



TÜRKİYE CUMHURİYETİ
ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ
TIP FAKÜLTESİ



**KARDİYAK BT GÖRÜNTÜLERİNDE SIK İZLENEN KORONER
ARTER VARYASYONLARININ YOLO-v10 MİMARİSİ KULLANARAK
YAPAY ZEKA TEMELLİ TESPİTİ VE SIKLIĞININ ARAŞTIRILMASI**

Dr. Önder DURMAZ

RADYOLOJİ ANABİLİM DALI
TIPTA UZMANLIK TEZİ

DANIŞMAN
Doç. Dr. Sonay AYDIN

ERZİNCAN

2025

TÜRKİYE CUMHURİYETİ
ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ
TIP FAKÜLTESİ

**KARDİYAK BT GÖRÜNTÜLERİNDE SIK İZLENEN KORONER
ARTER VARYASYONLARININ YOLO-v10 MİMARİSİ KULLANARAK
YAPAY ZEKA TEMELLİ TESPİTİ VE SIKLIĞININ ARAŞTIRILMASI**

Dr. Önder DURMAZ

RADYOLOJİ ANABİLİM DALI
TIPTA UZMANLIK TEZİ

DANIŞMAN
Doç. Dr. Sonay AYDIN

ERZİNCAN
2025

Erzincan Binali Yıldırım Üniversitesi

Tıp Fakóltesi Dekanlığı'na,

Tıpta Uzmanlık Tezi olarak hazırlayıp sunduğum “Kardiyak Bt Görüntülerinde Sık İzlenen Koroner Arter Varyasyonlarının Yolov-10 Mimarisi Kullanarak Yapay Zeka Temelli Tespiti Ve Sıklığının Araştırılması” başlıklı tez; bilimsel ahlak ve değere uygun olarak tarafımdan yazılmıştır. Tezimin fikir/hipotezi tümüyle tez danışmanım ve bana aittir. Tezde yer alan araştırma tarafımda yapılmış olup, tüm cümleler, yorumlar bana aittir.

Bu tez çalışmasıyla ilgili tüm süreçler Erzincan Binali Yıldırım Üniversitesi Klinik Araştırmalar Etik Kurulu tarafında 06.03.2025 tarihinde, 2025-05/04 numaralı kararla onaylanmıştır.

Yukarıda belirtilen hususların doğruluğunu beyan ederim.

Araştırma görevlisini Adı Soyadı: Önder DURMAZ

Tarih: 27.08.2025

İmza:

ÖN SÖZ

Tez danışmanım Doç. Dr. Sonay AYDIN'a, her anlamda rehberlikleri, sabırları ve destekleri için minnettarım. Bana sadece akademik bilgi değil, aynı zamanda hayatın sırlarını ve mesleki tecrübelerini de öğretiler. Prof. Dr. Mecit KANTARCI, Prof. Dr. Volkan KIZILGÖZ ve Doç.

Dr. Erdem FATİHOĞLU'na sonsuz teşekkürlerimi sunarım. Vermiş oldukları emeklerin değerini asla unutmayacağım.

Öğr. Üyesi Dr. Türkhun ÇETİN , Öğr. Üyesi Kemal Buğra MEMİŞ ,Öğr. Üyesi M. Fırat ÖZTEPE ve Öğr. Üyesi Dr.Hüseyin AYDEMİR'e de yürekten teşekkür ederim. Onların ilham verici öğretileri ve destekleriyle mesleğimde ilerleme fırsatı buldum. Tüm zorluklara birlikte göğüs gerdik ve bu başarıya hep birlikte ulaştık.

Asistan arkadaşlarımla geçirdiğim her an benim için çok kıymetliydi. Destekleri ve teşvikleri sayesinde hiçbir zorluk karşısında yalnız kalmadım.

En büyük destek ve sevgi kaynağım olan eşim ve anne/babama minnettarım. Onlar benim için gerçek birer kahramanlar, her daim yanımda olup beni motive ettiler. Hayatımın her anında onların desteğiyle ayakta durdum. Sonsuz şükranlarımı sunarım.

İÇİNDEKİLER

Etik Beyan		ii
Önsöz	iii	
İçindekiler		
iv		
Simgeler	ve	Kısaltmalar
v		
Resim	ve	Şekiller
vi		Dizini
Tablolar		Dizini
vii		
1. TÜRKÇE		ÖZET
1		
2.		ABSTRACT
2		
3. GİRİŞ	VE	AMAÇ
4		
4. GENEL		BİLGİLER
11		
4.1. Koroner	Arter	Embriyolojisi
11		
4.2. Koroner		Anatomi
13		
4.3. Koroner Arter Varyasyon Ve Anomalileri		18
4.4. Koroner Arter Görüntüleme		21
4.5. YOLO Mimarisi: Tarihçesi, Gelişimi Ve Tıbbi Görüntülemedeki Rolü		26
4.6. YOLO Algoritmasının Kullanım Alanları		28
4.7. YOLO'nun Tercih Edilme Nedenleri		30
4.8. Kalp Damarlarındaki Varyasyonlar Ve Anomaliler:Klinik Önemi Ve Yapay Zekâ Destekli Tespiti		31
4.9. Literatürde Kalp Varyasyon Ve Anomalisi Tespiti İçin Kullanılan Derin Öğrenme Yöntemleri		32
5. GEREÇ ve YÖNTEM		34
5.1. Çalışmaya Alınan Koroner Arter Varyasyonları Ve Kısaltma İsimlendirilmeleri		
36		
5.2. Dataset		
39		
5.3. YOLOv10		
39		
5.4. Değerlendirme Ölçütleri (Evaluation Metrics)		41
6. BULGULAR	44	
7. TARTIŞMA	49	
8. SONUÇ ve ÖNERİLER	55	
9. OLGU ÖRNEKLERİ	56	
10. KAYNAKLAR	62	

11. EKLER

11.1. Ek 1: Özgeçmiş

11.2. Ek 2: Etik Kurul Karar Formu

11.3. Ek 3: Benzerlik Raporu 72

SİMGELER VE KISALTMALAR

ALCAPA: Pulmoner Arterden Köken Alan Anormal Sol Koroner Arter

ARCAPA: Pulmoner Arterden Köken Alan Anormal Sağ Koroner Arter

AF: Atriyal Fibrilasyon

BT: Bilgisayarlı Tomografi

CNN: Derin Öğrenme ve Evrişimsel Sinir Ağları

EKG: Elektrokardiyografi

EKO: Ekokardiyografi

HU: Hounsfield ünitesi

InfoGAN: Bilgi Maksimizasyonu Yapan Üretici Çekişmeli Ağ

KAVF: Koroner arteriovenöz fistüller

KBTA: Koroner Bilgisayarlı Tomografi Anjio

LAD: Sol ön İnen arter

LMCA: Sol Ana Koroner Arter

LCx: Sol Sirkumflkeks Arter

MPR: Çok Düzlemli Görüntü Rekonstrüksiyonu

MRA: Manyetik Rezonans Anjiografi

MSv: Milisievert

MRG: Manyetik Rezonans Görüntüleme

RCA: Sağ Koroner Arter

U-net : Tıbbi Görüntü Segmentasyonu

VEGF: Vasküler Endotelyal Büyüme Faktörü.

VRT: Hacimsel Görselleştirme Tekniği

YOLO: You Only Look Once

ŞEKİLLER DİZİNİ

Şekil 1. Epiblasttan hücrelerin ayrılışını, endoderm ve mezoderm katmanlarını oluşturmak için ilkel oluk boyunca göç ettiğini gösteren şematik çizim.....	12
Şekil 2. Koroner arterlerin embriyolojik gelişimi.....	13
Şekil 3a. Koroner arterlerin ve önemli dallarının KBTA tetkiklerindeki ham görüntülerden VRT ile üç boyutlu hacim oluşturma sonrası meydana gelen görüntüsü.....	15
Şekil 3b. Koroner arterlerin ve önemli dallarının KBTA tetkiklerindeki ham görüntülerden VRT ile üç boyutlu hacim oluşturma sonrası meydana gelen görüntüsü.....	16
Şekil 3c. Normal koroner arter ve ostiumlara sahip sağlıklı bir bireyin KBTA tetkiklerindeki ham görüntülerden VRT (Hacimsel Görselleştirme Tekniği) yöntemi ile elde edilen çıkartılmış koroner anjiyo görüntüsü.....	17
Şekil 4. Çalışmanın Akış Şeması.....	38
Şekil 5. NMS'siz (Non-Maximum Suppression) eğitim için tutarlı çift atamalar.....	40
Şekil 6. Precision-Confidence Curve Analizi.....	46

Şekil 7. Görsellerde NORMAL, MYB, SLMCA, LHTO, LPDA, RCX, ELMCA, NLMCA, RBCX, DLAD, LRCA, NRCA ve DLCX sınıflarına ait tahminler yer almaktadır. NORMAL sınıfı en sık tespit edilen sınıf olup, neredeyse tüm görsellerde modelin yüksek güven skorlarıyla bu sınıfı tespit ettiği görülmektedir.....**48**

TABLÖLAR DİZİNİ

Tablo 1. Hasta Dışlama Kriter Diyagramı.....	35
Tablo 2. Yolov10 Modelinin Farklı Varyantlarının Performans Sonuçları.....	44

1. TÜRKÇE ÖZET

Amaç

Son yıllarda görüntüleme teknolojilerindeki ilerlemeler, koroner arterlerin anatomik yapısının daha ayrıntılı incelenmesine olanak tanımıştır. Koroner Bilgisayarlı Tomografi Anjiyo (KBTA), non-invaziv bir yöntem olarak koroner arter anatomisinin ve varyasyonlarının değerlendirilmesinde sıkça tercih edilmektedir. Bu araştırmanın temel amacı, KBTA görüntülerinde sık görülen koroner arter varyasyonlarını tespit edebilen, derin öğrenme tabanlı bir sistem geliştirmektir. Önerilen sistem, YOLOv10((You Only Look Once-v10) mimarisinin sunduğu hız ve doğruluk dengesinden yararlanarak klinik ortamlarda uygulanabilir, güvenilir ve etkin bir çözüm sunmayı hedeflemektedir.

Gereç ve Yöntem

Bu çalışmada, koroner arter varyasyonlarının tespiti için derin öğrenme tabanlı YOLOv10 algoritması kullanılmıştır. Araştırmada, üçüncü basamak bir hastaneye kardiyak problemlerle başvuran 100 hastadan dışlama kriterleri sonrası seçilen 20 hastaya ait çok kesitli Kardiyak BT görüntülerinden oluşan 2.837 kesitlik bir veri seti hazırlanmıştır. Görüntüler, 2.263'ü eğitim, 287'si doğrulama ve 287'si test olmak üzere üç alt gruba ayrılmıştır. Veri seti, modelin farklı senaryolarda doğruluğunu ve etkinliğini değerlendirmek amacıyla dengeli bir şekilde dağıtılmıştır.

Bulgular

YOLOv10 modeli, koroner arter varyasyonları ve normal sınıf için yüksek doğrulukta tahminler yapmıştır. Modelin sınıflandırma kapasitesi güvenilir bulunmuş, tahminlerin büyük çoğunluğu doğru sınıflandırılmıştır. Ayrıca tespit edilen sınırlayıcı kutular, koroner arter varyasyonlarının belirlenmesinde güçlü bir temel sunmuş ve YOLOv10'un tıbbi görüntü analizlerinde yüksek potansiyele sahip olduğunu göstermiştir. YOLOv10 koroner arter varyasyon belirlemede ,uygulamanın gereksinimlerine göre precision, recall ve mAP dengesi önemlidir. Yüksek doğruluk gereken durumlarda YOLOv10-X, daha dengeli ve genellenebilir sonuçlar için ise YOLOv10-L öne çıkmaktadır.

Sonuç

Modelin tıbbi tanı süreçlerine entegrasyonu, koroner arter varyasyonlarının tespiti ve normal anatomik yapının değerlendirilmesinde klinik uygulamalara önemli katkılar sunabilir. Varyasyonların erken ve doğru tanınması, özellikle kateter anjiyografi sırasında karar verme sürecini hızlandırarak olası komplikasyonların önlenmesine yardımcı olabilir. Gelecekteki çalışmaların, daha geniş veri setleri ve düşük temsil gücüne sahip sınıfların optimizasyonuna odaklanmasıyla modelin etkisinin artırılması öngörülmektedir.

Anahtar Kelimeler: Koroner Arter Varyasyonu , BT, YOLOv10, Yapay Zeka , Sınıflandırma

DETECTION AND FREQUENCY INVESTIGATION OF COMMON CORONARY ARTERY VARIATIONS IN CARDIAC CT IMAGES USING THE YOLOV-10 ARCHITECTURE BASED ON ARTIFICIAL INTELLIGENCE

2. ABSTRACT

Aim

Advances in imaging technology in recent years have enabled more detailed examination of the anatomical structure of coronary arteries. Coronary Angiography Computed Tomography (CACT) is frequently preferred as a non-invasive method for evaluating coronary artery anatomy and variations. The primary objective of this study is to develop a deep learning-based system capable of detecting common coronary artery variations in CTA images. The proposed system aims to provide a clinically applicable, reliable, and effective solution by leveraging the balance of speed and accuracy offered by the YOLOv10 architecture.

Materials and Methods

In this study, the deep learning-based YOLOv10 algorithm was used to detect coronary artery variations. In the study, a dataset consisting of 2,837 multi-slice cardiac CT images from 20 patients selected from 100 patients who presented to a tertiary hospital with cardiac problems after exclusion criteria were applied. The images were divided into three subgroups: 2,263 for training, 287 for validation, and 287 for testing. The dataset was distributed in a balanced manner to evaluate the model's accuracy and effectiveness in different scenarios.

Results

The YOLOv10 model has made highly accurate predictions for coronary artery variations and the normal class. The model's classification capacity has been found to be reliable, with the vast majority of predictions classified correctly. In addition, the detected bounding boxes have provided a strong foundation for identifying coronary artery variations and demonstrated YOLOv10's high potential in medical image analysis. In coronary artery variation detection, the balance between precision, recall, and mAP is important depending on the application's requirements. In cases requiring high accuracy, YOLOv10-X stands out, while YOLOv10-L is preferred for more balanced and generalizable results.

