayısıyla aort bölgesindeki kalsifik alanların BT'ye ihtiyaç kalmadan, ekokardiyografik görüntüler üzerinden tespit edilmesi birçok açıdan fayda sağlar. Fakat doktorlar tarafından yapılan değerlendirmelerde bu tam olarak fark edilemeyebilir. Bu sebeple aort bölgesindeki kalsifik alanların ekokardiyografik görüntüler üzerinden otomatik olarak algılanması oldukça önemlidir. Bu çalışmada ekokardiyografik görüntülerle hazırlanan veri setleri kullanılmıştır. Ayrıca segmentasyonda daha gerçekçi sonuçlar elde etmek amacıyla, ilk aşama olarak görüntülerde kalbin aort ilgi bölgesi belirlenmiş ve daha sonrasında algılanan ilgi bölgesi üzerindeki kalsifik alanlar segmentasyon kullanılarak tespit edilmiştir.


2.2.1. Kalsifik Alan Segmentasyonu İçin Aort Kapağı Veri Setinin Hazırlanması

Literatürde her biri farklı ayarlarla oluşturulan veri setleri önerilmesine rağmen herkese açık paylaşılan bir veri seti mevcut değildir. Bu çalışmada önerilen aort kapağı veri seti Karadeniz Teknik Üniversitesi, Tıp Fakültesi, Kardiyoloji Bölümü'nde 82 farklı hastadan alınan 119 parasternal kısa eksen ekokardiyografi görüntüsünden oluşmaktadır. Tüm hastalardan alınan ekokardiyografi görüntülerinin standardizasyonu için parasternal kısa eksen görüntüde her 3 aort yaprakçığının aynı anda en net görüldüğü kesit uzman kardiyolog tarafından belirlenerek alınmıştır.

Çalışmada önerilen kapakçık kireçlenmesi segmentasyonu veri seti Karadeniz Teknik Üniversitesi, Tıp Fakültesi, Kardiyoloji Bölümü'nde toplanan kısa-eksen parasternal ekokardiyografi görüntüleri kullanılarak oluşturulmuştur. Görüntüler 1024*768 boyutlarındadır ve jpg formatında kaydedilmiştir. Veri seti 119 ekokardiyografi görüntüsünden ve ilgili görüntülere ait etiketler ile oluşturulmuş ikili maskelerden oluşmaktadır.



Şekil 20. Aort kapak kalsifikasyon bölge sınırlarının piksel etiket türü yardımıyla etiketlenmesi



Şekil 21. Manuel etiketleme ve otomatik etiketleme sonuçlarının birleştirilmesi (Yeşil etiketli olan bölgeler kardiyolog tarafından manuel olarak işaretlenen, mavi etiketli bölgeler ise piksellerin parlaklık değerleri göz önüne alınarak, bilgisayar tarafından önerilerek işaretlenen bölgelerdir)


Etiketleme işlemi iki uzman kardiyolog tarafından "Matlab 2022a Image Labeler" görüntü etiketleme araç kutusu ile gerçekleştirilmiştir. Şekil 20'de ekokardiyografi görüntülerinde uzman kardiyologlar tarafından aort kapak kalsifikasyon bölge sınırlarının çokgen yardımıyla (piksel etiket türü) etiketleme örneği verilmiştir. Etiketleme işlemi yapıldıktan sonra her bir görüntü için kardiyologlar tarafından etiketlenen bölge maskeleri aynı isimli .png formatında dosyalara kaydedilmiş ve sonuç olarak elde edilen etiket (maske görüntüsü), arka plan siyah, ön plan beyaz olarak etiketlenmiştir.

Oluşturulan veri seti analiz edildiğinde görüntülerde renk benzerlikleri ve konum farklılıklarından dolayı karmaşık durumlar ortaya çıkmıştır. Bunlara örnek olarak manuel etiketleme kireçli bölgeler belirli bir parlaklık değerine sahip olurken, uapılan inceleme sonucunda aynı parlaklığa sahip olup kireçli olarak etiketlenmeyen bölgeler olduğu fark edilmiştir. Bu durumun önüne geçmek amacıyla manuel etiketleme sonuçlarıyla beraber görüntü işleme yardımıyla bulunan benzer özellikteki pixeller Şekil 21'de belirtildiği gibi aynı görüntüde üst üste eklenerek uzman kardiyoloğa gösterilmiş ve etiketler daha sağlam hale getirilmiştir.

Sonuç olarak Şekil 22'da gösterdiği gibi veri seti, aort bölgesinde kalsifikasyon içeren her bir görüntü ve o görüntüye ait etiket ile oluşturulmuştur.

Veri seti %90 eğitim ve %10 test olmak üzere iki parçaya ayrılmıştır. Ayrıca, eğitim seti kendi içerisinde %10'luk kısmı validasyon geri kalanı eğitim olacak şekilde ayrılmıştır. En iyi ağ, sinir ağının eğitimi sırasında gerçekleştirilen validasyon ile elde edilen doğruluk ve

hataya bağılı olarak belirlenmiştir. Ardından, topluluk ağının performansı test seti üzerinde ölçülmüştür



Şekil 22. Piksel etiket türü ile etiketlenmiş aort kapak kalsifikasyon bölge sınırları

2.2.2. Makine Öğrenmesi Yöntemlerine Dayalı Kalsifik Alan Segmentasyonu

Ekokardiyografi görüntüleri üzerinde kalsifik alanların segmentasyonu için Bölüm 1.7’de bahsedilen makine öğrenmesi yöntemleri oluşturulan veri seti üzerinde denenmiştir.

Belirtilen yöntemler genellikle sınıflandırma problemi için kullanılmalarına rağmen bu çalışmada görüntü segmentasyonu amacıyla kullanılmışlardır. Bu amaç doğrultusunda oluşturulan veri seti %90 eğitim %10 test verilerinden oluşacak şekilde iki parçaya bölünmüş ve görüntülerin her biri piksel düzeyinde okunarak, değerleri csv uzantılı dosyalara kaydedilmiştir. Eğitim ve test kümelerinin hem görüntü hem de maskelerine ait ayrı ayrı csv doyaları ("eğitim_görüntü.csv, eğitim_maske.csv test_görüntü.csv ve test_maske.csv) oluşturularak modelin girişine uygun hale getirilmiştir.

Eğitim yapılırken klasik makine öğrenmesi yöntemi olan K-NN algoritması ince ayarlamalar yapılmadan direkt kullanılmıştır. Rastgele orman, Adaboost ve Balanced Bagging algoritmaları ise alt öğrenici ve tahmin edici sayıları belirlenerek eğitilmiştir. Eğitime ait kod detayları aşağıda maddeler halinde özetlenmiştir:

- **Rastgele Orman Algoritması:** Bu algoritma uygulanırken fonksiyon parametreleri `class_weight='balanced'`, `n_estimators=50`, `random_state=42` olarak ayarlanmıştır.

```
brf = BalancedRandomForestClassifier(
    class_weight='balanced',
    n_estimators=50,
    random_state=42)
```

Bu kod, bir Rastgele Orman sınıflandırıcısının temel yapısını oluşturur. `BalancedRandomForestClassifier`, dengeli sınıf ağırlıklarını dikkate alır, yani sınıflar arasındaki dengesizliği ele alır. Bu önemlidir çünkü bazı sınıfların diğerlerinden daha fazla örneği olabilir ve bu durum modelin dengesiz sınıflarla başa çıkmasını zorlaştırabilir. `n_estimators` parametresi, oluşturulacak ağaç sayısını belirtir. Bu durumda, 50 ağaçtan oluşan bir orman kullanıyoruz. `random_state`, rastgele sayı üreticinin başlangıç durumunu belirler. Bu, tekrarlanabilir sonuçlar elde etmek için kullanılır.

- **AdaBoost Sınıflandırıcı:** Bu algoritma uygulanırken fonksiyon parametreleri `class_weight='balanced'`, `n_estimators=50`, `random_state=42` olarak ayarlanmıştır.

```
base_estimator = AdaBoostClassifier(
    n_estimators=200,
    learning_rate=0.2, random_state=42)
eec = EasyEnsembleClassifier(n_estimators=200,
    estimator=base_estimator, random_state=42)
```

Yukarıda paramtere ayarlaması yapılan kod bloğunda, `n_estimators` oluşturulacak olan zayıf öğrenicilerin (genellikle karar ağaçları) sayısıdır. Daha fazla öğrenici genellikle daha iyi bir performans sağlar, ancak daha fazla hesaplama maliyetine neden olabilir. `learning_rate` her bir zayıf öğrenicinin katkısını kontrol eden öğrenme oranıdır. Daha

küçük bir öğrenme oranı, her bir zayıf öğrenicinin daha az katkıda bulunmasına neden olur. Genellikle, daha düşük öğrenme oranları daha iyi sonuçlar verir, ancak daha fazla zayıf öğreniciye ihtiyaç duyulabilir. `random_state` rastgele sayı üreticinin başlangıç durumunu belirler. Bu, modelin tekrarlanabilir sonuçlar üretmesini sağlar.

Bu yöntem uygulanırken kullanılan "EasyEnsembleClassifier" ise ensemble (topluluk) öğrenme yöntemlerinden biridir ve AdaBoost algoritmasını temel alır. Bu yöntemin parametreleri `n_estimators = 200`, `estimator = AdaBoostClassifier` ve `random_state = 42` olarak ayarlanmıştır.

"EasyEnsemble" sınıflandırıcı için `n_estimators` oluşturulacak olan ensemble (ensemble) sayısıdır. EasyEnsemble, veri setini rastgele alt örneklemeler halinde böler ve her alt örneklemden bir öğrenici (genellikle karar ağaçları) oluşturur. Bu parametre, oluşturulacak ensemble sayısını belirler. `estimator` her alt örneklemden oluşturulacak olan temel öğrenici (base learner) türünü belirtir. Bu, `AdaBoostClassifier` veya başka bir sınıflandırıcı olabilir. `random_state` ise rastgele sayı üreticinin başlangıç durumunu belirler. Bu, modelin tekrarlanabilir sonuçlar üretmesini sağlar.

Bu parametreler, modelin başarı oranını ve performansını etkilerken, belirli bir problem veya veri setine bağlı olarak uygun değerler seçilmelidir.

- **Balanced Bagging Sınıflandırıcı:** Bu algoritma için, aşağıda verilen kod parçalarında hem temel bir sınıflandırıcı (`GradientBoostingClassifier`) hem de ensemble bir sınıflandırıcı (`BalancedBaggingClassifier`) kullanılmıştır. Bu iki sınıflandırıcının birlikte nasıl çalıştığını ve ne amaçla kullanıldığını açıklayacak olursak:

```
clf = GradientBoostingClassifier(
    n_estimators=100,
    learning_rate=0.1,
    max_depth=1,
    random_state=42)
bbc=BalancedBaggingClassifier(
    n_estimators=50,
    random_state=42,
    estimator=clf)
```

- Temel Sınıflandırıcı (Gradient Boosting): Gradient boosting algoritması üzerine kurulmuş bir sınıflandırıcıdır. Temel olarak, bu algoritma ardışık olarak zayıf öğreniciler oluşturur ve her biri önceki öğrenicilerin yapmadığı hataları düzeltmeye çalışır. `n_estimators` parametresi, oluşturulacak olan zayıf öğrenicilerin sayısını belirtir. Her bir öğrenici, veri kümesinin zayıf yönlerini düzeltmeye çalışır. `learning_rate` parametresi, her bir öğrenicinin katkısını kontrol eder. Daha düşük bir öğrenme oranı, her bir öğrenicinin daha az katkıda bulunmasına neden olur. `max_depth` parametresi, her bir karar ağacının maksimum derinliğini belirler. Bu, her bir ağacın karmaşıklığını kontrol eder ve aşırı uydurma (overfitting) riskini azaltır.

Bu temel sınıflandırıcı, gradient boosting algoritmasını temel alarak karmaşık ilişkileri öğrenebilir ve genellikle yüksek doğruluk sağlar.

- Topluluk Sınıflandırıcı (Balanced Bagging Classifier): Balanced Bagging sınıflandırıcı, dengeli alt örneklemeler (balanced bagging) kullanarak bir topluluk (ensemble) sınıflandırıcı oluşturur. Alt örneklemeler, veri kümesinin dengesizliği ile başa çıkmak için rastgele olarak seçilir. `n_estimators` parametresi, oluşturulacak olan ensemble sayısını belirtir. Her ensemble, alt örneklemelerden ve temel sınıflandırıcıdan oluşur. `estimator` parametresi, her ensemble için kullanılacak temel sınıflandırıcıyı belirtir. Bu, `GradientBoostingClassifier` gibi başka bir sınıflandırıcı olabilir. Bu ensemble sınıflandırıcı, veri kümesinin dengesizliğiyle başa çıkmak ve daha dengeli bir model oluşturmak için kullanılır. Dengeli bagging, her sınıfın eşit sayıda örnekleme sahip olduğu bir alt örnekleme seti oluşturarak dengesizlik problemini ele alır. Bu şekilde, temel sınıflandırıcı karmaşık ilişkileri öğrenirken, ensemble sınıflandırıcı dengesizlik sorununu ele alarak daha dengeli bir model oluşturur. Bu kombinasyon, modelin performansını artırabilir ve dengesizlik sorununu ele alabilir.

2.2.3. Derin Öğrenme Yöntemlerine Dayalı Kalsifik Alan Segmentasyonu

Medikal görüntü segmentasyonunda derin öğrenme teknikleri, özellikle U-Net, Fully Convolutional Networks (FCN) ve SegNet gibi ağ yapıları, büyük başarılar elde etmiştir. U-Net, özellikle biyomedikal görüntü segmentasyonu için tasarlanmış bir mimaridir ve

simetrik bir encoder-decoder yapısı kullanarak yüksek doğruluk sağlar. Encoder kısmı görüntüyü düşük çözünürlüklü özellik haritalarına dönüştürürken, decoder kısmı bu özellik haritalarını orijinal çözünürlüğe geri çıkarır. U-Net'in dikkat çekici bir özelliği, encoder ve decoder arasında yoğun bağlantılar kurarak ayrıntı kaybını minimize etmesidir. FCN, tüm ağ boyunca yalnızca evrişimsel katmanlar kullanarak girdi görüntüsünü doğrudan segmentasyon haritasına dönüştürür. Bu, geleneksel tam bağlı katmanları kaldırarak hesaplama verimliliğini artırır ve daha büyük görüntülerin işlenmesine olanak tanır. SegNet ise bir başka popüler mimaridir ve encoder-decoder yapısını kullanarak görüntü segmentasyonu gerçekleştirir. SegNet'in ayırt edici özelliği, encoder aşamasında elde edilen pooling indekslerini decoder aşamasında yeniden kullanarak yüksek kaliteli segmentasyon haritaları oluşturmaktır. Bu ağlar, özellikle tümör tespiti, organ segmentasyonu ve diğer klinik teşhislerde önemli ölçüde doğruluk ve verimlilik sağlamış, medikal görüntü analizi alanında devrim niteliğinde ilerlemelere yol açmıştır.

Çalışmanın ekokardiyografi görüntüleri üzerinde kalsifik alanların derin öğrenmeye dayalı segmentasyonu aşamasında bölüm 1.8'de de bahsedilen bu yöntemler oluşturulan veri seti üzerinde denenmiştir. Tüm yöntemler için parametreler, veri setine uygun hale getirilip modeller eğitilmiş ve eğitim sonuçlarına göre modeller test örnekleri üzerinde denenerek performans karşılaştırılması yapılmıştır. Daha sonra veri seti ve ağ parametreleri değiştirilerek segmentasyon performansına etkileri gözlemlenmiş ve model veri seti için en uygun hale getirilmiştir.

2.3. Eğitim Detayları

Tüm deneyler KTÜ bilgisayarlı görü laboratuvarında NVIDIA GeForce RTX 3060-12 GB ekran kartı ve 32 GB RAM'e sahip bir bilgisayarda gerçekleştirilmiştir. Eğitim sırasında kodlama için Pytorch kütüphanesi kullanılmıştır.

Ağ eğitiminde tüm modeller (FCN, SegNET, UNET) sıfırdan eğitilmiş ve aynı eğitim, doğrulama ve test setleri üzerinde çalıştırılmıştır. Parametreler ve değerleri epok sayısı 500, yığın boyutu 16, girdi görüntü boyutu 128 ve öğrenme oranı 0.001 olarak ayarlanmıştır. Girdi boyutu belirlenirken, veri setinin bilgi kaybını en aza indirecek uygun boyutta olmasına dikkat edilmiştir. Model eğitimine her versiyon için belirlenen parametreler ile başlanmış ve eğitim sonunda eğitim sırasında elde edilen en iyi sonuçlar ağırlık dosyası olarak kaydedilmiştir. Adil bir karşılaştırma için tüm modeller aynı test veri kümesi üzerinde test edilmiştir.