Conclusions

The integration of the model into medical diagnostic processes can make significant contributions to clinical applications in the detection of coronary artery variations and the evaluation of normal anatomical structure. Early and accurate recognition of variations can help prevent potential complications by speeding up the decision-making process, especially during catheter angiography. Future studies are expected to enhance the model's effectiveness by focusing on optimizing classes with lower representativeness using broader data sets.

Key Words: Coronary Artery Variation, CT, YOLOv10, Artificial Intelligence, Classification



2. GİRİŞ VE AMAÇ

Kardiyovasküler hastalıklar ; kalbin kendisinin, ana vasküler yapıların veya koroner arterlerin etkilendiği hastalık grubudur. Kardiyovasküler hastalıklar dünya genelinde on iki milyondan fazla ölüme sebebiyet vermiş olup yetişkinlerde oldukça yaygın görülen ölüm nedenidir. Kalp hastalıkları çevresel ve kalıtsal olarak farklılıklar gösterdiğinden dolayı tanısı doğru ve kesin bir şekilde konulmalıdır. Bu hastalıklar, erken teşhis ve müdahale gerektiren karmaşık yapısal ve işlevsel anomalileri içermektedir. Bu bağlamda kardiyak varyasyon ve anomalilerin önemli bir kısmı koroner arterlerde meydana geldiğini bilmekteyiz. Özellikle koroner arter varyasyon ve anomalileri, hastaların yaşam kalitesini ciddi şekilde etkileyen bir hastalık grubu ve bu durum tanı sürecinde detaylı görüntüleme yöntemleri gerektirdiğinden kritik önem arz etmektedir. Bilindiği üzere koroner arter varyasyonları bazen anomalileri taklit ederek hastaların tanı sürecinde zorluklar çıkarmaktadır(1, 2).

Kardiyak varyasyonlar normal anatomiden farklı olup çoğunluğu anomalilerden daha masum klinik sonuçlar doğurur. Bu gibi durumların erken ve etkin tespiti , anomali görünümü çizen ama aslında varyatif olan (özellikle koroner arterlerde) hastalıkların ortaya konulması hasta için kritik bir önem taşımaktadır. Hastalardaki bu durumun ortadan kaldırılması durumunda önleyici tedbirlerin alınması mümkün olabilir (1, 3, 4).

Dünyada gün geçtikçe koroner arter hastalık insidansın artması nedeniyle erken tanı ve teşhisinde uygulanan koroner arter katater anjiyografik tekniklere alternatif noninvaziv yöntemler gündeme gelmiştir. Bu bağlamda, Bilgisayarlı Tomografi (BT) gibi yüksek çözünürlüklü görüntüleme teknikleri, koroner arter varyasyonların teşhisinde önemli bir rol oynamaktadır. Koroner artere yönelik BT anjiyografik görüntülemeler kateter anjiyografi tekniklere göre daha konforlu (noninvaziv) oluşu, daha kısa sürede görüntülerin elde edilmesi ,3 boyutlu multplanar (MPR) görüntüler sayesinde distal kesim–zor seçilen varyasyon/anomalilerin tespitinde oldukça avantaj sağladığını bilmekteyiz. Bu avantajlar sayesinde koroner arter anomali ve varyasyonların tespiti daha da kolaylaşmaktadır. Koroner arter hastalıklarının doğru tanısı , diğer önemli ayırıcı tanı ekartasyonların hızlı tespiti ve görüntülemelerin subjektif yorumlardan arındırılması için BT görüntülerinin manuel analizine alternatif bir yöntemi gündeme getirmiştir(1,2,4).

Yapay zekâ uygulamalarının tıbbi görüntüleme alanında yaygınlaşması, tanısal süreçleri Önemli ölçüde değiştirmiştir. Son yıllarda, Derin Öğrenme ve Evrimsel Sinir Ağları (CNN) gibi yaklaşımlar, görüntü analizi görevlerinde üstün performans göstererek, tıbbi anomalilerin ve varyasyonların tespiti, segmentasyonu ve sınıflandırılmasında yeni ufuklar açmıştır.

Özellikle, nesne tespiti alanında ıgır aan YOLO (You Only Look Once) mimarisi, gerek zamanlı uygulamalarda hem hız hem de doėruluk aısından gl bir yntem olarak dikkat ekmektedir (5).

YOLO'nun tıp alanında uygulanması, anatomik yapıların, lezyonların, tmrlerin ve diėer klinik olarak nemli tıbbi nesnelerin tespit ve lokalizasyon yeteneėi sayesinde ilgi grmektedir (2,6,7,8). Bu teknoloji, tıbbi grntlerdeki organ anormalliklerin ya da varyasyonların tespitini ve lokalizasyonu saėlamak, meme gibi kanser sıklıėı ok olan dokulardaki lezyonların tespitinde , zellike posttravmatik –anevrizmal rptre sekonder geliėen kranial kanamaların hızlı tanısında, bazı organlarda prekanserz lezyonların taramalarında (Pulmoner nodllerin varlıėı vb.) ve kardiyovaskler hastalıklar gibi dnyada en sık lme yol aan hastalıkların erken tanı ve tedavisini saėlamada hatta gereksiz tedaviyi nlemede yardımcı olabilir (6).

YOLO'nun tıbbi uygulamalarda benimsenmesi, tıbbi tanıların doėruluėunu ve verimliliėini artırma potansiyeline sahip olup, hasta sonuları zerinde nemli bir etki oluėturabilir. YOLO'nun gerek zamanlı performansı, zellikle zaman aısından hassas tıbbi prosedrler ve klinik karar verme sreleri iin son derece nemli hale gelmektedir (7). İlgi alanındaki nesneleri doėru ve verimli bir ėekilde tanımlayarak, YOLO potansiyel olarak hastalıkların erken teėhisinde, tedavi planlamasında ve hastalık ilerleyiėinin izlenmesinde yardımcı olabilir. Ancak, YOLO'nun tıbbi grntlemede kullanımı arttıka, performansının, gl ynlerinin, sınırlamalarının ve uygulandıėı spesifik tıbbi alanların deėerlendirilmesi byk nem taėıyacaėına inanılmaktadır (8).

Yapılan zgn bir bilimsel alıėmada ; YOLO tabanlı bir yapay zeka algoritmasında magnifiye Mammogramlardaki kalsifikasyonları deėerlendirilmiėtir. Bu alıėmada nceden benign ve malign kalsifikasyon olarak belirlenen Mammogram grntlerini bir dizi iėlemden geirirerek deėerlendirip yksek doėruluk oranıyla kalsifikasyon niteliklerini (benign-malign) belirlemeyi hedeflemiėtir. Bylece alıėmacılar bu makalede YOLO'nun rutinde sık kullanılan Mammografik kalsifikasyonları deėerlendirme , benign-malign ayırımında hızlı tanıya ulaėtırma ve yapılacak gereksiz biopsileri nemli lde azaltma gibi sonuları ileriye srdler (9).

Yine benzer bir alıėmada derin ėrenme (YOLO) modelini kullanarak Mammografik grntlerde sık izlenen meme lezyon ve kalsifikasyonları gibi patolojik opasitelerin tespiti ve sınıflandırılmasını amalayan bir makale yayınlandı. Araėtırmacılar bu alıėmada kitle ve

kalsifikasyon odakları yüksek doğrulukla tanınır ve başarıyla sınıflandırıldığını ileri sürdüler (10).

S. Abdulrahman ve ark. yayınladığı bir çalışmada , kontrastlı beyin MR görüntülerinde tespit edilen kraniyal kitlelerin tanınması ve sınıflandırılması için Resnet(50) ve YOLO-v8 isimli yapay zeka algoritmaları kullandılar. Bu çalışmada modellerin (Resnet-50 ve YOLO-v8) gerçek zamanlı teşhis senaryolarının uygunluğu için sadece sınıflandırma performans analizi yapmak değil aynı doğrultuda hız performanslarını da karşılaştırmaktı. Sonuç olarak bu iki yapay zeka modeli beyin tümörlerinin tanınmasında ve sınıflandırılmasında oldukça etkili olduğu bildirdiler (11).

2020 yılında yayınlanan bir çalışmada BT görüntülerini veri seti olarak kullanarak elde edilen görüntülerde akciğer nodül tespit etme verimliliğini artıran ve yanlış pozitif olasılıklarını azaltan bilgisayar destekli derin öğrenme yöntemi (YOLO-v3) gündeme atılmıştır. Belirtilen yöntemle akciğer nodüllerin lokalizasyonu ve çapını yüksek doğruluk oranıyla tespit ettiklerini ileri sürdüler. Araştırmacılar akciğer nodüllerin tanı sürecinin hızlı olması ve ucuz iş gücü maliyete sahip olması nedeniyle klinik uygulamada faydalı olacağını ön görmüşlerdir (12).

Yapay zeka algoritmaları kardiyovasküler görüntüleme alanında birçok farklı aşamada katkı sağlayabilir. Hastaların görüntülemeye yönlendirilmesinden başlayarak, hangi görüntüleme yönteminin kimde kullanılacağı konusunda daha isabetli kararlar alınmasına yardımcı olabilir. Görüntülerdeki örüntüleri ve patolojik işaretleri öğrenerek tanı sürecini kolaylaştırabilir. Ancak tüm bu uygulamaların sağlık hizmetlerinde gerçek karşılık bulabilmesi için çözülmesi gereken birçok teknik ve yapısal sorun bulunmaktadır (13-17).

Kardiyovasküler görüntüleme, kendi içinde bazı özellikleriyle hem avantaj hem de zorluklar barındırır. Kalbin yapısal ve işlevsel özelliklerini bir arada değerlendirmeyi sağlar. Birçok farklı görüntüleme yöntemi (BT, MRG, EKO ,EKG vb.) bu alanda kullanılır. Gün geçtikçe kardiyak hastalarının teknolojik gelişmelere daha açık olduğu aşikardır. Bu durum verinin çeşitli, hacimli ve karmaşık olmasına yol açar. Aynı zamanda kalbin farklı düzeylerde ve çok sayıda parametre üzerinden analiz edilmesi gerekir. Buna ek olarak kardiyak görüntüleme, tedavi öncesi karar alma, işlem sırasındaki rehberlik ve işlem sonrası takip gibi klinik süreçleri doğrudan etkileyen bir rol üstlenir(18-23).

Elektrokardiyografi (EKG), kalp hastalıklarının değerlendirilmesinde uzun süredir temel tanı araçlarından biridir. Son yıllarda bu yöntemin yapay zekâ ile birleştirilmesiyle, EKG'nin içerdiği verilerin daha derin analizine olanak tanıyan sistemler geliştirilmektedir. Bu

sistemler, özellikle semptom göstermeyen bireylerde saptanamayan kardiyak sorunların erken tanı şansını artırabilir. Örneğin, aort darlığı gibi belirli kapak hastalıklarının tanınması amacıyla geliştirilen modeller, EKG sinyalleri üzerinden öğrenim yaparak bu hastalıkların varlığını tahmin edebilmektedir. Klasik görüntüleme yöntemlerine kıyasla daha erişilebilir ve maliyet etkin olan bu algoritmalar, erken tarama açısından dikkat çekici sonuçlar vermektedir. Çeşitli araştırmalarda, bu sistemlerin yüksek doğruluk değerleri ile hastalığı dışlama konusunda güçlü bir potansiyele sahip olduğu ortaya konmuştur (24-28).

Benzer şekilde, yapay zekâ modelleri ritim bozukluklarının önceden tahmin edilmesi için de kullanılmaktadır. Standart bir sinüs ritmindeki EKG kayıtlarında, gizli kalmış atriyal fibrilasyon (AF) riskini tanımlayabilen modeller, çok sayıda kayıtlı eğitilmiş derin sinir ağları aracılığıyla uygulanmaktadır. Bu sistemlerin, ilerleyen dönemlerde AF gelişme olasılığı yüksek olan bireyleri erkenden belirleyebildiği ve bunun sonucunda daha uygun bir takip ve önleyici tedavi sürecinin mümkün olduğu gözlemlenmiştir (29, 30).

Lima ve ark. çeşitli kardiyovasküler hastalıklarda kalp hızı görüntülerini sınıflandırmıştır. Anormal sınıflara ait yapay görüntüler üretmek için InfoGAN mimarisi kullanıldıktan sonra, sınıflandırma için iki boyutlu bir Permütasyon sinir ağı önerilmiştir (31).

Kavitha ve ark. tarafından yapılan çalışmada, kalp hastalığını tahmin etmek için bir karar ağacı ve rastgele orman kombinasyonuna dayalı yeni bir makine öğrenimi yaklaşımı önerilmiştir. Bu çalışmada, yalnızca karar ağacı ve rastgele orman yöntemi, kalp hastalarının tahmin verileri üzerinde uygulanmıştır (32).

Bharti ve ark., kalp hastalığı veri seti üzerinde farklı makine öğrenimi algoritmalarını ve derin öğrenme yöntemlerini uygulayarak sonuçları ve analizlerini karşılaştırmıştır (33).

Koroner BT anjiyografisi (KBTA), koroner arter hastalıklarının noninvaziv olarak değerlendirilmesinde yaygın olarak başvurulanan bir görüntüleme yöntemidir. Özellikle koroner arter darlıklarının tespiti açısından ilk basamak tercih olarak kabul edilmesine rağmen, işlem süresinin uzunluğu, maliyetin yüksekliği ve yarı otomatik manuel analiz ihtiyacı gibi bazı sınırlılıklar taşır. Bu süreci daha verimli ve güvenilir hale getirmek amacıyla, çeşitli yapay zekâ algoritmalarının KBTA verileri üzerinde uygulanması araştırmalarda giderek daha fazla yer bulmaktadır (34).

Bazı çalışmalarda, KBTA'nın klinik performansını artırmak üzere geliştirilen derin öğrenme modellerinin, uzman okuyucularla uyumlu sonuçlar verdiği gösterilmiştir. Örneğin, stenoz

derecesi, plak oluşumu ve damar morfolojisinin otomatik olarak değerlendirilebildiği sistemler, zamandan tasarruf sağlarken insan kaynaklı meydana gelen yorumlama değişkenliğini de azaltabilmektedir. Plak yükünü ve darlığın derecesini ölçmek amacıyla eğitilen modellerin, aynı zamanda miyokard enfarktüsü gibi olayların olasılığını öngörmede de tanısal değer taşıyabileceği ortaya konmuştur (35).