2.4. Değerlendirme Metrikleri

Bu çalışmada önerilen modelin, kalp kapakçığında bulunan kalsifik bölgenin tespitindeki performansını niceliksel olarak değerlendirmek için precision (doğruluk), recall (hassasiyet), Dice katsayısı (F1-Score), ve Jaccard indeksi (IoU) dahil olmak üzere dört ölçüm kullanılmıştır. Ortalama Hassasiyet (AP), hassasiyet-hassasiyet eğrisi üzerindeki farklı hassasiyet değerlerine karşılık gelen hassasiyet değerlerinin ortalaması olarak her sınıf için ayrı ayrı hesaplanır. Hassasiyet, doğru tahmin edilen pozitif numunelerin tahmin edilen tüm pozitif numunelere oranını ölçer. Daha yüksek hassasiyet, modelin daha az yanlış pozitive sahip olduğu anlamına gelir. Duyarlılık olarak da bilinen hatırlama, doğru tahmin edilen olumlu örneklerin tüm gerçek olumlu örneklerle oranını ölçer. Daha yüksek bir hatırlama, modelin daha fazla gerçek pozitif örneği tespit ettiği anlamına gelir. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1 skoru, kesinlik ve hatırlama arasında bir denge bulmayı amaçlar ve bu parametrelere bağlı olarak hesaplanır. Daha sonra tahmin edilen ve temel gerçek segmentasyonları arasındaki örtüşmeyi ölçerek segmentasyon doğruluğunun bir ölçüsünü sağlar. Ayrıca, sınıf dengesizliği yüksek veri kümelerinde yaygın bir faktör olan yanlış pozitifleri de cezalandırır. Modelin performansının genel değerlendirmesini sağlayan tek bir değerdir. Birleşim Üzerinden Kesişme (IoU) olarak da bilinen Jaccard endeksi, iki küme arasındaki benzerliği, bunların kesişimlerinin birleşimlerine oranını hesaplayarak ölçer. Bu metriklerin tümü denklem (2.11-2.14)'de verildiği gibi hesaplanmıştır.

$$Kesinlik = \frac{TP}{TP + FP} \quad (2.11)$$

$$Hassasiyet = \frac{TP}{TP + FN} \quad (2.12)$$

$$Dice = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (2.13)$$

$$Jaccard = \frac{TP}{TP + FP + FN} \quad (2.14)$$

Burada TP (true positive), TN (true negative), FP (false positive) ve FN (false negative) sırasıyla gerek pozitiflerin, gerek negatiflerin, yanlış pozitiflerin ve yanlış negatiflerin sayısını temsil eder.



3. BULGULAR VE İRDELEME

Bu bölümde aort bölgesinde bulunan kalsifik alan segmentasyonu için kullanılan makine öğrenmesine ve derin öğrenmeye dayalı bilgisayar destekli tanı aşamalarında gerçekleştirilen deneylerden elde edilen görsel ve sayısal bulgular irdelenerek, literatürde bu alanda mevcut çalışmalarla performans karşılaştırması yapılacaktır. Önerilen yöntemlerin aort ilgi bölgesinin tespiti ve kalsifik alanların segmentasyonu problemlerine ayrı ayrı çözüm getirmeyi amaçlamaktadır. Önerilen yöntemlerden elde edilen bulgular ve literatürde mevcut çalışmalarla karşılaştırması alt ana başlıklar altında incelenmiştir.

3.1. Kalp Kapakçıklarında Kireçlenmenin Tespiti için Derin Öğrenmeye Dayalı Yaklaşımların Analizi ve Elde Edilen Deneysel Sonuçlar

3.1.1. Önerilen AVD-YOLOv5 Modelinin Aort Bölgesi Tespitine Etkisi

BT görüntüleri kullanılarak yapılan değerlendirmelerde, uzman kardiyologlar genelde kolaylıkla tanı koyabilselerde, birçok renk değişimine sahip ekokardiyografi görüntülerinde tanı koymakta zorlanırlar. Ayrıca ekokardiyografik görüntülerde kalsifik alanların otomatik analizinde meydana gelebilecek tüm renk değişimlerinde görüntülerin yüksek başarı ile segmentasyonunu gerçekleştirebilecek bir yöntem önermek zordur. Çünkü, ekokardiyografik görüntülerde aynı açıdan çekilen görüntüler kullanılsa bile, aort duvarı ve kalp kası dokuları yapısal özellikleri ve renk dağılımı açısından kalpteki kalsifik alanla büyük oranda benzerlik gösterir. Buna bağlı olarak benzer fizyolojik özelliklerinden dolayı kas dokuları ve aort duvarı, kalsifik alanlarla aynı şekilde değerlendirilebilmektedir ve ya çok küçük kalsifik alanlar değerlendirme sırasında gözden kaçabilmektedir. Eğitim setine kalsifik alan barındıran ve barındırmayan tüm görüntülerin eklenmesi, önerilen tek başına uygulanan UNET segmentasyonu yönteminin ilgili görüntülerde başarıyı düşürmesine sebep olmakla birlikte ağırlık öğrenmesi için gereken iterasyon sayısını da önemli ölçüde artıracaktır. Ayrıca bahsedilen doku yapılarının fizyolojik özelliklerinin etkisiyle yöntem yine de küçük bir değişikliğe karşı negatif sonuçlar doğurabilecektir.


Tüm bu sebepler göz önüne alındığında önerilen AVD-YOLOv5 modeli kullanılan segmentasyon yönteminden önce veri setine uygulanmıştır. UNET modelinin tek başına ve

Tablo 10. Önerilen AVD-YOLOv5 modelinin dört YOLOv5 modeli alt versiyonu ile performans karşılaştırması

Yöntem	#katman	#parametre	GFLOPs	Kesinlik	Hassasiyet	mAP	Çıkarım Süresi (ms)
YOLOv5-x	445	86217814	203.8	0.8	0.898	0.868	16.76
YOLOv5-l	368	46138294	107.6	0.957	0.903	0.926	9.72
YOLOv5-m	291	20871318	47.9	0.809	0.871	0.87	8.42
YOLOv5-s	214	7022326	15.8	0.952	0.871	0.903	7.95
AVD-YOLOv5	170	148844	0.6	0.943	0.868	0.896	2.58

AVD-YOLOv5 modeli ile birlikte uygulandığı senaryolara ait sonuçlar Tablo 11’de gösterildiği üzere segmentasyon başarısını önemli ölçüde artırmıştır.

Önerilen AVD-YOLOv5 modelinin klasik YOLOv5 modeline göre farkları veri setinin özellikleri temel alınarak değiştirilen parametreler ve katmanlar içerisinde kullanılan yöntemlerin değiştirilmesinden kaynaklanır. Tablo 10’de verilen sonuçlara bakıldığında yapılan tüm değişikliklerinin ağ performansını olumlu yönde etkilediği görülmektedir.




Şekil 23. AVD-YOLOv5 ile algılanan aort ilgi bölgesinin gösterimi. Kırmızı kutular uzman kardiyologlar tarafından belirlenen, yeşil kutular ise AVD-YOLOv5 modelinin tespit ettiği aort ilgi bölgesi sınırlarını göstermektedir.

AVD-YOLOv5 modelinin performansı hem niteliksel hem de niceliksel olarak değerlendirilmiştir. Şekil 23’de önerilen aort kapağı veri kümesindeki bazı örnek görüntülerin aort kapağı tespit sonuçlarını niteliksel olarak göstermektedir. Şekilde gösterildiği gibi, farklı şekil ve ölçeklere sahip aort kapakçıkları çok yüksek hassasiyetle tespit edilebilmektedir. Bu, önerilen AVD-YOLOv5 algılama modelinin çok güçlü bir sağlamlığa sahip olduğunu göstermektedir.

Aort ilgi bölgesi tespiti için kullanılan orijinal YOLOv5 mimarisinin eğitim süresi boyunca eğitim ve validasyon kümelerine ait bazı değerlerin değişimine ait grafikler Şekil


24’de verilmiştir. Yapılan eğitim süresince kesinlik ve hassasiyet değerlerinin hızlı bir şekilde 1’e, hata değerlerinin ise 0’a yakınsadığı görülmektedir.



Şekil 24. Orijinal YOLOv5 modelinin eğitim (ilk satır) ve validasyon (ikinci satır) kümelerine ait sınır kutusu hatası(box loss), nesnellik hatası(obj loss), kesinlik ve duyarlılık değerlerinin zamanla değişimini gösteren grafikler

Yeniden yapılandırılan AVD-YOLOv5 mimarisinin eğitim grafikleri Şekil 25’de gösterilmektedir. Grafikler, epok sayısı arttıkça, kesinlik ve hassasiyet değerlerinin giderek arttığını aynı zamanda doğrulama (validasyon) ve eğitim aşamalarının kayıp değerlerinin giderek azaldığını göstermektedir. Ayrıca, kesinlik ve hassasiyet değerlerinin 1’e yakınsama süresinin oldukça kısa olduğu ve kayıp değerlerinin 0’a yakınsama süresinin epok sayısına bağlı olduğu görülmektedir. Tüm bu veriler göz önüne alındığında, modelin kısa sürede başarılı bir şekilde eğitildiği söylenebilir.

Çalışmanın ikinci aşaması olan ekokardiyografi görüntülerinde segmentasyon incelendiğinde AVD-YOLOv5 yöntemini uygulayarak ve uygulanmadan yapılan eğitimlerin başarı oranları birbirlerinden oldukça farklıdır. Tablo 11’ de görüldüğü üzere, öncesinde AVD-YOLOv5 uygulanarak aort ilgi bölgesi belirlendikten sonra kalsifikasyon bulunduran bölgelerin segmente edildiği görüntüler sadece segmentasyon yapılan görüntülere oranla tüm metrikler açısından daha yüksek test başarısına ulaşmıştır. Önerilen yöntem uygulanarak kalsifik alan segmentasyonu yapıldığında, yöntemin kesinlik değerini %22.59, hassasiyet



Şekil 25. Önerilen AVD-YOLOv5 modelinin eğitim (ilk satır) ve validasyon (ikinci satır) kümelerine ait sınır kutusu hatası(box loss), nesnellik hatası(obj loss), kesinlik ve duyarlılık değerlerinin zamanla değişimini gösteren grafikler

Tablo 11. Aort ilgi bölgesine odaklanarak ve odaklanmadan yapılan model eğitimlerinin performans karşılaştırması

Yöntem	Kesinlik	Hassasiyet	Dice	Jaccard
UNET	66.80	78.92	38.40	24.90
AVD-YOLOv5 + UNET	86.30	80.27	76.27	61.90

değerini %1.68, dice değerini %49,65, ve jaccard değerini ise %59,77, oranında artırdığı görülmüştür.

3.1.2. Uygulanan Makine Öğrenmesi Yöntemlerinin Kalsifikasyon Segmentasyonu Performansı

Çalışmada aort bölgesinde bulunan kalsifik alanların segmentasyonu için öncelikle makine öğrenmesine dayalı yöntemler denenmiş ve Tablo 12’te verilen sonuçlar elde edilmiştir.

Elde edilen sonuçlara bakıldığında en yüksek performansı topluluk (ensemble) öğrenme yöntemi kullanan dengelenmiş torbalama (Balanced Bagging) algoritmasının verdiği görülmüştür. Bu algoritma sınıf dengesizliği bulunan veri kümelerinde, az bulunan kategoriye

Tablo 12. Kalsifik alanların segmentasyonu amacıyla kullanılan makine öğrenmesine dayalı yöntemlerin performans karşılaştırması

Yöntem	Kesinlik	Hassasiyet	Dice	Jaccard
K-NN	55.92	31.77	40.52	25.41
Rastgele Orman	16.21	99.74	27.89	16.20
Uyarlanabilir Güçlendirme	25.0	97.03	39.76	24.8
Dengeli Torbalama	25.79	96.56	40.71	25.56

ait örneklerin ağırlıklarını her iterasyonda artırarak eğitim süresince daha fazla dikkate alınmasını sağlamış ve en son bu ağırlıklarla güçlü öğrenici oluşturarak tahminleri yapmıştır. Bu sebeple diğer makine öğrenmesi algoritmalarına göre başarı performansı daha yüksektir.


3.1.3. Uygulanan Derin Ağ Mimarisinin Kalsifikasyon Segmentasyonu Performansı Üzerindeki Etkisi

Kalp bölgesine ait medikal görüntülerde kullanılan segmentasyon yöntemleri genellikle CNN tabanlıdır. Ayrıca bu alanda yapılan çalışmaların tamamında kalsifik alanların segmentasyonunda BT görüntüleri kullanılmıştır. Bu bağlamda ekokardiyografi görüntüleri üzerinden segmentasyon işlemi ilk defa gerçekleştirilmiştir. Çalışmada özgün bir veri seti oluşturulmaya başlandığından segmentasyon için genellikle az sayıda veri ile de başarıyı yakalayabilen UNet mimarisi kullanılmıştır. Buna ek olarak segmentasyon için kullanılan en popüler yöntemlerden FCN ve SegNet mimarileri de denenmiş ve sonuçlar karşılaştırılmıştır. Bu mimarilerin hepsi FCNN (Fully Convolutional Neural Network) tabanlı mimarilerdir. Ayrıca makine öğrenmesinde popüler olmalarından ve çeşitli tıbbi görüntü segmentasyon problemlerine adapte edildiklerinde iyi performans gösterdiklerinden dolayı seçilmişlerdir.

Tablo 13. Önerilen veri kümesi üzerinde üç derin öğrenme modelinin performans karşılaştırması.

Yöntem	Kesinlik	Hassasiyet	Dice	Jaccard
FCN	83.92	91.64	75.51	61.72
SegNet	80.5	92.35	72.46	56.84
UNET	86.3	80.27	76.27	61.90

Tablo 13’de sunulan sonuçlar analiz edildiğinde, UNET modelinin kesinlik, dice ve jaccard değerlerinin FCN ve SegNet’i sürekli olarak geride bıraktığı görülmektedir. Test veri kümesinde ise %86,3 hassasiyet ve %76,27 Dice değeri ile UNET modeli, aort kapağındaki kireçlenmeyi kesin olarak tanımlamada umut verici bir performans sergilemiştir.



Şekil 26. (a) Orijinal girdi görüntüsü, (b) temel gerçeklik maskesi ve (c) UNET ile model eğitiminin sonuna ulaştırılan tahmini maske

Yöntemlerin segmentasyon performansı, Kesinlik, Hassaiyet, Dice, ve Jaccard ölçütleri kullanılarak ölçülmüştür. Kesinlik metriği, doğru tahmin edilen pozitif örneklerin tahmin edilen tüm pozitif örneklere oranını gösterir ve UNET modelinin yanlış pozitifleri en aza indirme yeteneğini vurgular. Benzer şekilde, tahmin edilen ve temel gerçek segmentasyonları arasındaki örtüşmeyi temsil eden Dice değeri, UNET modelinin kalsifikasyon bölgelerini doğru bir şekilde tanımlama konusundaki yeterliliğinin altını çizmektedir. Jaccard endeksi, tahmin edilen ve gerçek segmentasyonlar arasındaki benzerliği ölçerek UNET modelinin sağlam performansını daha da doğrulamaktadır.

Ayrıca, segmentasyon sonuçlarının görsel olarak incelenmesi, FCN ve SegNet'e kıyasla kalsifik alanların daha net bir şekilde tanımlandığını göstererek UNET modelinin etkinliğini daha da doğrulamaktadır. Şekil 26'de gösterildiği gibi, UNET modeli tarafından elde edilen segmentasyon sonuçları, temel gerçek sonuçlarına yakından benzemektedir.

Bu, modelin aort kapakındaki kireçlenme bölgelerini doğru bir şekilde belirleme kabiliyetinin altını çizmekte ve semantik segmentasyon görevlerindeki etkinliğini göstermektedir. Bu çalışma, tıbbi görüntüleme alanında önemli bir kilometre taşıdır ve kardiyologlara aort kapak kalsifikasyonlarının otomatik ve doğru bir şekilde skorlanması için sağlam bir yardımcı araç sağlamaktadır.

Yüksek duyarlılık değeri, kalsifik bölgelere ait piksellerin yüksek oranda doğru sınıflandırıldığı diğer bir deyişle FN sayısının az olduğu anlamına gelmektedir. Yüksek özgüllük değeri ise, kalsifik alana ait olmayan piksellerin düşük oranda kalsifik alana

ait olarak sınıflandırıldığı diğer bir deyişle FP sayısının az olduğu anlamına gelmektedir. Tablo 11’de önerilen AVD-YOLOv5 yöntemi uygulanmadan önce kesinlik ve duyarlılık değerlerinin oldukça düşük olduğu görülmektedir. Bunun sebebi, kalsifik alana ait piksellerin yanlışlıkla arka plan olarak sınıflandırılması dolayısıyla FN sayısının yüksek olmasıdır. Önerilen yöntem uygulandıktan sonra kalsifik alana ait piksellerin doğru sınıflandırılması ile kesinlik ve duyarlılık değerlerinin yüksek oranda iyileştirildiği görülmüştür. Ayrıca dice ve jaccard değerlerinin yöntem uygulanmadan önce ve uygulandıktan sonra yüksek olduğu görülmektedir. Bunun sebebi ise her iki durumda da FP sayısının düşük olması ve çekirdek olmayan piksellerin yüksek oranda doğru sınıflandırılmasıdır.

3.1.4. Önerilen AVD-YOLOv5 Yönteminin Literatürdeki Diğer Yöntemlerle Karşılaştırılması

Tablo 14. Önerilen AVD-YOLOv5 modelinin literatürdeki benzer çalışmalarla performans karşılaştırması.

Referans	IoU Eşik Değeri	Yöntem	Doğruluk	Kesinlik	Hassasiyet
Nizar ve ark. Nizar vd. (2020)	0.5	Faster-RCNN + Inceptionv2 ResNet50 + Faster-RCNN	0.949 0.724	0.942 0.668	0.957 0.89
Hatfaludi ve ark. Hatfaludi vd. (2022)	0.5	VGG-16 VGG-19 ResNet-19 ResNet-50	-	0.894 0.852 0.894 0.932	0.988 0.997 0.997 0.997
Önerilen Yöntem	0.9	AVD-YOLOv5	0.95	0.943	0.868

Önerilen modelin uygunluğunu daha fazla değerlendirmek için, önerilen modelimizi (AVD-YOLOv5) Tablo 14’da özetlendiği gibi ekokardiyografi görüntülerinde aortik bölge tespiti için yapılan son teknoloji CNN tabanlı çalışmalarla karşılaştırdık. Bu çalışmalar çok küçük IoU eşik değerlerine sahip farklı veri kümeleri üzerinde gerçekleştirilmiştir. Ayrıca, ortak veri kümelerinin mevcut olmaması nedeniyle, tüm modeller için aynı konfigürasyonlar ve ayarlar kullanılarak adil ve titiz bir karşılaştırma elde edilememiştir. Nizar vd. (2020) çalışmasında, Faster R-CNN ve Inception V2 modelleri 94,9% kesinlik, 94,2% kesinlik ve 95,7% geri çağırma elde etmiştir. Ancak bu çalışmada nispeten düşük bir IoU eşik değeri (0,5) kullanılması dikkat çekicidir. Benzer şekilde, Hatfaludi vd. (2022) çalışmasında, ResNet-50 modeli, 0,5 gibi düşük bir IoU eşik değeri ile 93,2% ve 99,7% geri çağırma ile en yüksek hassasiyeti vermiştir. Öte yandan, önerilen çalışmamız 0,9 gibi yüksek bir IoU eşik değeri ile karşılaştırılabilir sonuçlar göstermiş, 95% kesinlik, 94,3% kesinlik ve 86,8% geri çağırma

elde etmiştir. IoU eşik değeri, aranan nesnelerin doğru bir şekilde tespit edilmesini sağlar. Bu nedenle, önerilen çalışmamızda sunulan sonuçlar, yüksek IoU eşik değeri dikkate alındığında daha güvenilirdir. Düşük IoU eşik değerinin seçilmesinin, tanınan nesnenin aranan nesne olma olasılığını artırdığını ve böylece TP sayısını artırarak hassasiyeti iyileştirdiğini ve FN sayısını azaltarak geri çağırmaı iyileştirdiğini belirtmek önemlidir. Çalışmamızdaki düşük geri çağırma değeri bu gerçekten kaynaklanmaktadır.