Koroner arter kalsiyumunun kardiyovasküler olaylarla olan ilişkisi literatürde uzun süredir bilinmektedir. Buna rağmen, bu bulgu genellikle rapor dışı kalmakta ya da değerlendirilmesi zaman, deneyim ve ekipman gerektirdiğinden ihmal edilmektedir. Son dönemde geliştirilen derin öğrenme algoritmaları, Toraks BT görüntülerinden koroner kalsiyum skorunu otomatik olarak hesaplayarak bu açığı kapatma potansiyeline sahip olduğunu biliyoruz. Geniş hasta gruplarında yapılan uygulamalarda, bu skorların kardiyovasküler olaylarla yüksek düzeyde ilişkili olduğu ve manuel ölçümlerle güçlü korelasyon gösterdiği raporlanmıştır (36).

Yapay zekâ temelli analizlerin bir diğer kullanım alanı da miyokardiyal perfüzyon değerlendirmesidir. Kardiyak MR görüntüleme verileri üzerinden miyokardiyal kan akımı ve perfüzyon rezervini ölçebilen sistemler, uzun süreli hasta takiplerinde anlamlı sonuçlar vermektedir. Bazı kohort çalışmalarında, bu tür ölçümler ile elde edilen düşük perfüzyon değerlerinin, olumsuz kardiyak sonuçların bağımsız belirleyicisi olabileceği saptanmıştır (37).

Benzer şekilde, epikardiyal yağ dokusu hacmi ve yoğunluğunun da kardiyak hastalıkların gelişme riskleri ilişkili olabileceği bildirilmektedir. Bu parametrelerin yapay zekâ tarafından kontrastsız BT görüntüleri üzerinden otomatik olarak hesaplanmasıyla, uzun dönem takipte majör kardiyak olaylarla bağlantılı bir öngörü gücü olarak yorumlanmıştır. Epikardiyal yağ dokusu hacmindeki artışın riskle pozitif yönde ilişkili olması, yağ dokusunun yapısal değişimlerinin klinik sonuçlar üzerinde etkili olabileceğini düşündürmektedir (38).

Yapılan özgün bir çalışmada kardiyak kan akışının sonografik görüntülerinin özelliklerine göre kardiyak sıvı hareketinin görsel analizini meydana getirmek için YOLO öğrenme modeli kullanılmıştır. Burdan yola çıkılarak iki boyutlu süreklilik denkleminde dayalı olarak kardiyak kan akış vektör haritalama analizinin yapılması için bir yapay zeka uygulaması geliştirilmiştir. Çalışmacılar bu çalışmada geliştirdikleri metod ile kan akım radyal hızını , ventrikül duvar lekelerinin azimut hızını vektörel olarak birleştirip kardiyak akış sahasında girdap akım diyagramını ortaya koymak ve flow fonksiyonların daha az hata ile değerlendirilmesinde faydalı olabileceğini savunmuşlardır (6).

Bir çalışmada, koroner arter segmentasyonu ve stenoz lokalizasyonu görevleri için YOLO-v8, YOLO-v9 ve YOLO-v11 modellerinin performansı, ARCADE veri kümesi üzerinde karşılaştırmalı olarak değerlendirilmiştir. Elde edilen sonuçlarda modern YOLO sürümlerinin, koroner anjiyografi görüntülerinde hızlı ve doğru analiz yapma potansiyeline sahip olduğunu ortaya koyduklarını bildirdiler. Yine temas ettikleri bir diğer husus ise ; Bu modellerin, otomatik karar destek sistemlerine entegre edilerek klinik uygulamada kullanılabilir hale gelmesi durumunda , radyologların iş yükünü azaltabileceği ve tanısal doğruluğu artırabileceği yönündedir (39).

Jonghoe Ku ve çalışma arkadaşları, sağ koroner arter (RCA) ile sol koroner arter (LMCA) arasında ayırım yapmayı amaçlayan ve anatomik özellikleri ön plana çıkaran alternatif bir yaklaşım önermiştir . Bu yöntemde, her damar tipi için ayrı derin öğrenme modelleri kullanılmış ve yüksek düzeyde sınıflandırma başarısı elde edilmiştir. Uygulama kapsamında sınıflandırma amacıyla YOLO-v8, segmentasyon için ise farklı kodlayıcılarla yapılandırılmış U-net ve U-net++ modelleri gibi çok sayıda sinir ağı modele dahil edilmiştir. Bu kapsamlı ve çok modelli yaklaşımın, koroner arter sınıflandırma doğruluğu açısından umut verici sonuçlar ürettiğini bildirdiler (40-43).

Tıbbi bilgi sistemi ile entegre tekniklerin kullanılması durumunda bu fayda daha da artacak ve sağlık maliyetlerinin düşmesine neden olacaktır. Entegre sistemler, hastanın geçmişinden faydalı bilgiler toplayarak hastalığın aşamalarını teşhis etmeye ve hastalığın ilerlemesini önlemek için gerekli reaksiyonları reçete etmeye çalışır. Bu entegre sistemler son zamanlarda hayatın hemen her alanında uluslararası kabul görmüş ve tıp alanında da yaygın şekilde kullanılmaktadır. Ham verilerden bilgi çıkarma konusundaki avantajları nedeniyle yapay zekâ yöntemleri, kardiyovasküler hastalıkların teşhisine yönelik entegre bilgi sistemleri oluşturmak için önemli bir rol oynamaktadır. Sağlık hizmetlerini iyileştirmedeki genişliği nedeniyle, kardiyovasküler hastalıkları teşhis ve tahmin etmek için çeşitli teknikler önerilmiştir (2, 44, 45).

Aykırı değerler olarak da bilinen anomalilerin ya da varyasyonların tespiti, çok çeşitli disiplinlerin ayrılmaz bir uygulaması olmuştur. Anomaliler ve varyasyonların bir sistemin veya örüntünün ihlal edildiğini gösterebilir (46,47). Sağlık hizmetleri bağlamında bu, bir hastalık tedavi komplikasyonunun veya hatalı tanıların giderilmesinde etkin rol alabilir. Bazen odak noktasının hastalık verilerini tanımlamak değil de , gelecekte gelişebilecek hastalık risk durumlarını veya hastalıkların meydana gelme sıklığını tahmin etmek üzerine olabilir. Bu

durum sađlık uygulama politikasında önemli bir yer alacağı bazı arařtırmacılar nezdinde gündeme getirildiđini bilmekteyiz. Aslında, sađlık hizmetlerinin iyi bir görüntüleme modalitesinden veya raporlamadan beklediđi, organ anomalilerinin veya varyasyonlarının normal anatomiden ayırabilmesi ve hastalıkların tedavi sürecinde klinisyeni gelişebilecek komplikasyonlar hakkında öngörü sunmasıdır. Hem denetimli hem de denetimsiz anomali /varyasyon tespit modellerinin uygulanmasına ve görselleştirilmesine daha fazla vurgu yapılması, sađlık hizmetleri gibi uygulamalı ortamlarda pratiđi geliřtirecek ve dolayısıyla hasta sonuçlarını iyileřtirecektir (46).

Yaptığımız kapsamlı literatür taramasında koroner arter varyasyonlarını tespitinde, normal anatomiden ayırmada YOLO mimarisini kullanan herhangi bir çalışmaya rastlanılmamıştır. Bu çalışmada, YOLO ailesinin en yeni sürümlerinden biri olan YOLO-v10 mimarisi kullanılarak KBTA görüntülerinde koroner arterlerin önemli varyasyonlarını tespit edilmesi hedeflenmiştir.

Bu nedenle, YOLO'nun koroner arter varyasyonların tespiti gibi tıbbi uygulamalardaki mevcut literatürünü analiz etmek için sistematik bir literatür taraması ve titiz bir yaklaşım sağlayabilir. Mevcut bulguları sistematik bir şekilde toplayarak, deđerlendirerek ve sentezleyerek, YOLO'nun tıbbi uygulamalardaki güçlü yönlerini, sınırlamalarını ve potansiyelini belirlemeyi ikincil bir hedef olarak belirledik.

4. GENEL BİLGİLER


4.1 Koroner Arter Embriyolojisi.

Kalp embriyolojik gelişmesinin erken döneminde içi endotel ve ince miyokardiyal kas tabakasından oluşan bir tüp formasyonundadır. Lümeninde akan kan ile beslendiğinden bu dönemlerde vasküler damar yatağına ihtiyaç duymaz. Zamanla gelişen ve büyüyen kalpteki beslenme daha kompleks bir hal alır. Ventrikülleri beslemek için gelişen vasküler pleksuslar progenitör hücrelerin ve VEGF vb. meditörlerin etkisi ile olgunlaşma sürecine girer. Koroner arterler ilk olarak intrauterin erken haftalarında matüre olmamış bir vasküler pleksus oluşumu ve sonrasında zamanla bazı progenitör proteinler sayesinde gelişerek işlev gören damar yatağına dönüşen bir anjiyogenezis süreciyle meydana gelir (47, 48).


Bu vasküler pleksuslar çoğu görüşe göre sinüs venozus ve endokard'dan köken almaktadır. Embriyolojik süreç ilerledikçe vasküler pleksus aort ile bağlantı kurar ve gelişen pleksuslar miyokarda yayılarak sarmaya devam eder. Bu kompleks vasküler pleksuslar Aort ile anastamoz sağladıktan sonra koroner arter , venöz ve kapiller vasküler sistemleri meydana getirirler. Aort düzeyinde bağlantı noktasında en yüksek debiye sahip pleksuslar dallarından sol ana koroner arter (LMCA) ve Sağ ana koroner arter gelişir (RCA) (49-53).

Koroner pleksus gelişiminde önemli büyüme faktörlerinin Epikardiyum kaynaklı olduğunu bildiren çalışmalar olduğunu bilmekteyiz. Koroner arter gelişmesinde diğer kayda değer etmen ise Sinüs venozus'tur (54, 55) . Ayrıca embriyolojik dönemde koroner arterlerin sağlıklı gelişmesinde ve eksikliğinde ise ciddi anomalilerin /varyasyonların meydana gelmesinde rol alan diğer önemli molekül Notch reseptörleridir. Notch reseptörleri 'Delta ve Jagged' ligandlarına sahiptir. Bu reseptörlerin ya da ligandlarında herhangi bir hatalı kodlama veya eksiklik durumunda epikardiyal gelişim bozulduğundan koroner vasküler pleksusların yanlış anastamozuna veya koroner arterlerin gelişmemesine sebebiyet verir (47, 48, 56-59).

Bazı özgün araştırmalarda belirtildiği gibi bir takım koroner anomalilerin veya varyasyonların meydana gelmesinde özellikle VEGF ve Notch arasındaki sinyal etkileşim kusurları suçlanmaktadır (47, 56, 60).



Şekil 1: Epiblasttan hücrelerin ayrılışını , endoderm ve mezoderm katmanlarını oluşturmak için ilkel oluk boyunca göç ettiğini gösteren şematik çizim.(Kalp ve koroner arterlerin progenitör hücreleri endoderm ve mezoderm kaynaklıdır) (61).



Şekil 2 : Koroner arterlerin embriyolojik gelişimi: Progenitör(öncü) hücreler primer vasküler pleksus oluşturmak üzere göç ederler. Daha sonra pleksuslar daha donanımlı kan akışını sağlamak için Aorta ile anastamoz oluştururlar (62).

4.2 Koroner Anatomi

“Coronarius”(Koroner) , sözcüğü Latince kökenli olup “Çelenge” ya da “Tac” anlamına gelmektedir. Koroner arterler ve dalları kalbin çevresinde dolanıp kalbi beslediklerinde bir tacı andırdığından bu isimle tanımlanmıştır.

Aortik kökten sağ ve sol koroner arterler ilgili sinüs valsalva’lardan köken alırlar.Aort kökü posteriorunda ‘Nonkoroner sinüs’ denilen herhangi bir koroner arterin orjin almadığı anatomik yapı vardır. Düşük olasılıkla da olsa bazen Nonkoroner sinüs’den koroner arterler orjin alabilmektedir (63).


Sinüs valsalvalar genelde aynı düzeyde yerleşim gösterirler. Ancak sağ sinüs sola kıyasla hafif önde yer alır. RCA , LMCA'ya kıyasla inferiordan orjin alır. RCA genelde sağ ventrikülü , LMCA ise sol ventrikül anterior duvarını ve interventriküler septumun anterior kısmını beslemektedir. Geriye kalan sol ventrikül miyokardiyal sahayı ise dominant gösteren koroner arter aracılığıyla sulanmaktadır.

RCA Dallar:


- Konus arteri
- Sinoatriyal Nodal arter
- Akut marjinal dallar
- Posterior interventriküler arter (PDA)
- Posterior sol ventrikül (PLV) dal

LMCA Dalları :

- Sol ön inen arter (LAD)
 - Diagonal dallar
 - Septat perforatörler
- Sirkumfleks arter (LCx)
 - Optüs marjinal dallar
- Ramus intermedius arteri (RI)



Şekil 3a: Koroner arterlerin ve önemli dallarının KBTA tetkiklerindeki ham görüntülerden VRT (Volüm Rendering Teknik) ile üç boyutlu hacim oluşturma sonrası meydana gelen görüntü.



Şekil 3c : Normal koroner arter ve ostiumlara sahip sağlıklı bir bireyin KBTA tetkiklerindeki ham görüntülerden VRT (Volüm Rendering Teknik) yöntemi ile elde edilen çıkartılmış koroner anjio görüntüsü.

4.2.1 Koroner arter baskınlığı:

Sağ dominant dolaşım , posterior desendan arter ve posteriolateral dalların RCA'dan kaynaklandığında kullanılan terminolojidir. İnsanlarda yaklaşık %82-86'sında sağ dominant dolaşım mevcuttur. Sağ dominanside sol ventrikülün inferioseptal ve inferior duvar beslenmesini RCA tarafından sağlanır. Buna karşılık posterior desendan arter ve posteriolateral dallar sol sirkumfleks arterden (LCx) kaynaklanırsa bu duruma ise sol dominant dolaşım olarak tanımlanmaktadır. Genelde olguların %14-21'i sol dominant dolaşıma sahiptir. Yaklaşık olguların %4-6'sında RCA posterior desendan artere , LCx ise posteriolateral dallara orjin olur .Bu duruma ise kodominant dolaşım adını almaktadır (63-65).