Genel olarak, önerilen AVD-YOLOv5 modelinin doğruluk ve hız arasında denge sağladığı ve önemli ölçüde daha az parametre ve hesaplama karmaşıklığı ile rekabetçi bir performans sunduğu görünmektedir. Hem yüksek doğruluk hem de verimlilik beklenen nesne tespit görevleri için umut verici bir çözüm gibi görünmektedir.

3.2. Aort Bölgesinde Bulunan Kalsifik Alanların Derin Öğrenme Yöntemlerine Dayalı Otomatik Tespiti Yaklaşımının Analizi ve Elde Edilen Deneysel Sonuçlar

Bu bölümde ilk olarak, kalsifik alanların tespit edilmesinde uygulanan FCNN tabanlı popüler segmentasyon yöntemlerine ait ağ mimarilerinin performansları nicel ve nitel olarak karşılaştırılmıştır. Ayrıca, önerilen ağ mimarisinde birçok ağ parametresi değiştirilerek segmentasyon performansına etkisi araştırılmıştır. Son olarak, elde edilen sonuçlar daha önce kalsifik alan segmentasyonunda yayınlanan önceki çalışmaların sonuçlarıyla karşılaştırılmıştır.

Nicel olarak, Tablo 13’de, popüler FCNN yöntemlerinden olan FCN, SegNet ağ mimarileri ile önerilen UNET ağ mimarisinin segmentasyon performansı karşılaştırılmıştır. Bu çalışmada ayrıca, sınıflandırma amacıyla yaygın olarak kullanılan makine öğrenmesi yöntemleri ile performans karşılaştırması gerçekleştirilmiştir. Bu karşılaştırma, derin öğrenmeye dayalı yöntemlerin etkinliğini araştırmak amacıyla gerçekleştirilmiştir.

Yöntemlerin performansı, Bölüm 2.4’te belirtilen dört ölçüt kullanılarak değerlendirilmiştir: Kesinlik, Hassasiyet, Dice benzerlik katsayısı ve Jaccard benzerlik katsayısı.

3.2.1. Ağ Derinliğinin Segmentasyon Performansı Üzerindeki Etkisi

Önerilen kalsifik alan segmentasyonu yöntemi mimarisi oluşturulurken öncelikle farklı ağ derinliklerinin segmentasyon performansına etkisi incelenmiştir. Bu amaçla ağ derinliği N sırasıyla 3, 4 ve 5 olarak seçilerek UNET yönteminin segmentasyon performansına

Tablo 15. Önerilen mimari üzerinde katman derinliği değişiminin modelin performansına etkisi

#katman Derinliği	Kesinlik	Duyarlılık	Dice	Jaccard
3	81.32	74.77	70.10	54.64
4	77.01	84.82	72.05	57.13
5	86.30	80.27	76.27	61.90

etkisi Jaccard ve Dice benzerlik katsayısı performans kriterleri açısından Tablo 15'daki gibi karşılaştırılmıştır.

N derinlikten her biri, Şekil 11'de gösterildiği gibi art arda gelen konvolüsyon (Conv) katmanı, BN katmanı, ve ReLU katmanı anlamına gelmektedir. Tablo 15'de gösterildiği gibi önerilen model N=5 derinliğe sahip olduğunda yöntemlerin Jaccard ve Dice açısından en iyi performansa sahip olduğu görülmüştür. Ayrıca derinliğin belirli bir noktadan sonra artması performans düşüşüne neden olmakla birlikte ağı karmaşıklığını artırmaktadır. Bu sonuçlardan yola çıkarak bu çalışmada ağ derinliği N=5 olarak seçilmiştir.

3.2.2. Veri Setine Tüm verilerin Eklenmesi

Kalsifik alan segmentasyonu için oluşturulan veri seti yalnızca kalsifik alan bulunduran ekokardiyografi görüntülerinden seçilerek elde edilmiştir. Kalsifik alan segmentasyonunda başarı oranı en yüksek olan UNET mimarisinin kalsifik alan bulundurmeyen görüntülerdeki başarı performansını ölçmek amacıyla eğitim ve test kümelerine farklı oranlarda kalsifik alan bulundurmeyen görüntüler eklenerek Tablo 16'de verilen şekilde veri kümesi varyasyonları oluşturulmuş ve UNET ile başarıları ölçülmüştür.

Tablo 16. Kalsifik alan bulunduran ve bulundurmeyen görüntülerden oluşan veri seti varyasyonları

Veri Seti	Eğitim Seti		Test Seti	
	#Kalsifik Görüntü	#Kalsifik Olmayan Görüntü	#Kalsifik Görüntü	#Kalsifik Olmayan Görüntü
Veri_1	106	0	12	0
Veri_2	106	0	12	12
Veri_3	106	0	12	6
Veri_4	106	106	12	6
Veri_5	106	53	12	6

Tablo 17. Oluşturulan veri seti varyasyonlarının performans karşılaştırma sonuçları


Veri Seti	Kesinlik	Hassasiyet	Dice	Jaccard
Veri_1	86.30	80.27	76.27	61.90
Veri_2	49.73	37.24	41.10	33.87
Veri_3	61.64	55.03	55.93	46.54
Veri_4	77.6	41.53	58.20	48.77
Veri_5	59.78	56.33	55.94	46.36

Tamamı kalsifikasyon bulunduran görüntülere sırasıyla eğitim seti sabit tutularak test aşamasında kalsifik görüntü sayısına eşit miktarda ve kalsifik görüntülerin %50'si kadar kalsifik olmayan görüntü eklenmiştir. Daha sonra kalsifik olmayan görüntüler eğitim kümesine de sırasıyla kalsifik görüntüler ile aynı miktarda ve kalsifik görüntülerin %50'si kadar eklenerek UNET ağının başarısını nasıl etkiledikleri test edilmiştir.

Tablo 17'de verilen sonuçlarda görüldüğü üzere kalsifik görüntülerle eğitilen bir modelin test sırasında kalsifik olmayan görüntülerle karşılaşması performansı düşürmüştür. Test sırasında verilen kalsifik olmayan görüntülerin sayısı arttıkça performansın düştüğü görülmektedir. Kalsifik olmayan görüntülerle ilk kez test sırasında karşılaşılması için eğitim kümesine kalsifik olmayan görüntüler farklı oranlarda eklenmiştir. Fakat eğitim kümesinde kalsifik olmayan görüntüler modele tanıtılmasına rağmen test performansının oldukça azaldığı gözlemlenmiştir.

Tamamen kalsifik olan görüntülerle eğitilen ve sonra aynı oranda kalsifik olmayan görüntüler eklenerek eğitilen modelde, kalsifik olmayan görüntülerin modelin test sonuçlarında, kesinlik değerini %10.08, hassasiyet değerini %48.26, Dice benzerlik katsayısını %23.69 ve Jaccard benzerlik katsayısını %26.92 oranında düşürdüğü gözlemlenmiştir. Eğitime konulan kalsifik olmayan görüntülerin oranı yarıya indirildiğinde test başarısının yükseldiği görülmüştür.

Şekil 27'de görüldüğü üzere, kalsifik alan içermeyen görüntülerin segmentasyon aşamasına dahil edilmesi, hem kalsifik alan içeren hem de içermeyen görüntülerin test aşamasındaki başarı oranlarını olumsuz yönde etkilemiştir. Bu durumun incelenmesi, segmentasyon aşamasında karşılaşılan bazı önemli sorunları ortaya koymaktadır. Kalsifik alan içeren görüntülerde, modelin daha fazla bölgeyi konumdan bağımsız olarak yüksek piksel parlaklıklarına odaklanarak kalsifikasyon olarak algıladığı görülmektedir. Bu durum, modelin beyaz piksellere yakın gürültüleri de kalsifikasyon olarak algılama eğiliminde olduğunu göstermektedir. Bu yanlış algılama, özellikle kalsifik olmayan bölgelerdeki beyaz piksellerin yanlış sınıflandırılmasına yol açmaktadır.