4.3 Koroner Arter Varyasyon Ve Anomalileri

4.3.1 Sınıflama :

A. Köken Anomalileri ve varyasyonları

1.Yüksek Çıkış

- *Yüksek çıkışlı RCA , Yüksek Çıkışlı LMCA*

2.Çoklu Ostium

- *Sol koroner sinüsten kaynaklanan LMCA + LAD ve LCx yok*

3.Tek koroner arter

4.Koroner arterin pulmoner arterden köken alması

- *Pulmoner arterden kaynaklanan RCA (ARCAPA sendromu)*
- *Pulmoner arterden kaynaklanan LMCA(ALCAPA sendromu)*

5.Koroner arterin kontralateral veya koroner olmayan sinüsten kökeni

- *Sol koroner sinüsten kaynaklanan RCA*
- *Sağ koroner sinüsten kaynaklanan LCx*
- *Sağ koroner sinüsten kaynaklanan LMCA*
- *Koroner olmayan sinüsten kaynaklanan RCA*

B. Seyir Anomalileri ve varyasyonları

1.Miyokardiyal köprüleşme(en sık)

- *LAD miyokardiyal köprüleşme*
- *LAD ve LCx miyokardiyal köprüleşme*

2.Arter Duplikasyonu

- *LAD dublikasyonu*
- *LCx Dublikasyonu*

C.Sonlanma Anomalileri ve varyasyonları

1.Koroner arter fistülleri

- *Sol atriyum-PDA fistülü*
- *Pulmoner arter-LAD fistülü*

2.Kardiyak dışı sonlanma (63-65).

Farklı klinik prezentasyon ile hastaneye başvuran koroner arter varyasyon ve anomaliler çoğunlukla konjenital olarak meydana gelen malformasyonlardır. Bazıları diğer konjenital kalp hastalıkları ile ilişkili olabilir. Bu tür varyasyonların meydana gelmesinde yukarıda da detaylı olarak açıklandığı gibi özellikle VEGF ve NOTCH moleküllerinde ya da reseptörlerindeki yapısal kusurlardan meydana gelmektedir (47, 48, 56).

Bazen klinik bulgu vermeden rastlantısal olarak başka kardiyak sebeple çekilen birtakım görüntüleme teknikleri ile de koroner arter varyasyonların tespiti yapılabilmektedir. Bu görüntüleme modaliteleri Bilgisayarlı Tomografi Anjiyografi (BTA), Manyetik Rezonans Anjiyografi(MRA) ve Perkütan Koroner Kateter Anjiyografik (PTKA) tetkiklerdir. Koroner arter anomali ve varyasyonların otopsi verilerinde %0.2-0.4 oranlarını bildiren çalışmalar mevcuttur. Günümüzde ise neredeyse rutin hale gelen KBTA çekimleri nedeniyle koroner arter varyasyon görülme sıklığı giderek artmaktadır (66, 67).

Koroner arter varyasyon ve anomaliler ilk olarak 18. yüzyılda kısmi tanımlanmıştır. Sınıflandırma olarak ilk bilimsel çalışma 1969 yılında gündeme gelmiş olup 2000 yılında revizyona gidilmiştir. Halen ortak bir sınıflandırma konusunda belirgin konsensüs sağlanamamıştır. Koroner arter varyasyon ve anomalilerin sınıflandırılması bazı literatürel çalışmalarda ve kitaplarda ‘ köken , kurs ve sonlanma ‘ olarak nitelendirilmiştir (68).

Genel olarak iki koroner ostium vardır. Bununla birlikte, Sol Ana Koroner Arter (LMCA) bulunmadığı bazı farklı hastalarda üç ostium mevcut olabilir. Bu duruma sahip kişilerde, sol inen arter (LAD) ve sol sirkumfleks arter (LCx) farklı ostiumlardan gelir.Bazen RCA sol koroner sinüs ,LCx veya LAD sağ koroner sinüsten kaynaklanabilir (69, 70).

Ramus intermedius’a sahip LMCA bir diğer varyasyon nedenidir.Bu anatomik birlikteliğe LMCA Trifkuasyonu denmektedir.

Ana epikardiyal arterler (LMCA ve RCA) bazen normal anatomideki orjin düzeylerinden farklı olabilir. Yüksek çıkış varyasyonu ve akut çıkış açısı şunlardır: ana koroner arterin sinotubuler kavşaktan daha fazla 1 cm süperiorundan çıkması ve koroner arter ile aort duvarı arasındaki açı $<45^\circ$ 'tir. Koroner kateter anjiyografide bu tür varyasyonlar sorunlara neden olabilir (71, 72).

ALCAPA, LMCA'nın pulmoner arterden orijin almasıyla nitelendirilen bir koroner anomalidir. ALCAPA, düşük basınç altında sol ventrikül miyokardını nispeten desatüre kanla perfüze ederek miyokardiyal iskemiye neden olabilir.

ARCAPA, konjenital kalp hastalıkları arasında çok nadir görülen bir anomali olup, pulmoner arterden çıkan anormal sol koroner arterden dört kat daha az yaygındır. RCA pulmoner trunkus kaynaklıdır. Genellikle erkeklerde daha sık görülür. Bu durum, aortopulmoner septal defekt gibi diğer kardiyak sorunlarla birlikte olabilir ve vakaların yaklaşık %10'unda görülür. Tedavi genellikle cerrahidir ve amaç, koroner çalmayı engelleyip sağ koroner arterin normal anatomik yerine yerleştirilmesidir. Ameliyat sırasında kardiyopulmoner baypas kullanılır (73).

Miyokardiyal köprüleşme, normalde epikardiyal seyir gösteren koroner arterin miyokarda gömülmesidir. LAD en sık miyokardiyal köprüleşme gösteren koroner arterdir. Miyokardiyumun altındaki damarın derinliği, miyokardiyumun köprüleşme segment uzunluğundan daha önemlidir. Hemodinamik olarak, bu miyokardiyal köprüleşmelerin bazılarının önemli olup olmadığı konusunda tartışmalar vardır (74).

Tüm koroner arterler arasında LAD en sabit seyir gösterenidir. LAD duplikasyonu nadir görülen bir anomalidir. Bu nadir varlığın anjiyografik bulguları sporadik olarak tanımlanmış olsa da, BT görünümü hakkında çok az rapor bulunmaktadır. Koroner BT anjiyografisinin yaygın kullanımıyla, BT yorumcularının bu varyant, tipleri ve cerrahi vaskülarizasyonun planlanması için önemli çıkarımlar konusunda bilgi sahibi olması önemlidir. Spindola-Franco ve ark. ilk olarak 1983 yılında Dublike LAD'ı tanımlamış ve sınıflandırmıştır. Dublike LAD, anterior interventriküler olukta yüksekte sonlanan kısa bir LAD ve çoğunlukla LAD'ın uygun erken bir dalı olarak (tip 1-3) başlayan ve nadiren sağ koroner arterden anormal olarak başlayan uzun bir LAD'dan (tip 4) oluşur (75-78).

Sağ koroner arter (RCA) duplikasyonu nadir görülse de, tahmini sıklığı %1'in üzerindedir. Bu varyant, koroner BT anjiyografi, MRG veya invaziv anjiyografi ile saptanabilir. Duplikasyon durumunda RCA, ön ve arka olmak üzere iki dala ayrılır. Ön dal, sağ ventrikülün serbest duvarı boyunca ilerleyerek distal posterior inen arteri oluşturur. Arka dal ise atrioventriküler

oluđu izler ve crux cordis yakınında, interventriküler oluđu proksimaline y nelen ikinci bir posterior inen dalı verir (71, 79-81).

Koroner arterioven z fist ller (KAVF), koroner arterlerle genellikle sađ kalp bořlukları arasında anormal bađlantıların bulunduđu nadir anomalilerdir. En sık RCA (%50) ve LAD (%42) kaynaklıdır; drenaj genellikle sađ ventrik l, sađ atriyum veya pulmoner artere olur. Daha nadiren koroner sin s, vena kavalara veya sol kalp bořluklarına da drene olabilirler (82,83).

Sađ kalbe olan drenaj nedeniyle genellikle soldan sađa řant oluřtururlar ve bu durum "koroner řalma" fenomeniyle miyokardiyal iskemiye tetikleyebilir. KAVF'ler; k kenlerine, drenaj yerlerine, fist l sayısına ve eřlik eden anomalilere g re sınıflandırılır. Bařlıca alt t rleri:

- **Koroner kameral fist ller** (kalp bořluklarına a ılanlar)
- **Arterioven z fist ller**,  rneđin:
 - Koroner arter–pulmoner arter fist l 
 - Koroner arter–koroner sin s veya ven z yapı fist l 
 - Koroner arter–bronřiyal arter fist l 
 - **Karmařık fist ller**:  oklu k ken ve  ıkıř noktalarıyla karakterizedir (82-85).

4.4 Koroner Arter G r nt leme

4.4.1 Bilgisayarlı tomografi tarih esi ve oluřma tekniđi

Yunanca tomos(kesit) ve graphia (g r nt ) kelimelerden k ken alan Tomografi , kolime edilmiř x-ıřını kullanarak incelenen maddenin yada organın kesitsel g r nt lerini meydana  ıkartan bir g r nt leme modalitesidir. X -ıřını farkı dokulardan ge erken deđiřik oranlarda aten e olur. Zayıflamıř olan bu x-ıřınları ilgili dedekt rler tarafından toplanır ve analog –sayısal d n řt r c ler ile numerik verilere  evrilir. G r nt  piksellerden oluřmaktadır. Her bir piksel ise Hounsfield  nitesi(HU) ile temsil edilir. Digital ortamda meydana gelen g r nt  bilgisayar hafızasında saklanır. Son ařamada ise dijital ortamdaki mevcut g r nt  analog bilgiye d n řt r l r ve monit rden izlenmeye hazır edilir.

1826'da Norve li bilim insanı Abel tarafından ilk defa tomografi fikri teorik olarak ortaya konulmuřtur.1917'de ise BT'nin matematiksel temelini Avusturyalı matematik i Johann

Radon tarafından bilim dünyasına aktarılmıştır. İlk defa çok yönlü projeksiyon ile dijital ortam eşliğinde görüntü oluşturma kavramı İngiliz elektrik mühendisi olan Godfrey N.Hounsfield tarafından ortaya sunulmuştur. Ayrıca Hounsfield 1971’de geliştirdiği bir tarayıcı modeli ile (EMI (Electrical and Musical Industries) -Mark 1) beyin tümörü olan bir hastaya tarihte ilk kez tomografik görüntüleme yapmayı başarmıştır. 1973 yılında ilk ticari BT cihazı piyasada yerini almış olup aynı yılda ilk olarak Amerika Birleşik Devletlerinde Mayo Klinik’te ,1976’da ise ülkemizde Hacettepe Üniversitesinde kullanılmıştır (86).

4.4.2 BT jenerasyonları

BT Jenerasyonu , veri toplamak maksadıyla gerekli teknik ve mekanik hareketin dizaynına dayalı sınıflamadır.

Birinci Jenerasyon

Kalem inceliğinde radyasyon ışının bir dedektöre yönlendirilerek translate-rotate(kayma –dönme) prensibine dayalı görüntüleme tekniği kullanılarak geliştirilen BT cihazlarıdır. Sadece beyin görüntülemeye kullanılmış olup tarama zamanı oldukça uzundur.

İkinci Jenerasyon

Birinci jenerasyondaki gibi translate-rotate(kayma –dönme) prensibine dayalı çalışılan ancak çok sayıda dedektör ve fan-beam(dar yelpaze) şeklinde X-ışını demeti kullanılarak geliştirilen BT cihazlarıdır. Bir kesit için gereken süre 20 sn seviyesine indiğinde vücut taramalarda kullanılmıştır.

Üçüncü Jenerasyon

Taranacak bölgeyi tamamen kapsayan geniş yelpaze şeklinde X-ışını demeti ve bu ışın demetine karşılık gelen dedektörler kullanılarak geliştirilen BT cihazlarıdır. Birbirine bağlı olan tüp ve dedektörler hasta çevresinde 360⁰ döner (rotate-rotate) dönerek görüntü kesitleri meydana getirirler. Bir kesitin elde edilme süresi 5sn’nin altına inmektedir. İlk dönemlerde dedektör sayıları 300 iken son teknolojiye 800-1000 dolayına ulaşmaktadır.

Günümüzde en çok kullanılan helikal 6. Jenerasyon ve çok kesitli 7.jenerasyon BT cihazları tüp-dedektör çalışma sistemi 3. Jenerasyon BT’den köken almaktadır.

Dördüncü Jenerasyon

Gantri içerisinde 360° boyunca dizilmiş olan hareketsiz çoklu dedektörlere objeye taraması için yelpaze şeklinde gönderilen X-ışını demeti ile görüntünün meydana getirildiği ve rotate-stationary prensibi ile çalışan BT cihazıdır. İlk versiyonlarında dedektör sayıları 600 iken ileri versiyonlarında bu sayı 4800'e kadar yükselmiştir. Maliyet fazla olması nedeniyle özel amaçlar dışında piyasada satışı nadirdir

Beşinci Jenerasyon

Sine BT veya elektron demeti tomografisi olarak da nitelendirilen son derece hızlı (ultra-fast) bir sistemdir. Bu cihazlarda anot ve dedektör hareket etmez(stationary-stationary) . Elektron demetleri manyetik alan sayesinde anoda yönlendirilir. Kesit elde edilme süresi 17 milisaniye'ye kadar inmiştir. Daha çok kardiyak görüntülemeye fayda olması için piyasaya sürülsede yaygınlaşmamıştır.

Altıncı Jenerasyon

Spiral (Helikal) BT olarak bilinir. Masa sabit bir hızla gantri içerisinde hareket ederken tüp ve dedektör hasta etrafında sürekli dönmesiyle taramaların yapıldığı BT cihazlarıdır. Bu cihazların temel çalışma prensibi kayan halka (slip ring) teknolojisi ile geliştirilmiştir. Oldukça hızlı görüntü elde edilip artefaktların gelişmesi bu cihazlar sayesinde azalmıştır. Günümüz BT cihazları spiral teknolojiyi kullanmaktadır.

Yedinci Jenerasyon

Bu tip cihazlarda hastanın uzun (z) eksen boyuna tek sıra değilde birden çok dedektör yerleştirilerek görüntüler elde edilir. Bu nedenle ismi Çok kesitli /sıralı (multi-slice) BT olarak bilinmektedir. Görüntüler oluşturulurken yelpaze şeklinde değilde koni şeklinde x-ışını demeti kullanılır. Çok kesitli BT'ler aynı sürede çok daha fazla bölgeyi tarar ve daha ince kesitler elde eder. Bu nedenle görüntülerin uzaysal çözünürlüğü artmıştır.(86)

4.4.3 Koroner BT Anjiyografi (KBTA) :

İskemik kalp hastalığını değerlendirmede Koroner BT Anjiyografi (KBTA), hemodinamik olarak anlamlı koroner arter hastalığını dışlamak açısından oldukça güvenilir bir yöntemdir. Birçok çalışmayı kapsayan meta-analizlerde, KBTA'nın negatif prediktif değerinin %100'e yakın olduğu gösterilmiştir. Acil servise başvuran, bilinen koroner arter hastalığı öyküsü olmayan, kalp enzimleri normal ve EKG'si iskemik olmayan düşük-orta riskli hastalarda KBTA, göğüs ağrısının değerlendirilmesinde etkili bir birinci basamak testtir.

Buna karşın, akut koroner sendrom ihtimali yüksek olan hastalarda doğrudan fonksiyonel değerlendirme (stres testleri veya invaziv anjiyografi gibi) tercih edilmelidir. Stres testi ile netlik sağlanamayan olgularda ise negatif KBTA sonucu, ileri tetkik veya hastaneye yatış ihtiyacını ortadan kaldırabilir. KBTA, %45'in üzerinde daralmaya neden olan anlamlı lezyonları yüksek duyarlılıkla saptayabilir; ancak özellikle kalsifiye plakların oluşturduğu blooming artefaktı, darlığın olduğundan daha ileri görünmesine yol açabilir.

KBTA'nın diğer kullanım alanları; büyük cerrahi işlemler öncesinde koroner damarların değerlendirilmesi, doğumsal koroner anomalilerin saptanması, kalp kapakları ve koroner bypass greftlerinin görüntülenmesi gibi çeşitli durumları kapsar.(86)

EKG Gating ve Radyasyon Dozu Ayarlamaları

Kalp hareketlerinden kaynaklanan görüntü bozulmalarını en aza indirmek için EKG gating yöntemi kullanılır. Bu tekniğin seçimi, hastanın maruz kalacağı radyasyon dozu üzerinde doğrudan etkilidir. Alınan dozun hesaplanmasında, tarama boyunca elde edilen doz-uzunluk çarpımı (DLP), 0,017'lik dönüşüm faktörüyle çarpılarak milisievert (mSv) cinsine çevrilir.

Retrospektif EKG gating yönteminde, kalp döngüsü boyunca sürekli tarama yapılır ve görüntüler daha sonra EKG'ye göre senkronize edilir. Bu yöntemin avantajı, kalp fonksiyonları ve kapak hareketlerinin ayrıntılı incelenmesine olanak tanıyan sine görüntüler oluşturabilmesidir; genellikle her döngü için 10-20 görüntü elde edilir. Ancak, bu yöntemin en büyük dezavantajı yüksek radyasyon dozudur.

Prospektif gating yönteminde ise yalnızca kalp döngüsünün belirli bir fazında görüntüleme yapılır ve bu sayede hasta sadece o fazda radyasyona maruz kalır. En büyük avantajı, önemli ölçüde daha düşük radyasyon dozudur. Ancak, kalp döngüsünün tamamı görüntülenmediğinden, sine rekonstrüksiyon yapılamaz (86).

Çözünürlük Özellikleri

Koroner arterlerin ortalama lümen çapı yaklaşık 3 mm olup, modern BT cihazları 0,18 mm'ye kadar uzaysal çözünürlük sunabilir. Optimal değerlendirme için aksiyel kesit kalınlığı 1,0 mm'nin altında olmalıdır. Obez bireylerde, görüntü kalitesini artırmak için daha kalın kesitler tercih edilebilir. Karşılaştırma açısından, kateter anjiyografinin uzaysal çözünürlüğü yaklaşık 0,16 mm'dir (86).

Temporal Çözünürlük ve Cihaz Teknolojisi

Tek dedektörlü BT sistemlerinde görüntü elde etmek için gantrinin yaklaşık 180 dereceden biraz fazla dönmesi gerekir. Örneğin, 330 milisaniyelik dönüş süresi olan bir cihazda temporal çözünürlük yaklaşık 165 ms olarak hesaplanır (yarı dönüş süresi).

Çift kaynaklı (dual-source) BT sistemlerinde ise iki X-ışını tüpü birbirine 90° açıyla yerleştirilmiştir. Bu sistemler sadece 90°'lik dönüşle yeterli veri toplayabildiğinden, temporal çözünürlük daha da artar. Üçüncü nesil çift kaynaklı cihazlarda dönüş süresi 250 ms olduğunda, temporal çözünürlük yaklaşık 66 ms'ye kadar düşer. Bu da özellikle hızlı kalp atımına sahip hastalarda daha net görüntüler elde edilmesini sağlar (86).

4.4.5 Hasta hazırlığı

Koroner BTA çekim öncesi hastalara bazı hazırlıklar yapılır. Hasta işlemden 12 saat öncesi sigara ve kafeinden uzak durması ,en az 4 saat önce katı gıda tüketmemesi , bol su içmesi gerekmektedir. Diğer yandan kontrast made allerjisi sogulanmalı ve mutlaka güncel kanda renal fonksiyon testi yapılması elzemdir.

Yüksek kaliteli görüntüler elde edilmesi , özellikle zorlukla tespit edilebilen koroner arter varyasyonların tanısının konulmasında nefes artefaktları ve kalbin kendi fizyolojik kasılmasının oluşturabileceği artefaktlardan arındırılması gerekmektedir. 64 dedektörlü BT görüntülerde normalde olguların kalp atımı dakidaka 65'i geçmemelidir. Çift çekirdekli BT cihazları ile çekilen hastalarda kalp hızı <90 atım/dk durumunda beta blokör kullanımına gerek kalmamaktadır (11,12). Çoğu merkezde KBTA çekim öncesi gerekli olan hastalara klinik uygulamada en yaygın yaklaşım oral b-bloker (50-100 mg oral metoprolol taramadan 1 saat önce uygulanır) veya intravenöz b-bloker (intravenöz metoprolol 5-20 mg taramadan önce) uygulanmasıdır (87).

Ayrıca koroner arterlerin daha iyi görüntülenmesi distal ve ince varyasyonların tespitinde sublingual Nitrogliserin kullanımı bazı merkezlerce kullanılmaktadır.Nitrogliserin bazı yan etkileri kullanımını sınırlandırmaktadır.Şiddetli baş ağrıları yapmaları ve fosfodiesteraz inhibitörleri ilaçlarla kullanılmamaları önemli istenmeyen etkileridir (En az 48 saat önce Fosfodiesterazlar bırakılmalıdır) (87).

4.4.4 Bazı önemli artefaktlar:

* Basamak artefaktları: Özellikle aritmisi olan hastalarda karşımıza çıkar . Farklı fazlarda alınan görüntülerin birleştirilmesiyle meydana gelir. Çoğunlukla beta blokör ile önlenir. Bu artefaktlar 256-320 kesite sahip BT cihazlarında izlenmezler

* Koroner arter hareket artefaktı: Daha çok sağ koroner arterde karşımıza çıkar. Kardiyak hız ve görüntü ayarlarıyla çoğunlukla ortadan kalkar .

* Solunumsal artefaktlar: Düzgün nefes tutmakla bu tür artefaktan kaynaklanır. Koopere olmayan hastalarda bazı yapay zeka postproses tekniklerle bu artefaktlardan arındırma yapılabilir.

* Çizgi artefaktları : Genelde metalik klipsler bağlı olarak gelişir.

* Tomurcuk artefaktı: Damar cidarındaki kalsifik plakların ve stentlerin koroner arter lümenlerinin yalancı kontrast artışını ve damarları olduğundan daha geniş kalibrede gösterirler (86).

4.5 YOLO Mimarisi: Tarihçesi, Gelişimi Ve Tıbbi Görüntülemeadaki Rolü

Görüntü işleme alanlarında yaşanan gelişmelerin başında gerçek zamanlı nesne tespiti problemlerine yönelik olarak geliştirilen YOLO (You Only Look Once) mimarisi gelmektedir. Redmon ve arkadaşları tarafından 2016 yılında geliştirilen YOLO mimarisi, nesne tespitine yönelik geleneksel yöntemlerden farklı olarak, tek bir ileri geçişle (forward pass) görüntüdeki tüm nesneleri eş zamanlı olarak tespit etme ve sınıflandırma yeteneğiyle ön plana çıkmıştır. YOLO mimarisi, ilk versiyonundan itibaren “tek bakışta” nesne tespiti anlayışını merkezine alarak, bölütleme, kenar çıkarımı veya çok aşamalı filtreleme gibi zaman alan işlemleri ortadan kaldırmıştır. Bu yaklaşım, gerçek zamanlı uygulamalar açısından ciddi bir avantaj sağlamış ve YOLO'yu otonom sistemlerden akıllı güvenliğe, endüstriyel üretimden tarıma kadar birçok alanda yaygın hale getirmiştir (88).

YOLO'nun evrimi oldukça dikkat çekicidir. 2016 yılında yayınlanan ilk sürüm olan YOLOv1, Pascal VOC veri kümesinde ortalama doğruluk (mean Average Precision - mAP) açısından rakiplerinden geride kalsa da saniyede 45 karelik (FPS) hızla görüntü işleyerek büyük bir performans devrimi yaratmıştır (89). YOLOv2 (2017), daha yüksek çözünürlüklü girdi görüntüleri ve daha derin bir ağ mimarisi ile daha iyi genel doğruluk sağlarken, YOLOv3 (2018) çok ölçekli tespit özelliği ile küçük nesnelerdeki doğruluğu artırmıştır (90).

YOLOv4 (2020) ile birlikte, Bag of Freebies (BOF) ve Bag of Specials (BOS) gibi eğitim sürecini iyileştiren tekniklerin entegrasyonu sayesinde hem mAP hem de hız daha da geliştirilmiştir (91). YOLOv5 (2020, resmi olmayan) sürümünde PyTorch tabanlı açık kaynak kod yapısı sayesinde kullanıcılar model mimarisi üzerinde daha esnek şekilde değişiklik yapabilmeye başlamıştır. Bu sürüm, birçok uygulama geliştiricisinin ve araştırmacının YOLO mimarisine yönelmesini sağlamış; model boyutları (s, m, l, x) gibi varyantları ile hem hafif cihazlar hem de yüksek performanslı sistemler için uyarlanabilir hale gelmiştir. Ardından gelen YOLOv6, YOLOv7 ve YOLOv8 sürümleri; endüstriyel ölçekte performans artışı, görev odaklı modüler yapılar ve yüksek hassasiyetli tespit kapasitesiyle öne çıkmıştır (92, 93). YOLO mimarisinin gelişiminde son aşama olan YOLOv10, 2024 yılında tanıtılmış ve modelin eğitim sürecinde kullandığı yenilikçi stratejilerle dikkat çekmiştir. Özellikle “one-to-one” eşleme stratejisi sayesinde, çıkarım aşamasında geleneksel *Non-Maximum Suppression (NMS)* tekniğine olan ihtiyaç ortadan kaldırılmış; bu da tahmin süresini daha da kısaltarak gerçek zamanlı sistemlerde verimliliği önemli ölçüde artırmıştır (94). YOLOv10, düşük gecikmeli (low-latency) sistem gereksinimlerini karşılayarak özellikle zaman baskısının olduğu alanlarda büyük bir avantaj sağlamaktadır.

YOLO mimarisi yalnızca genel amaçlı görüntü işleme uygulamalarında değil, aynı zamanda tıbbi görüntüleme gibi yüksek doğruluk ve hassasiyet gerektiren alanlarda da geniş bir uygulama alanı bulmuştur. Tıbbi görüntüleme, genellikle yüksek çözünürlüklü ve karmaşık veri yapıları içerdiğinden, geleneksel görüntü işleme algoritmaları bu verilerde yetersiz kalabilmektedir. Bu noktada, derin öğrenme tabanlı yöntemler, özellikle de evrimsel sinir ağlarına (CNN) dayalı YOLO mimarileri, hem öğrenme kapasitesi hem de hız açısından etkili çözümler sunmaktadır (95).

YOLO’nun tıbbi görüntülemedeki ilk uygulamaları arasında, meme tümörlerinin sınıflandırılması (96), göz fundusunda lezyon tespiti (97), kolorektal poliplerin gerçek zamanlı belirlenmesi (7) ve tiroid nodülü analizi (98) gibi klinik açıdan önemli birçok problem yer almaktadır. Bu çalışmalarda YOLO, yüksek doğruluk oranları ile birlikte tespit süresinde kayda değer bir azalma sağlamış ve klinik karar destek sistemlerinin etkinliğini artırmıştır. Özellikle YOLOv3 ve sonrasındaki sürümler, çok ölçekli tespit yapıları ve grid tabanlı analiz yetenekleri sayesinde hem küçük hem de büyük boyutlu patolojik yapıların belirlenmesinde başarı göstermiştir. YOLO mimarisinin tıbbi görüntüleme alanındaki yükselişi yalnızca nesne tespitiyle sınırlı kalmamış; aynı zamanda segmentasyon, lokalizasyon ve sınıf ayrımı gibi alt görevlerde de modelin yüksek performansı kanıtlanmıştır. YOLO’nun eğitilebilirliği, transfer öğrenmeye uygun yapısı ve çok sınıflı çıktılar üretme

kabiliyeti, bu modeli tıbbi görüntüleme problemleri için cazip hale getirmiştir. Derin öğrenme temelli algoritmaların, görüntülerin içerdiği yapısal bilgileri öğrenme konusundaki başarısı sayesinde, YOLO gibi modeller varyasyon /anomali tespiti, lezyon analizi ve tümör sınıflandırması gibi görevlerde önemli avantajlar sunmaktadır (99).