Şekil 27. Kalsifik (a satırı) ve kalsifik olmayan (b satırı) görüntülere ait temel gerçeklik maskeleri (1. sütun) ve sırasıyla 2, 3, 4, 5 ve 6. sütun, tablo 16’de belirtilen 1, 2, 3, 4 ve 5 numaralı veri setleri kullanılarak eğitilen UNET modelinin ürettiği tahmin maskeleri

Öte yandan, kalsifik alan içermeyen görüntülerde ise, eğitilen modelin yüksek parlaklığa sahip olan beyaz bölgeleri kalsifik alan olarak algılama eğiliminin arttığı gözlemlenmiştir. Bu durum, modelin gerçek kalsifik alanları tespit etmede zorlanmasına ve kalsifik olmayan beyaz alanları yanlış şekilde kalsifikasyon olarak sınıflandırmasına sebep olmaktadır. Bu tür hatalar, modelin genel doğruluğunu olumsuz yönde etkileyerek, kalsifik alanların doğru tespiti ve segmentasyonu konusunda performans kaybına neden olmaktadır.

Elde edilen sonuçlar, kalsifikasyon barındıran ve barındırmayan ekokardiyografi görüntülerinin hem eğitim hem de test aşamalarına dahil edilmesinin, eğitim süresini önemli ölçüde artırdığını ve bunun yanında elde edilen test doğruluğunu ve kaybını olumsuz yönde etkilediğini açıkça göstermektedir. Kalsifik alan içermeyen görüntülerin dahil edilmesi, modelin öğrenme sürecinde karmaşıklığı artırarak, eğitim süresinin uzamasına ve modelin doğruluk oranının düşmesine yol açmaktadır. Ayrıca, bu durum test aşamasında da benzer olumsuz etkiler yaratmakta, modelin kalsifik alanları tespit etme yeteneğini azaltmakta ve yanlış pozitif oranını artırmaktadır.

Bu bulgular, kalsifikasyon barındıran ve barındırmayan ekokardiyografi görüntülerinin eğitim ve test aşamalarına dahil edilmesinin dikkatli bir şekilde değerlendirilmesi gerektiğini ve bu sürecin model performansı üzerindeki etkilerinin iyice analiz edilmesi gerektiğini göstermektedir. Daha iyi sonuçlar elde etmek için, eğitim verilerinin seçimi ve işlenmesi aşamasında bu faktörlerin göz önünde bulundurulması önem arz etmektedir.

4. SONUÇLAR

Tez çalışmaları kapsamında, kalbin aort ilgi bölgesinde kapakçıklarda kalsifikasyon tespiti için derin öğrenme tabanlı bilgisayar destekli yöntemlerin geliştirilmesi ve uygulanması gerçekleştirilmiştir.

Önerilen yaklaşımlar ile kalsifik alan tespiti aşamalarında mevcut yöntemlerin değerlendirilmesiyle birlikte yeni yaklaşımlar geliştirilmiştir. Mevcut uygulamalarda yalnızca BT görüntüleri üzerinden kalsifik alan tespiti yapılırken, bu çalışmada tüm işlemler ekokardiyografi görüntüleri üzerinde geliştirilmiş ve test edilmiştir. Tez çalışmasında ayrıca algılama ve segmentasyon adımlarının her biri için ekokardiyografi görüntülerinden oluşan özgün veri setleri önerilmiştir. Önerilen veri setleri üzerinde eğitimler yapılmış ve çeşitli nicel ve nitel sonuçlar elde edilmiştir.

Bu bölümde, tez çalışması kapsamında elde edilen sonuçlar özet biçimde sıralanacaktır.

Ekokardiyografi görüntülerinde kalsifikasyon beklenen aort ilgi bölgesinin tespiti için ilk aşama olarak derin öğrenme yöntemi olan YOLOv5 kullanılmış ve ağ mimarisinde özgünlükler önerilmiştir.

YOLO ile algılama işlemi için oluşturulan veri setinde en yüksek performansı elde etmek amacıyla parametrelerde değişiklik yapılarak ablasyon çalışması gerçekleştirilmiş ve model en iyi versiyonuna iyileştirilmiştir.

Aort ilgi bölesinin algılanması için sonuçlar incelendiğinde, veri setinde önerilen yöntemin mevcut detection yönteminin başarısını önemli oranda artırdığı ve modeli hızlandırdığı görülmüştür.

Kalsifik alanın segmentasyonu için makine öğrenmesi yöntemleri klasik olarak ve daha sonra özellik çıkarımı yapılarak uygulanmış ve sonuçları karşılaştırılmıştır.

Kalsifikasyon segmentasyonu için makine öğrenmesi yöntemlerine ek olarak medikal görüntü segmentasyonunda popüler olan derin öğrenme yöntemleri veri seti üzerinde uygulanmış ve yöntemlerin performansları karşılaştırılmıştır. Ayrıca ağ mimarisindeki tüm parametreler veri setine uygun hale getirilerek performans üzerindeki etkisi incelenmiştir.

Sonuçlar incelendiğinde uygulanan yöntemin diğer segmentasyon yöntemlerine göre daha iyi performans gösterdiği ve başarıyı önemli oranda artırdığı görülmüştür. Ayrıca kalsifik alanların literatürde mevcut diğer yöntemlerde olduğu gibi BT üzerinde değil, direkt

ekokardiyografi görüntüleri üzerinde tespit edilmesi daha hızlı bir teşhis, tanı ve tedavi süreci olmasına katkıda bulunmuştur.

Kalp kapakçık bölgesinin algılanması amacıyla ve daha sonra algılanan bölgede kalsifik alan segmentasyonu için bu alanda ilk olacak iki veri seti (Detection Veri Seti, Segmentasyon Veri Seti) önerilmiştir.

Konvolüsyonel Sinir Ağları'nın nesne algılama alanında kullanılmaya başlanması ile birlikte Daha Hızlı R-CNN, R-FCN, SSD ve YOLO gibi birçok nesne algılayıcı önerilmiştir. Bu algılayıcılar genellikle büyük boyutlu nesnelerin (yüz, yaya, araç vb.) algılanmasında uygulanmıştır ve başarılı sonuçlar verdiği görülmüştür. Yapılan çalışmalardan anlaşıldığı üzere herhangi bir alanda hangi algılayıcının daha uygun olduğunu bilmek zordur ve yöntemlerin küçük boyutlu nesneler üzerinde çalışabilmesi için nasıl uygulanmaları gerektiği literatürde boşluk olarak görülmektedir. Dolayısıyla tez çalışmasında YOLOv5 nesne algılayıcı aort ilgi bölgesi algılama amaçlı önerilmiştir. Elde edilen sonuçlar neticesinde gerçek zamanlı uygulamalar için en hızlı algılama sağlayan YOLOv5 mimarisinin başarısını belirli seviyede tutmayı hedefleyerek daha hızlı çalışması için YOLOv5 mimarisinde iyileştirmeler yapılarak iki farklı ağ mimarisi önerilmiştir. Bu çalışma aort ilgi bölgesinin tespit literatüründe pek çok karşılaştırmanın yapıldığı ve yüksek başarılı performans gösteren ilk çalışma olma özelliğini taşımaktadır.

5. ÖNERİLER VE TARTIŞMA

Kalp aort bölgesinde ve kapakçık üzerinde görülen normal olmayan durumlar pek çok kalp hastalığının öncüsüdür ve bu durumla ilgili erken teşhisi sağlayan parametrelerden biridir. Aort ilgi bölgesinde oluşan kalsifikasyon ilerleyen süreçlerde arttığı takdirde kalp kaslarının yeterince kasılıp gevşeyememesinden dolayı damar daralması ve tıkanıklığa sebep olur.

Günümüzde kalsifik alan tespiti BT üzerinden yapılmaktadır. Fakat BT üzerinden yapılan çalışmalarda oldukça azdır. Öncelikle bu alandaki boşluklar göz önüne alınarak BT aşamasına geçmeye ihtiyaç kalmadan ekokardiyografi görüntüleri üzerinden aort bölgesinin tespit edilerek, o bölgede bulunan kalsifik alanların belirlenmesi tam otomatik bir şekilde gerçekleştirilmiştir. Bu işlemlerin otomatikleştirilmesi ile birlikte kalp hastalıklarının teşhisinde bu yaklaşımlar öncü rol üstlenmiş olacaktır. Tez çalışmasının derin öğrenme modellerinin klasik makine öğrenmesi yöntemlerine göre daha iyi sonuçlar verdiği ve hem başarı hem hız açısından performansı artırdığı görülmüştür. Bu bağlamda ilgili alanda çalışacak araştırmacıların derin öğrenme yöntemlerinin uygulanmasına ve geliştirilmesine yönelmesi ilgili alandaki çalışmaların niteliğini artıracaktır.