Sonuç olarak, YOLO mimarisi hem genel bilgisayarla görme uygulamalarında hem de tıbbi görüntüleme gibi kritik öneme sahip disiplinlerde, gerçek zamanlı, yüksek doğrulukta ve çevik çözümler sunabilen güçlü bir araç haline gelmiştir. Bu mimarinin kalp damarlarındaki varyasyonların tespiti gibi karmaşık ve hassas görevlerde de etkili şekilde uygulanabileceği yönünde güçlü bir literatür desteği oluşmuştur. Bu bağlamda YOLO, yalnızca nesne tespiti değil, aynı zamanda klinik kararlarda destekleyici bir unsur olarak tıp alanında yeni bir paradigma sunmaktadır.

4.6 YOLO Algoritmasının Kullanım Alanları

Derin öğrenme ve evrimsel sinir ağlarının gelişmesiyle birlikte, nesne tespiti algoritmaları pek çok alanda devrimsel uygulamalara kapı aralamıştır. Bu uygulamalar içinde en öne çıkan modellerden biri olan YOLO algoritması, çok çeşitli sektörlerde geniş bir kullanım alanı bulmuştur. YOLO'nun temel avantajı olan tek geçişli nesne tespiti mimarisi, bir görüntüyü küçük parçalara bölmeden, doğrudan bütüncül olarak analiz etmesine olanak tanır. Bu sayede, daha önce karmaşık ve çok aşamalı işlem gerektiren nesne tespiti görevleri, gerçek zamanlı ve yüksek doğrulukta çözülebilir hale gelmiştir (88).

YOLO algoritması, özellikle otonom araçlar ve ileri sürüş destek sistemleri (ADAS) içinde aktif olarak kullanılmaktadır. Bu sistemlerin, çevresel farkındalık düzeylerini artırmak için kameralarla gerçek zamanlı görüntü işlemeye ihtiyaçları vardır. Yol işaretleri, yayalar, trafik ışıkları, bisikletliler ve diğer araçlar gibi kritik nesnelerin hızlı ve doğru bir biçimde tespit edilmesi, kaza riskini azaltmada kilit rol oynar (87).

YOLO'nun saniyede 30 ila 60 kare arasında işlem yapabilme kapasitesi, otonom sürüşün gerektirdiği milisaniyelik karar sürelerine doğrudan hizmet etmektedir. Fabrika üretim hatlarında da YOLO, gerçek zamanlı görsel kontrol sistemlerinin temel yapı taşlarından biri haline gelmiştir. Özellikle yarı iletken üretimi, otomotiv parçaları, ilaç kutuları, elektronik devre kartları gibi hassas toleranslarla üretim yapılan alanlarda, ürün üzerindeki çizik, kırık, hizasızlık ya da eksik parça gibi kusurlar YOLO ile tespit edilebilmektedir (100).

Geleneksel kamera sistemleriyle kıyaslandığında, derin öğrenme tabanlı bu yöntemlerin doğruluk oranı %90'ın üzerine çıkabilmekte, böylece insan gözüyle yapılan manuel kontrollerin yerini otomatik sistemler almaktadır. YOLO, şehir güvenliği, havaalanı kontrol noktaları, kalabalık yönetimi ve suç analizi gibi güvenlik uygulamalarında da yoğun olarak kullanılmaktadır. Kapalı devre kameralarla (CCTV) entegre çalışan sistemlerde, şüpheli nesne tespiti (örneğin bavul, silah), belirli kişilerin takibi, olağan dışı davranış analizi gibi görevler otomatik hale getirilebilmektedir. YOLO'nun zaman ve kaynak açısından düşük maliyetli çıkarım yapabilme özelliği, bu sistemlerin düşük güçlü donanımlarla bile çalışmasına olanak tanımaktadır (101).

Tarımda, drone ve uydu görüntüleriyle tarla analizi, zararlı tespiti, ürün olgunluk analizi ve bitki sağlığı izleme gibi görevlerde YOLO kullanılmaktadır. Örneğin, yaprak yüzeyindeki mantar enfeksiyonu belirtilerinin tespiti veya hasat zamanının tahmini gibi işlemler, YOLO modelleri kullanılarak otomatikleştirilmektedir. Tarımsal karar destek sistemleri, bu görsel analizleri kullanarak ilaçlama, sulama veya hasat planlamasını optimize edebilmektedir (102).

Modern perakende sistemlerinde kamera görüntüleri üzerinden müşteri davranış analizi yapmak, mağaza içi ürün yerleşimini düzenlemek ve hırsızlık tespiti gibi görevlerde de YOLO aktif olarak kullanılmaktadır. Bir müşterinin reyonda geçirdiği süre, ürüne temas edip etmediği gibi davranışsal veriler, nesne takibi üzerinden analiz edilebilir. Bu sayede hem satış stratejileri optimize edilmekte hem de müşteri deneyimi geliştirilmektedir (103).

YOLO'nun kullanım alanlarının en kritiklerinden biri de tıbbi görüntüleme sistemleridir. BT (Bilgisayarlı Tomografi), MR (Manyetik Rezonans) ve fundus görüntüleme gibi yöntemlerle elde edilen veriler, çok büyük boyutlara sahip olup, geleneksel yöntemlerle analiz edilmesi hem zaman alıcı hem de hata oranı yüksek işlemlerdir. YOLO gibi algoritmalar sayesinde, tümör tespiti, lezyon lokalizasyonu, organ segmentasyonu ve anomali ayıklama gibi görevler otomatik olarak gerçekleştirilebilmekte, tanı süreci hızlanmakta ve hekimin iş yükü azalmaktadır (104). Gerçek zamanlı geri bildirim ihtiyacının bulunduğu operasyonel senaryolarda da (örneğin endoskopi sırasında polip tespiti) YOLO, başarıyla entegre edilebilmektedir (7).

YOLO ayrıca savunma sanayiinde, insansız hava araçlarında (İHA) hedef tanıma ve izleme; uydu görüntüleme sistemlerinde ise coğrafi nesnelerin sınıflandırılması gibi görevlerde kullanılmaktadır. Radar verilerinin görsel temsilinden, harita tabanlı analizlere kadar birçok askeri görevde, düşük gecikmeli ve yüksek doğruluklu analizler için uygundur (105).

4.7 YOLO'nun Tercih Edilme Nedenleri

YOLO algoritmasının bu kadar geniş bir uygulama yelpazesinde öne çıkmasının arkasında, yalnızca performans değil, aynı zamanda mimari sadelik, işlem verimliliği ve pratiklik açısından sağladığı avantajlar yer almaktadır. Derin öğrenme tabanlı nesne tespitinde birçok alternatif bulunmasına rağmen, YOLO'nun tercih edilme nedenleri çeşitli yönlerden açıklanabilir:

YOLO, adından da anlaşılacağı üzere, nesne tespit işlemini görüntü üzerinde yalnızca bir kez bakarak (one-shot) tamamlar. Bu, geleneksel yöntemlerdeki bölütleme, öznitelik çıkarımı ve sınıflandırma gibi aşamaları tek bir adımda birleştirir. RCNN tabanlı yöntemler her bölge için ayrı ayrı sınıflandırma yaparken, YOLO tüm görüntüyü tek seferde işler. Bu özellik, YOLO'yu saniyede 30-60 kare (FPS) hızında çalışabilir hale getirir ve onu gerçek zamanlı uygulamalar için ideal bir seçenek haline getirir (106).

YOLO'nun mimarisi, giriş olarak aldığı ham görüntüden doğrudan sınıf ve koordinat çıkışı üretir. Bu *end-to-end* yaklaşım, eğitim ve çıkarım süreçlerinde sadelik ve esneklik sunar. Eğitim sürecinde kayıp fonksiyonu doğrudan sınıflandırma ve lokalizasyon hatalarına göre optimize edilir. Bu yapı, modelin hem eğitim hızını artırır hem de daha kompakt bir yapıyla çalışmasını sağlar (107).

YOLO mimarisi, donanımsal kısıtların olduğu mobil cihazlardan, yüksek performanslı sunuculara kadar geniş bir yelpazeye ölçeklenebilir. YOLOv5 sonrası modellerde tanıtılan küçük (s), orta (m), büyük (l) ve ekstra büyük (x) boyutlar, ihtiyaçlara göre özelleştirilebilir. Bu sayede farklı işlem gücü seviyelerinde en uygun hız-doğruluk dengesi sağlanabilir (92).

Görüntüdeki nesnelerin boyutlarındaki büyük değişkenlik, birçok modelin zayıf yönüdür. Ancak YOLOv3'ten itibaren gelen çoklu ölçekli özellik çıkarım katmanları (multi-scale feature maps), hem küçük hem de büyük nesnelerin tespitinde yüksek doğruluk sağlamaktadır. Özellikle medikal görüntülerde küçük boyutlu lezyonların tespiti için bu yapı büyük avantaj sunar (108). Geleneksel modellerde, aynı nesne için birden fazla tespit yapıldığında, yalnızca en güvenilir olanı tutulur. YOLO, bu adımı daha hassas ve hızlı gerçekleştiren *NMS* algoritmasıyla desteklenmiştir. Yeni sürümlerde bu yapı tamamen ortadan kaldırılmış (YOLOv10'da), bunun yerine "one-to-one assignment" mekanizmasıyla çıkarım süreci daha da sadeleştirilmiştir (103). YOLO algoritması, geniş bir açık kaynak topluluğuna sahip olduğu için sürekli geliştirilmeye devam etmektedir. Hem akademik dünyada hem de endüstride yaygın olarak benimsenmiş olması, dökümantasyon, uygulama örnekleri ve kütüphane desteği açısından zengin bir ekosistem oluşturmuştur (94).

4.8 Kalp Damarlarındaki Varyasyonlar Ve Anomaliler: Klinik Önemi Ve Yapay Zekâ Destekli Tespiti

Kardiyovasküler sistem, insan vücudunda kanın taşınmasından ve dokulara oksijen ile besin maddelerinin ulaştırılmasından sorumlu hayati bir sistemdir. Kalp ve damarları kapsayan bu sistemde oluşabilecek yapısal ya da işlevsel bozukluklar, ciddi sağlık sorunlarına yol açmaktadır. Kalp damarlarındaki anomaliler, genetik (konjenital) ya da çevresel faktörlere bağlı olarak gelişen ve sıklıkla asemptomatik ilerleyen klinik tablolardır. Bu anomaliler, hastada ani kardiyak olaylara, kalp yetmezliğine, miyokard iskemisine veya ritim bozukluklarına neden olabilmektedir (109).

Özellikle koroner arter varyasyonları ve darlıkları, erken evrede tespit edilmediğinde mortalite riskini artırmaktadır. Kardiyovasküler hastalıklar, dünya genelinde en yaygın ölüm nedenleri arasında yer almakta olup, 2023 verilerine göre yalnızca iskemik kalp hastalıkları, 8.5 milyon ölümle tüm ölüm nedenleri içinde ilk sırada yer almıştır (89). Bu tablo, söz konusu hastalıkların tanı ve tedavisinin yalnızca tedavi edici değil, aynı zamanda önleyici hekimlik açısından da kritik bir öneme sahip olduğunu göstermektedir. Erken ve doğru tanı, tedavi planlaması ve hasta takibi süreçlerinin başarısını doğrudan etkilemektedir. Bu kapsamda, Bilgisayarlı Tomografi (BT) gibi görüntüleme yöntemleri, kalp damarlarının yüksek çözünürlükte üç boyutlu görüntülenmesine imkân vererek tanıda devrim niteliğinde bir dönüşüm sağlamıştır. Ancak, BT görüntülerinin manuel yorumlanması hem zaman alıcı hem de yoruma açık bir süreçtir. Radyologlar tarafından yapılan değerlendirmelerde, görüntü sayısının çokluğu ve yapısal varyasyonların fazlalığı nedeniyle yanlış pozitif ve yanlış negatif oranları artabilmektedir. Buna bağlı olarak, daha objektif, hızlı ve otomatik analiz yapabilen sistemlere duyulan ihtiyaç her geçen gün artmaktadır (110).

Son yıllarda, derin öğrenme ve bilgisayarla görme tekniklerinin tıp alanında giderek daha fazla benimsenmesiyle birlikte, kardiyovasküler görüntüleme de bu teknolojilerden önemli ölçüde faydalanmaya başlamıştır. Özellikle YOLO (You Only Look Once) gibi nesne tespit algoritmaları, hem lokalizasyon hem de sınıflandırma işlemini tek bir modelde birleştirerek görüntü analizi süreçlerini sadeleştirmektedir. Geleneksel görüntü işleme tekniklerinin başarısız olabileceği düşük kontrastlı ve düzensiz şekilli yapıların analizinde, YOLO gibi modeller yüksek düzeyli öznetelikleri öğrenerek çok daha hassas sonuçlar sunmaktadır (94). Literatürde yapılan çeşitli çalışmalar, YOLO mimarisinin tıbbi görüntüler üzerinde oldukça başarılı performans gösterdiğini ortaya koymuştur. Örneğin, fundus görüntülerinde diyabetik retinopati bulgularının tespitinde (97), Meme tümörlerinin sınıflandırılmasında (96) ve kolonoskopi videolarında polip tanımlamasında (7) YOLO tabanlı modellerle yüksek kesinlik

ve duyarlılık elde edilmiştir. Bu başarıların temelinde, YOLO'nun sınırlayıcı kutu tahminleri ve sınıf skorlamasını aynı anda yapabilen çoklu görev öğrenme yapısı yer almaktadır. Kalp damarlarındaki varyasyonların ve anomalilerin tespiti açısından, bu tür modellerin en önemli katkısı, BT görüntülerinde varyasyon gösteren yapıların standart dışı örüntülerini öğrenerek tespit edebilmesi olacağını öngörüyoruz. YOLO mimarisi, damar tıkanıklıkları, çap daralmaları, anomal damar çıkışları, varyasyonlu bifurkasyon yapıları gibi pek çok karmaşık morfolojiyi öğrenebilmekte ve bu bölgeleri otomatik olarak sınıflandırabilmektedir.