Ekokardiyografik görüntülerde kalp kapakçık bölgesindeki kalsifik alanların doğru bir şekilde tespit edilmesi, kardiyovasküler hastalıkların teşhisinden tedavi süreçlerine kadar önemli bir rol oynamaktadır. Bu nedenle, bilgisayar destekli tanı yöntemlerinin gerçek zamanlı olarak uygulanabilmesi, sağlık profesyonellerinin hastalarına hızlı ve etkili bir şekilde müdahale etmelerini sağlamak için kritik öneme sahiptir. Bu bağlamda, derin öğrenme mimarilerinin kullanımının, ekokardiyografik görüntüler üzerindeki kalsifik alanların algılanması için önemli bir potansiyele sahip olduğu, farklı derin öğrenme mimarilerinin tasarlanabileceği ve geliştirilebileceği, bunun da algılama doğruluğunu ve işleme hızını artırabileceği düşünülmektedir.

Bu gelişmeler, klinik uygulamalarda bilgisayar destekli tanı yöntemlerinin daha yaygın ve etkin bir şekilde kullanılmasına yol açabilir. Sonuç olarak, hastaların tanı ve tedavi süreçlerinin hızlanması ve iyileştirilmesi sağlanabilir, bu da sağlık hizmetlerinin kalitesini artırabilir.

Ekokardiyografik görüntülerde aort duvarı ve kalp kasının bulunduğu bölgeler, kalsifik alanlarla benzer renk dağılımına sahip olduğu görülmektedir. Bu benzerlikler piksel bazlı

derin öğrenme modellerinin performansını olumsuz yönde etkileyen faktörlerden biridir. Aort ilgi bölgesinin tespiti bu amaçla önerilen bir ön uygulamadır ve tez çalışmasında kalsifik alan segmentasyonu performansını artırdığı kanıtlanmıştır. Bu açıdan bakıldığında araştırmacıların aort duvarı dışında kalan bölgeyi ve kas dokusunu kalsifik alanlardan ayıracak ve konumun daha fazla dikkate alındığı bir model geliştirmeye yönelmesi çalışmaların niteliğini artıracaktır.

Tez kapsamında ekokardiyografi görüntülerinden oluşan, aort ilgi bölgesinin tespiti için ve aort bölgesindeki kalsifik alan segmentasyonu için iki adet veri seti oluşturulmuştur. İlerleyen çalışmalarda bu veri setlerinin geliştirilebilir ve segmentasyon performansına etkisi gözlemlenebilir. Ayrıca tez kapsamında oluşturulan veri setleri literatürde ekokardiyografi görüntüleri kullanılarak aort bölge tespiti ve kalsifik alan segmentasyonu için oluşturulan ilk veri setleridir. Dolayısıyla oluşturulan veri setleri bu alanda gelecekte yapılacak çalışmalara da temel oluşturacaktır. Bu alanda daha çok BT görüntülerinden oluşan veri setleri ve bu görüntüleri kullanan yöntemler kullanıldığından, ekokardiyografi görüntüleri kullanılarak yapılan çalışmaların sağlık sektöründe ve literatürde özgün çalışma ve uygulama alanı bulacağı düşünülmektedir.

Tez kapsamında yapılan çalışmalar aort ilgi bölgesini görüntüler üzerinde ve ekokardiyografi videoları üzerinde gerçek zamanlı algılamayı sağlamıştır. Gerçek dünyada kardiyologlar ultrason üzerinde aort bölgesini bulsalar bile ilgili bölgedeki kalsifik alanı tespit etme aşamasında zorlanmaktadırlar ve emin olmak amacıyla şüphelendikleri hastaları BT görüntülemeye yönlendirmektedirler. Tez kapsamında önerilen ve uygulanan bilgisayar destekli tanı yaklaşımları ile sadece ekokardiyografi görüntüleri kullanılarak hem ilgi bölgesinin bulunması hem de kalsifik alanların tespit edilmesi otomatik olarak gerçekleştirilmiştir. Bu anlamda kardiyologların iş yükü önemli ölçüde azaltılmış ve buna bağlı olarak teşhis ve tanı aşamasındaki karar süreci hızlandırılmıştır.

6. KAYNAKLAR

- Agatston, A. S., Janowitz, W. R., Hildner, F. J., Zusmer, N. R., Viamonte Jr, M., & Detrano, R. (1990). Quantification of coronary artery calcium using ultrafast computed tomography. *Journal of the American college of cardiology*, 15(4), 827–832.
- Al Alwany, A. A. (2022). Echocardiographic assessment of the aortic stenosis valve area: Parameters and outcome. *Echocardiography*, 3, 2D.
- An, F.-P., & Liu, Z.-W. (2019). Medical image segmentation algorithm based on feedback mechanism cnn. *Contrast Media & Molecular Imaging*, 2019(1), 6134942.
- Azzalini, L., Ghoshhajra, B. B., Elmariah, S., Passeri, J. J., Inglessis, I., Palacios, I. F., & Abbara, S. (2014). The aortic valve calcium nodule score (avcns) independently predicts paravalvular regurgitation after transcatheter aortic valve replacement (tavr). *Journal of cardiovascular computed tomography*, 8(2), 131–140.
- Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 39(12), 2481–2495.
- Bellhouse, B. J., & Talbot, L. (1969). The fluid mechanics of the aortic valve. *Journal of fluid mechanics*, 35(4), 721–735.
- bin Ahmad Nizar, M. H., Chan, C. K., Yusof, A. K. M., Khalil, A., & Lai, K. W. (2018). Detection of aortic valve from echocardiography in real-time using convolutional neural network. *2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, (Bildiriler Kitabı: 91–95). IEEE.
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5–32.
- Çakır, M., Ekinci, M., Kablan, E. B., & Şahin, M. (2023). Deep learning-based automatic detection of aortic valve on echocardiographic images. *2023 31st Signal Processing and Communications Applications Conference (SIU)*, (Bildiriler Kitabı: 1–4). IEEE.
- Çakır, M., Ekinci, M., Kablan, E. B., & Şahin, M. (2024). Avd-yolov5: a new lightweight network architecture for high-speed aortic valve detection from a new and large echocardiography dataset. *Medical & Biological Engineering & Computing*, (Bildiriler Kitabı: 1–18).
- Carabello, B. A., & Paulus, W. J. (2009). Aortic stenosis. *The lancet*, 373(9667), 956–966.
- Chang, S., Kim, H., Suh, Y. J., Choi, D. M., Kim, H., Kim, D. K., Kim, J. Y., Yoo, J. Y., & Choi, B. W. (2021). Development of a deep learning-based algorithm for the automatic detection and quantification of aortic valve calcium. *European Journal of Radiology*, 137, 109582.

- Clavel, M.-A., Burwash, I. G., & Pibarot, P. (2017). Cardiac imaging for assessing low-gradient severe aortic stenosis. *JACC: Cardiovascular Imaging*, 10(2), 185–202.
- drzezo (2022). Aortic Valve Disease. Accessed 16-August-2023.
URL <https://thoracickey.com/aortic-valve-disease-10/>
- Fu, J., Singhrao, K., Cao, M., Yu, V., Santhanam, A. P., Yang, Y., Guo, M., Raldow, A. C., Ruan, D., & Lewis, J. H. (2020). Generation of abdominal synthetic cts from 0.35 t mr images using generative adversarial networks for mr-only liver radiotherapy. *Biomedical Physics & Engineering Express*, 6(1), 015033.
- Hatfaludi, C.-A., Ciusdel, C. F., Toma, A., & Itu, L. M. (2022). Deep learning based aortic valve detection and state classification on echocardiographies. *2022 IEEE 20th International Power Electronics and Motion Control Conference (PEMC)*, (Bildiriler Kitabı: 275–280). IEEE.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Hyun, S.-M., & Lee, K. (2023). The study on tavr medical twin method based on real world data (rwd). *2023 International Conference on Information Networking (ICOIN)*, (Bildiriler Kitabı: 678–682). IEEE.
- Iung, B., & Vahanian, A. (2011). Epidemiology of valvular heart disease in the adult. *Nature Reviews Cardiology*, 8(3), 162–172.
- Khalique, O. K., Hahn, R. T., Gada, H., Nazif, T. M., Vahl, T. P., George, I., Kalesan, B., Forster, M., Williams, M. B., Leon, M. B., vd. (2014). Quantity and location of aortic valve complex calcification predicts severity and location of paravalvular regurgitation and frequency of post-dilation after balloon-expandable transcatheter aortic valve replacement. *JACC: Cardiovascular Interventions*, 7(8), 885–894.
- Lai, K. W., Shoaib, M. A., Chuah, J. H., Nizar, M. H. A., Anis, S., & Ching, S. L. W. (2021). Detection of aortic valve using deep learning approaches. *2020 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, (Bildiriler Kitabı: 538–542). IEEE.
- Lessmann, N., van Ginneken, B., Zreik, M., de Jong, P. A., de Vos, B. D., Viergever, M. A., & Išgum, I. (2017). Automatic calcium scoring in low-dose chest ct using deep neural networks with dilated convolutions. *IEEE transactions on medical imaging*, 37(2), 615–625.
- Liu, S., Qi, L., Qin, H., Shi, J., & Jia, J. (2018). Path aggregation network for instance segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*, (Bildiriler Kitabı: 8759–8768).
- Nelson, J., & Solawetz, J. (2020). YOLOv5 is here: State-of-the-art object detection at 140 fps. *Roboflow com* <https://blog.roboflow.com/yolov5-is-here> Accessed, 17.
- Nizar, M. H. A., Chan, C. K., Khalil, A., Yusof, A. K. M., & Lai, K. W. (2020). Real-time detection of aortic valve in echocardiography using convolutional neural networks. *Current medical imaging*, 16(5), 584–591.