Böylelikle hem tanı sürecinin hızlanması hem de doktorlar arası yorum farklılıklarının azalması mümkün hale gelmektedir (95). Ayrıca, bu tür sistemlerin eğitiminde kullanılan denetimli öğrenme yöntemleri sayesinde, uzman anotasyonları ile eğitilen modeller gerçek hastane verileri üzerinde genelleştirilebilir performans sergileyebilmektedir. YOLO'nun açık kaynak yapısı, farklı veri kümelerine kolayca adapte edilebilmesini ve yeni anomali türleri için yeniden eğitilebilmesini mümkün kılmaktadır (92).

Sonuç olarak, kalp damarlarındaki varyasyon ve anomalilerin yapay zekâ destekli tespiti, özellikle BT gibi yüksek hacimli veri üreten yöntemlerde büyük avantaj sağlamaktadır. YOLO gibi derin öğrenme tabanlı nesne tespit algoritmaları, bu alanda doğruluk, hız ve ölçeklenebilirlik açısından güçlü bir alternatif olarak öne çıkmakta; tanı sürecinin otomatikleştirilmesine ve klinik kararların desteklenmesine önemli katkılar sunmaktadır.

4.9 Literatürde Kalp Varyasyon Ve Anomalisi Tespiti İçin Kullanılan Derin Öğrenme Yöntemleri

Son yıllarda tıbbi görüntüleme alanında yaşanan dijital dönüşüm, özellikle kalp ve damar sistemine ilişkin anormalliklerin değerlendirilmesinde yapay zekâ tabanlı analiz yöntemlerinin önünü açmıştır. Derin öğrenme modelleri, özellikle yüksek çözünürlüklü ve çok boyutlu veriler üzerinde çalışabilme kapasitesi sayesinde, kardiyovasküler sistemdeki yapısal bozuklukların tespitinde etkili araçlar olarak öne çıkmaktadır. Literatürde, kalp varyasyonları ve anomalilerinin belirlenmesi amacıyla hem sınıflandırma hem de segmentasyon tabanlı birçok farklı model önerilmiştir (1,3,13,15).

En sık kullanılan yöntemlerden biri, evrimsel sinir ağlarına dayalı mimarilerdir. Bu yapılar, girdi olarak alınan iki boyutlu tıbbi görüntülerden anlamlı öznitelikler çıkararak, bu özniteliklerin sınıflandırılması yoluyla anomali varlığını belirleyebilmektedir. Örneğin, Zreik ve arkadaşları, kardiyak BT görüntüleri üzerinden miyokardiyal iskemi tespiti yapmak amacıyla derin CNN mimarisi kullanmış ve hastalıklı alanların tanımlanmasında yüksek doğruluk oranları elde etmiştir (111). Benzer şekilde, Litjens et al. tarafından yapılan derleme çalışmasında, derin öğrenme algoritmalarının kalp ve damar hastalıklarının

değerlendirilmesinde rutin klinik uygulamalara entegrasyon potansiyeli olduğu vurgulanmıştır (112). Segmentasyon tabanlı yaklaşımlar da kalp anatomisindeki anormal bölgelerin piksel düzeyinde ayrıştırılması için kullanılmaktadır. Özellikle U-Net ve türevleri, bu tür görevlerde sıklıkla tercih edilmektedir. U-Net'in encoder-decoder yapısı, giriş görüntüsündeki alanların konum bilgisi ile sınıf bilgisini aynı anda koruyarak, kalp odacıkları, damar yapıları ve anormal bölgeleri başarılı şekilde ayırt edebilmektedir. Mortada ve arkadaşları, transtorasik ekokardiyografi görüntülerinde kalbin sol bölümlerini segmentlemek amacıyla geliştirdikleri U-Net tabanlı bir modeli başarıyla uygulamışlardır (95).

Bunun yanında, Res-Net, Dense-Net, Efficient-Net gibi daha derin CNN mimarileri de, kalp yapılarındaki ince farklılıkları öğrenme konusunda başarılı sonuçlar vermektedir. Bu modeller, özellikle geniş etiketli veri setleri üzerinde transfer öğrenme yoluyla eğitildiğinde, sınırlı veriye sahip klinik durumlarda etkili sonuçlar verebilmektedir. Örneğin, Smistad ve arkadaşları, kalp ultrason görüntülerinde sol ventrikül sınırlarının belirlenmesi için ResNet tabanlı bir yaklaşım geliştirmiş ve klinik yorumlayıcılarla karşılaştırılabilir çıktılar elde etmiştir (113). Geleneksel CNN modellerinin yanı sıra, son dönemde nesne tespit görevlerine özel geliştirilmiş modeller de kalp anomalisi analizlerinde kullanılmaya başlanmıştır.

Özellikle YOLO, Faster R-CNN ve RetinaNet gibi mimariler; kalp damarlarının lokalizasyonu, varyasyonların konumunun belirlenmesi ve sınıflandırması gibi çok yönlü görevleri tek bir model altında gerçekleştirebilme kapasitesine sahiptir. YOLO mimarisi, düşük işlem süresi ve tek geçişli yapısı sayesinde, yüksek çözünürlüklü BT görüntüleri üzerinde hızlı tespitler yapılmasına olanak tanımaktadır (95,113). Tüm bu çalışmalar, kalp damar hastalıklarının erken teşhisi, risk sınıflandırması ve cerrahi planlamada yapay zekâ destekli sistemlerin giderek daha fazla rol almaya başladığını göstermektedir. Derin öğrenme mimarilerinin sunduğu potansiyel, hekimlerin iş yükünü azaltmakla kalmayıp, aynı zamanda insan hatasını minimize ederek klinik süreçlerin güvenilirliğini de artırmaktadır.

5. GEREÇ VE YÖNTEM


Çalışma yürütüldüğü merkezdeki etik kurul tarafından onaylanmıştır(Etik kurul numarası: 2025-05/04, Tarih: 06.03.2025, Erzincan Binali Yıldırım Üniversitesi). Aydınlatılmış onam formu ise çalışmanın retrospektif karakteri sebebiyle gerekli görülmemiştir. Bu çalışmada, koroner artere ait bazı önemli varyasyonların tespiti için bir derin öğrenme algoritma modeli olan YOLO kullanılarak kapsamlı bir yöntem geliştirilmiştir.

Araştırma, tıbbi görüntü analizi süreçlerinde hem doğruluk hem de hız açısından önemli bir yere sahip olan YOLO mimarisinin güncel sürümlerinden YOLOv10'u içermektedir. YOLOv10, önceki sürümlerinden daha gelişmiş bir özellik çıkarım yeteneğine sahip olup, model doğruluğunu artırırken tespit süresini en aza indiren bir algoritma yapısına sahiptir.

Çalışmada kullanılan veri seti farklı kardiyak problemlerle üçüncü basamak hastaneye başvuran toplamda 100 hastadan bazı dışlama kriterleri yapılarak (Tablo 2) elde kalan koroner varyasyonlu olduğu bilinen 20 hastaya ait çok kesitli Kardiyak BT görüntülerini içeren 2.837 kesitten oluşmaktadır. Bu görüntüler (2837), 2.263'ü eğitim, 287'si doğrulama ve 287'si test olmak üzere üç alt gruba ayrılmıştır. Bu veri seti, eğitim, doğrulama ve test süreçlerinde dengeli bir şekilde dağıtılarak algoritmanın farklı senaryolar altında performansını değerlendirmek için hazırlanmıştır.

Dışlama kriterleri; 18 yaş altı hastalar, Koroner arter ya da kardiyak bir problemten opere olan hastalar, Koroner artere veya Asendan aortaya uygulanmış stentli olgular, Dekstrokardi vb. kalbin normal anatomisini bozan aks anomalileri, Eksik görüntüye ya da artefaktlı görüntülere sahip hastalar çalışmaya dahil edilmedi(Tablo 1).

Tablo 1. : Hasta Dışlama Kriter Diyagramı



5.1 Çalışmaya Alınan Koroner Arter Varyasyonları Ve Kısaltma İsimlendirilmeleri

1. **MYB**: Miyokardiyal Briding,
2. **SLMCA** : Kısa seyirli LMCA
3. **LHTO** : LMCA ‘nın yüksek çıkış göstermesi
4. **LPDA**: PDA’nın Cx kaynaklı olması
5. **RCx**: Cx’in RCA dan orjin alması
6. **ELMCA**: Uzun seyir gösteren LMCA
7. **NLMCA** : LMCA yokluğu
8. **RBCx** : RCA dalından orjin alan Cx
9. **DLAD**: LAD duplikasyonu
10. **LRCA** : LMCA’dan orjinn alan RCA
11. **NRCA** : RCA yokluğu
12. **DLCx**: LCx duplikasyonu

Koroner BT protokolümüz 128 dedektörlü bir BT tarayıcı (Lightspeed VCT, GE Healthcare, Milwaukee, WI, ABD) kullanarak gerçekleştirildi. Dedektör kolimasyonu 64x 0,625 mm, tüp akımı 400-500 mAs, voltaj 80 kVp veya 120 kVp, kesit aralığı aralık 0,16-0,24 (ortalama 0,22) ve gantri dönüş süresi 0,35 sn. Elektrokardiyogram (EKG) gating retrospektif olarak düzenlendi. EKG modülasyonu kullanarak radyasyon doz miktarını önemli ölçüde azaltıldı.

Koroner arter BT görüntülerin oluşmasında hastanın alacağı dozu azaltmak için sistolik fazda radyasyon dozu azaltıldı (80kVp). Koroner arterlerin daha net görüntülenmesi için diyastolik fazda hastalara tam doz (120kVp) radyasyon verildi. Bazı taşikardik olgulara kontrendikasyon olmadığı sürece incelemeden 1 saat önce beta-bloker (50-100mg metoprolol , Beloc Zok , Astra Zeneca) verildi. Halen taşikardik olan olgular durumunda ilgili klinisyenle görüşüp ya randevusu farklı bir güne ertlendi ya da intravenöz (İV) beta bloker (5mg metoprolol İV bolus; Beloc Ampul , Astra Zeneca) ile uygulandı. Çekime alınan hastaların kalp hızı 40-88 atım/dakika(ortalama 61 atım/dakika) aralığındaydı.

Alınan Koroner BT görüntülerini öncesinde ‘Syngo.Via’ olarak adlandırılan özel yazılımlı bir iş istasyonunda değerlendirilmeye alındı (Syngo.via, Siemens Healthineers, Erlangen, Almanya)


Veri seti, eğitim, doğrulama ve test süreçlerinde dengeli bir şekilde dağıtılarak algoritmanın farklı senaryolar altında performansını değerlendirmek için hazırlanmıştır. Veri seti seçimi ve ön işleme adımları, YOLOv10'un anormal bölgeleri doğru bir şekilde öğrenmesini sağlamak amacıyla dikkatle tasarlanmıştır. Ayrıca, bu bölümde YOLOv10 algoritmasının nasıl uygulandığı, hiperparametre ayarları ve modelin eğitimi sırasında izlenen süreçler açıklanacaktır. Algoritmanın başarısını değerlendirmek için kullanılan metrikler, kesinlik gibi ölçütleri de içermektedir. Bu bölüm, çalışmanın temel yapı taşlarını oluşturan veri seti, kullanılan derin öğrenme modeli ve performans değerlendirme kriterlerini detaylandırarak, araştırmanın metodolojik altyapısını sağlam bir şekilde ortaya koymayı amaçlamaktadır.

Tıbbi görüntüleme uygulamalarında precision (kesinlik), bir modelin pozitif olarak tahmin ettiği örneklerden kaç tanesinin gerçekten pozitif olduğunu ölçen kritik bir değerlendirme metriğidir. Özellikle koroner arter varyasyonları ve anomalileri gibi hastalık tespiti çalışmalarında, yüksek bir precision değeri, modelin yanlış pozitif (false positive) oranını minimize ettiğini ve yalnızca gerçekten anormal bölgeleri tespit ettiğini gösterir. Yanlış pozitif sonuçlar, tıbbi uygulamalarda ciddi sonuçlara yol açabilir; örneğin, hastaların gereksiz yere stres yaşaması, gereksiz tıbbi testlere veya müdahalelere maruz kalması gibi durumlar ortaya çıkabilir. Bu nedenle, yüksek bir precision değeri, modelin güvenilirliğini ve klinik karar süreçlerine entegrasyon potansiyelini artırarak, tıbbi tanı sistemlerinin etkinliğini önemli ölçüde artırır.

Şekil 4, YOLOv10 algoritmasını kullanarak tıbbi görüntülerin sınıflandırılması sürecini adım adım göstermektedir. Süreç şu adımlardan oluşmaktadır:

- **Veri Seti Toplama**: İlk adımda, koroner arter varyasyonların tespiti ve sınıflandırılması için kullanılan BT görüntüleri gibi tıbbi görüntülerin toplanması sağlanır. Bu aşama, modelin eğitim ve test süreçleri için temel veri setinin oluşturulmasını sağlar.
- **Resim Etiketleme**: Toplanan veri setindeki görüntüler, gerçek değerli (ground truth) bilgileri ile etiketlenir. Bu aşamada, görüntülerdeki anormal bölgeler sınır kutuları ile işaretlenir ve sınıflandırma etiketleri atanır.
- **Verileri Böl**: Anotasyon işlemi tamamlandıktan sonra, veri seti eğitim, doğrulama ve test olmak üzere üç alt gruba ayrılır. Bu bölme işlemi, modelin performansını değerlendirmek ve genelleme yeteneğini test etmek için önemlidir.
- **Eğitim**: Eğitim seti kullanılarak YOLOv10 algoritması eğitilir. Model, koroner arter varyasyonlarını tespit edebilmek için verilerden öğrenme sürecine girer.