- Osnabrugge, R. L., Mylotte, D., Head, S. J., Van Mieghem, N. M., Nkomo, V. T., LeReun, C. M., Bogers, A. J., Piazza, N., & Kappetein, A. P. (2013). Aortic stenosis in the elderly: disease prevalence and number of candidates for transcatheter aortic valve replacement: a meta-analysis and modeling study. *Journal of the American College of Cardiology*, 62(11), 1002–1012.
- Pawade, T., Clavel, M.-A., Tribouilloy, C., Dreyfus, J., Mathieu, T., Tastet, L., Renard, C., Gun, M., Jenkins, W. S. A., Macron, L., vd. (2018). Computed tomography aortic valve calcium scoring in patients with aortic stenosis. *Circulation: Cardiovascular Imaging*, 11(3), e007146.
- Pawade, T. A., Newby, D. E., & Dweck, M. R. (2015). Calcification in aortic stenosis: the skeleton key. *Journal of the American College of Cardiology*, 66(5), 561–577.
- Peterson, L. E. (2009). K-nearest neighbor. *Scholarpedia*, 4(2), 1883.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*, (Bildiriler Kitabı: 779–788).
- Redmon, J., & Farhadi, A. (2017). Yolo9000: better, faster, stronger. *Proceedings of the IEEE conference on computer vision and pattern recognition*, (Bildiriler Kitabı: 7263–7271).
- Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. *arXiv preprint arXiv:1804.02767*.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18*, (Bildiriler Kitabı: 234–241). Springer.
- Rosenhek, R., Binder, T., Porenta, G., Lang, I., Christ, G., Schemper, M., Maurer, G., & Baumgartner, H. (2000). Predictors of outcome in severe, asymptomatic aortic stenosis. *New England Journal of Medicine*, 343(9), 611–617.
- Shabaan, M., Arshid, K., Yaqub, M., Jinchao, F., Zia, M. S., Bojja, G. R., Iftikhar, M., Ghani, U., Ambati, L. S., & Munir, R. (2020). Survey: smartphone-based assessment of cardiovascular diseases using ecg and ppg analysis. *BMC medical informatics and decision making*, 20, 1–16.
- Sun, W., He, J., Tan, X., Wang, Y., Chen, F., Xu, D., & Xie, A. (2021). Os-lalm-ogm algorithm-based computed tomography image for characteristics and comorbidities of patients before transcatheter aortic valve implantation. *Journal of Healthcare Engineering*, 2021, 1–12.
- van Assen, M., Martin, S. S., Varga-Szemes, A., Rapaka, S., Cimen, S., Sharma, P., Sahbaee, P., De Cecco, C. N., Vliegenthart, R., Leonard, T. J., vd. (2021). Automatic coronary calcium scoring in chest ct using a deep neural network in direct comparison with non-contrast cardiac ct: A validation study. *European journal of radiology*, 134, 109428.
- Wang, C.-Y., Liao, H.-Y. M., Wu, Y.-H., Chen, P.-Y., Hsieh, J.-W., & Yeh, I.-H. (2020). Cspnet: A new backbone that can enhance learning capability of cnn. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops*, (Bildiriler

Kitabr: 390–391).

- Wolterink, J. M., Leiner, T., de Vos, B. D., van Hamersvelt, R. W., Viergever, M. A., & Išgum, I. (2016). Automatic coronary artery calcium scoring in cardiac ct angiography using paired convolutional neural networks. *Medical image analysis*, 34, 123–136.
- Wu, P., Liu, A., Fu, J., Ye, X., & Zhao, Y. (2022). Autonomous surface crack identification of concrete structures based on an improved one-stage object detection algorithm. *Engineering structures*, 272, 114962.
- Yang, D., Lin, Y., Wei, J., Lin, X., Zhao, X., Yao, Y., Tao, T., Liang, B., & Lu, S.-G. (2023). Assisting heart valve diseases diagnosis via transformer-based classification of heart sound signals. *Electronics*, 12(10), 2221.
- Zakkar, M., Bryan, A. J., & Angelini, G. (2016). Aortic stenosis: diagnosis and management. *Bmj*, 355.
- Zambrano-Vizuite, M., Botto-Tobar, M., Huerta-Suárez, C., Paredes-Parada, W., Patiño Pérez, D., Ahanger, T. A., & Gonzalez, N. (2022). Segmentation of medical image using novel dilated ghost deep learning model. *Computational Intelligence and Neuroscience*, 2022(1), 6872045.
- Zhang, J., Wang, Y., Chen, L., Liu, J., Zhang, S., Pan, Z., Wang, Z., Tang, Z., & Guo, Y. (2023). Dual-branch transv-net for 3d echocardiography segmentation. *IEEE Transactions on Industrial Informatics*.

7. EKLER

Ek 1. Makine Öğrenmesine Dayalı Sınıflandırma Yöntemleri İçin Denklemler

A. *k*-en yakın komşuluk (*k*-NN)

K-en yakın komşuluk (*k*-NN) sınıflandırma algoritmalarından biridir. K-NN algoritması, özellik uzayındaki en yakın eğitim örneklerine dayanmaktadır. Bilinmeyen bir örneğin eğitim setindeki *k* en yakın komşularının çoğunluğu belirli bir sınıfa aitse, bu bilinmeyen örnek bu sınıfa dahil edilmektedir. *k* parametresi, *k*-NN algoritmasının performansını etkilemektedir. *k*-NN algoritmasında en yakın komşuyu belirlemek amacıyla denklem (E.1 - E.3)'de verilen Öklid, Manhattan ve Minkowski gibi uzaklık hesaplama ölçütleri kullanılmaktadır.

$$d_{öklid}(x,y) = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (E.1)$$

$$d_{manhattan}(x,y) = \sum_{i=1}^k |x_i - y_i| \quad (E.2)$$

$$d_{minkowski}(x,y) = \left(\sum_{i=1}^k (x_i - y_i)^q \right)^{1/q}, \quad q = 1, 2, \dots \quad (E.3)$$

B. Rastgele Ormanlar (RF)

Rastgele Ormanlar (RF) algoritması, veri örneklerini birçok sınıflandırma ağacına göre sınıflandırmaktadır. Her bir ağaç ayrı sınıflandırma sonucu vermektedir. RF ilgili karar ağacı çıkışlarını denklem E.4'de verilen şekilde birleştirmektedir.

$$h(x, \theta_k), k = 1, \dots, K \quad (E.4)$$

Burada θ_k bağımsız ve aynı şekilde dağıtılmış rastgele özellik örneklerini, *K* ise ağaç sayısını göstermektedir. Ağaç sayısı *K* kullanıcı tarafından tanımlanmaktadır. Her bir ağaç *x*'in çoğunluğa ulaştığı örneklerin sınıfı hakkında oy birliği sağlamaktadır.

RF algoritması büyük miktarda veri ile başa çıkmak için etkili ve hızlı bir yöntemdir. RF varyansı azaltmanın yanısıra karşılaştırılabilir sınıflandırma doğruluğu elde etme avantajlarını sunmaktadır.

ÖZGEÇMİŞ

Mervenur ÇAKIR, ilkokul öğrenimini Trabzon'da, ortaokul ve lise öğrenimini Gümüşhane'de tamamladı. 2017 yılında Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünde lisans programına başladı. 2021 yılında Bilgisayar Mühendisliği Bölümünden Bilgisayar Mühendisi unvanı ile mezun oldu. 2021-2022 güz döneminde Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı ve 04.03.2022 tarihinde Yazılım Mühendisliği Bölümü'nde Araştırma Görevlisi olarak göreve başladı. Karadeniz Teknik Üniversitesi Yazılım Mühendisliği Bölümünde halen çalışmaya devam etmektedir. 1'i SCI/expanded indeksli dergilerde, 1'i ulusal konferanslarda, olmak üzere toplam 2 yayını mevcuttur. Yabancı dil olarak İngilizce bilmektedir. Yayınları aşağıda verilmiştir.

Hakemli konferans/sempozyumların bildiri kitaplarında yer alan yayınlar

1. Çakır, M., Ekinci, M., Baykal Kablan, E. ve Şahin, M. (2023, May). Deep learning-based automatic detection of aortic valve on echocardiographic images. In 2023 31st Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.

Uluslararası hakemli dergilerde yayınlanan makaleler (SCI/SCI-E)

1. Çakır, M., Ekinci, M., Baykal Kablan, E. ve Şahin, M. (2024, April). AVD-YOLOv5: a new lightweight network architecture for high-speed aortic valve detection from a new and large echocardiography dataset. Medical & Biological Engineering & Computing (Vol. 62, Issue 5), 1-18.