- **Doğrulama:** Eğitim sırasında doğrulama seti kullanılarak modelin ara performansı değerlendirilir. Bu aşama, modelin aşırı öğrenme (overfitting) yapmasını önlemek için kritik bir rol oynar.
- **Test:** Model eğitimi tamamlandıktan sonra, test seti kullanılarak modelin genel performansı değerlendirilir. Bu aşama, modelin gerçek dünya uygulamalarındaki başarısını ölçmek için önemlidir.
- **Metrik Değerlendirmesi:** Modelin doğruluğu, duyarlılığı (Sensitivity), kesinliği (Precision), F1 skoru ve Birleşim Üzerindeki Kesişim (Intersection over Union -IoU) gibi değerlendirme metrikleri kullanılarak performansı analiz edilir. IoU bilgisayarlı görme alanında nesne tespit modellerinin başarısını ve doğruluğunu ölçmek için kullanılan temel bir metriktir. Bu ölçüm, iki sınırlayıcı kutunun ne kadar örtüştüğünü sayısal olarak ifade eder. Biri gerçek nesnenin konumunu gösterirken, diğeri modelin o nesne için yaptığı tahmini temsil eder. IoU, modelin tahmin ettiği kutunun, gerçek nesneyle ne derece örtüştüğünü ortaya koyar. Yüksek bir IoU değeri, tahminin gerçeğe yakın ve doğru olduğunu gösterir.
- **Sınıflandırma:** Son aşamada, model, normal ve sık görülen bazı koroner arter varyasyonları (örneğin, MYB, SLMCA, LHTO vb.) doğru bir şekilde sınıflandırır ve bu sınıflandırma sonuçları nihai olarak raporlanır.



Şekil 4. Çalışmanın Akış Şeması

5.2 Dataset

Bu çalışmada kullanılan veri seti, koroner arter varyasyonların tespitine yönelik olarak ince kesit KBTA görüntülerinden oluşmaktadır. Veri seti, KBTA'sı çekilen varyasyonlu ve normal anatomik koroner arter yapısına sahip toplamda 20 farklı hastadan toplanan ince kesit 2.837 aksiyal BT görüntüsünü içermektedir. Bu görüntüler, eğitim, doğrulama ve test aşamalarında kullanılmak üzere dikkatlice ayrılmıştır:

- Eğitim (Training) Seti: 2.263 görüntü
- Doğrulama (Validation) Seti: 287 görüntü
- Test (Testing) Seti: 287 görüntü

Veri seti, farklı koroner arter varyasyonlarını içeren görüntülerle zenginleştirilmiş olup, anotasyon işlemleri titizlikle gerçekleştirilmiştir. Anotasyonlar, YOLOv10 algoritmasının ihtiyaç duyduğu formatta hazırlanmış ve her görüntüdeki varyasyonların sınırlarını belirleyen sınır kutuları (bounding boxes) kullanılarak tanımlanmıştır. Bu, modelin hem varyatif bölgeleri tespit etmesine hem de doğru bir şekilde sınıflandırmasına olanak tanımaktadır. Veri setinin hazırlanması sırasında görüntüler farklı hasta gruplarından alınarak çeşitlilik sağlanmıştır. Bu, modelin farklı varyasyonları öğrenmesini ve genelleme yeteneğini artırmasını sağlamaktadır. Veri setinin dengeli bir şekilde ayrılması, modelin doğruluğunu ve genelleme performansını test etmek için önemli bir temel oluşturmuştur.

5.3 YOLOv10

YOLOv10, hızlı ve doğru sonuçlar üreten bir derin öğrenme algoritmasıdır. Tek aşamalı bir dedektör olan YOLO, bir evrimsel sinir ağı (CNN) üzerinden tek bir ileri geçişle, bir görüntüdeki nesnelerin sınır kutularını ve sınıf olasılıklarını aynı anda tahmin edebilir. Bu özellik, YOLOv10'u özellikle gerçek zamanlı uygulamalar için ideal bir çözüm haline getirmektedir. YOLOv10, önceki sürümlerine kıyasla daha gelişmiş bir özellik çıkarma yeteneği ve derin ağ mimarisiyle öne çıkmaktadır. Bu iyileştirmeler hem doğruluk oranlarını artırmakta hem de tespit hızını optimize etmektedir.


Model, grid tabanlı bir yaklaşım kullanarak görüntüyü bölgelere ayırır ve her bir bölgedeki nesnelerin varlığını ve konumunu değerlendirir. YOLOv10'un yetenekleri, tıbbi görüntüleme gibi karmaşık ve hassas veri türlerinde bile başarılı sonuçlar elde etmeye olanak tanır. Bu çalışmada, YOLOv10 kullanılarak KBTA görüntülerindeki koroner arter varyasyonların tespit edilmesi hedeflenmiştir. Model, tıbbi verilerin özelliklerini öğrenmek üzere, hazırlanmış bir eğitim veri setiyle eğitilmiştir. YOLOv10'un hem hız hem de doğruluk açısından sağladığı üstünlükler, modelin klinik ortamlarda uygulanabilirliğini artırmakta ve erken teşhis

süreçlerinde yenilikçi bir çözüm sunmaktadır. Bu bölümde, YOLOv10'un mimari özellikleri, hiperparametre ayarları ve uygulama süreci detaylı bir şekilde ele alınacaktır.

Geleneksel olarak, YOLO modelleri eğitim sırasında birden-çoğa atama stratejisi kullanır; bu strateji, her bir gerçek değerli (ground truth) örnek için birden fazla pozitif örnek atanmasını sağlar. Görev Farkındalıklı Öğrenme (Task-Aware Learning, TAL) olarak bilinen bu yöntem, optimizasyonu ve genel performansı artıran bol miktarda denetleyici sinyal sunar. Ancak, bu yaklaşım aynı zamanda fazlalık içeren tahminleri filtrelemek için çıkarım (inference) sırasında Maksimum Olmayan Bastırma (Non-Maximum Suppression, NMS) kullanılmasını gerektirir. Bu durum, verimsizliklere ve çıkarım gecikmesinin artmasına yol açabilir. YOLO-v10, bu stratejileri zekice birleştirerek, orijinal birden-çoğa dal yapısını ve optimizasyon hedeflerini yansıtan ek bir birden-bire (one-to-one) katman sunar. Eğitim sırasında, her iki katman birlikte optimize edilir ve birden-çoğa atamalardan gelen zengin denetim sinyallerinden yararlanır. Çıkarım aşamasında ise model yalnızca birden-bire katmanı kullanır; böylece NMS ihtiyacını ortadan kaldırarak ek bir çıkarım maliyeti olmadan yüksek verimlilik sağlar (bkz. Şekil 5).

Çift etiket atama stratejisinin temel bileşenlerinden biri, tahminler ile gerçek değerli (ground truth) örnekler arasındaki uyumu değerlendirmek için kullanılan tutarlı eşleştirme metriğidir. Bu metrik hem sınıflandırma skorunu hem de tahmin edilen ve gerçek sınırlayıcı kutular (bounding boxes) arasındaki IoU değerini içermektedir ve şu şekilde tanımlanır:

$$m(\alpha, \beta) = s * p^\alpha * IoU(\hat{b}, b)^\beta \# (SEQ \text{ Denklem } \setminus * ARABIC 1)$$



Şekil 5. NMS'siz (Non-Maximum Suppression) eğitim için tutarlı çift atamalar (5).

5.4 Değerlendirme Ölçütleri (Evaluation Metrics)

Kesinlik (Precision), gerçek pozitif örneklerin, pozitif olarak sınıflandırılan örnekler içerisindeki oranı olarak tanımlanır. Pozitif örnekler içindeki doğru pozitif vakaların yüzdesini gösterir. Kesinlik, yanlış pozitif örneklerin miktarını azaltmaya odaklanır.

$$Precision = \frac{TP}{TP + FP} \# (SEQ Denklem \setminus * ARABIC 2)$$

Duyarlılık (Recall), doğru pozitif örneklerin tüm pozitif örneklere oranını ifade eder. Yani, tüm doğru pozitif örnekleri tespit etme başarısını gösterir. Duyarlılık, yanlış negatif örneklerin sayısını azaltmaya odaklanır.

$$Recall = \frac{TP}{TP + FN} \# (SEQ Denklem \setminus * ARABIC 3)$$

F1 skoru, kesinlik (precision) ve duyarlılığın (recall) harmonik ortalamasıdır. Kesinlik ve duyarlılık her ikisi de yüksek olduğunda, F1 skoru da yüksek olacaktır.

$$F1 - Score = 2 * \frac{Precision * Recall}{Precision + Recall} \# (SEQ Denklem \setminus * ARABIC 4)$$

Spesifiklik (Specificity), doğru negatif örneklerin tüm negatif örneklere oranını ifade eder. Yani, tüm doğru negatif örnekleri tespit etme başarısını gösterir.

$$Specificity = \frac{TN}{TN + FP} \# (SEQ Denklem \setminus * ARABIC 5)$$

Mean Average Precision (mAP), bir modelin nesne tespiti performansını değerlendirmek için kullanılan bir ölçüttür. mAP, sınıf başına Ortalama Doğruluk (Average Precision, AP) değerlerinin ortalamasını alarak hesaplanır. Bir sınıf için Ortalama Doğruluk (AP) şu şekilde hesaplanır:

- **Precision-Recall Eğrisi (P-R Curve):** Farklı eşik değerleri (IoU eşikleri) için Precision ve Recall değerleri hesaplanarak bir eğri oluşturulur.
- **AP Hesaplama:** Precision-Recall eğrisinin altındaki alan (area under the curve, AUC) hesaplanır. Bu, sınıf için ortalama doğruluğu verir.

mAP formülü, tüm sınıflar için AP'nin ortalamasını alır:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \# (SEQ Denklem \setminus * ARABIC 6)$$

Yukarıdaki metrikler, sınıflandırma modellerinin performansını ölçmek için yaygın olarak kullanılan metriklerdir. Bu göstergeler, çalışmanın başarı kriterini değerlendirmek için kullanılmaktadır. Burada:

N : Toplam sınıf sayısı, A

P_i : Her bir sınıf için hesaplanan Ortalama Doğruluk (Average Precision).

Train Box Loss, Nesne tespiti (object detection) modellerinde kullanılan bir hata ölçümüdür. Modelin tahmin ettiği sınırlayıcı kutu (bounding box) ile gerçek kutu (ground truth) arasındaki konum ve boyut farkını sayısal olarak ifade eder. Bu fark ne kadar küçükse, modelin tahmini o kadar doğrudur.

Minimum Train Box Loss ise modelin eğitim süreci boyunca bu kutu kaybının ulaştığı en düşük değerdir. Yani modelin sınırlayıcı kutuları, eğitim verisindeki gerçek kutulara en yakın şekilde tahmin ettiği anda oluşan en iyi sonuçtur. Bu değer, modelin öğrenme kapasitesinin en verimli olduğu noktayı temsil eder.

Object Matching (OM) , Nesne tespiti modellerinde, modelin bulduğu kutular ile gerçek kutuların birbiriyle eşleştirilmesi işlemidir. Bu eşleştirme sayesinde modelin ne kadar doğru çalıştığı değerlendirilir. Eşleştirme işlemi genellikle IoU (Intersection over Union) adı verilen bir ölçütle yapılır. IoU, tahmin edilen kutu ile gerçek kutunun ne kadar örtüştüğünü gösteren bir orandır. Örtüşme ne kadar fazlaysa, eşleşme o kadar başarılı kabul edilir.

Minimum Validation Box Loss , Modelin nesneleri en doğru şekilde yerleştirmeyi **başardığı** noktayı gösteren bir değerdir. Daha açık anlatmak gerekirse: Box Loss, modelin çizdiği kutular ile gerçek nesne kutuları ne kadar örtüşüyor diye ölçülen bir hatadır. Bu hata ne kadar küçükse, model nesneleri o kadar doğru yerleştiriyor demektir.

Validation aşamasında, model daha önce görmediği verilerle test edilir. Buradaki en düşük kutu hatasına da "**Min Validation Box Loss**" denir.

Minimum Train Box Loss OM, modelin eğitim seti üzerinde tahmin edilen sınır kutularının (bounding boxes) gerçek kutulara olan konum ve boyut farklılıklarını ölçen kayıp fonksiyonunun, eğitim sürecinde ulaşılan en düşük değerini ifade eder. Bu metrik, modelin nesne lokasyonlarını ne kadar doğru şekilde öğrendiğini gösterir.

Minimum Train Class Loss OM, eğitim aşamasında model tarafından tahmin edilen sınıf olasılıklarının gerçek sınıf etiketleriyle olan uyumsuzluğunu ölçen sınıflandırma kayıp fonksiyonunun, eğitim sürecinde ulaştığı en düşük değeri belirtir. Bu değer, modelin eğitim verisi üzerindeki sınıflandırma başarımını yansıtır.

Minimum Train Distribution Focal Loss (DFL) OM, modelin eğitim setindeki kutu koordinatlarını sürekli dağılımlar şeklinde daha hassas şekilde tahmin etmesini sağlayan ve koordinat regresyonundaki hatayı ölçen DFL kayıp fonksiyonunun, eğitim süresince ulaştığı minimum değeri belirtir. Bu kayıp, özellikle kutu sınırlarının daha kesin belirlenmesinde etkilidir.

Minimum Validation Box Loss OM, doğrulama setinde (validation) modelin tahmin ettiği sınır kutuları ile gerçek kutular arasındaki uyumsuzluğu ölçen box loss fonksiyonunun, doğrulama süresince gözlemlenen en düşük değeridir. Modelin genel performansının aşırı öğrenme (overfitting) olmadan, farklı veri üzerinde ne kadar iyi genellenebildiğini gösterir.

Minimum Validation Class Loss OM, modelin doğrulama setindeki nesne sınıflandırma hatalarını ölçen kayıp fonksiyonunun, doğrulama aşamasında ulaştığı minimum değeri ifade eder. Bu değer, modelin eğitimde öğrendiği sınıflandırma bilgisinin, görmediği veri üzerinde ne kadar başarılı şekilde uygulandığını gösterir.

Minimum Validation Distribution Focal Loss (DFL) OM, doğrulama veri kümesinde kutu koordinatları için hesaplanan DFL kayıp fonksiyonunun, doğrulama sürecindeki en düşük değeridir. Bu metrik, modelin hassas kutu koordinatlarını yeni veri üzerinde ne derece iyi tahmin edebildiğini değerlendirir.

6. BULGULAR

Tablo 2, YOLOv10 modelinin farklı varyantlarının (N, S, M, B, L, X) performansını değerlendirmek için kullanılan metriklerin sonuçlarını göstermektedir. Bu metrikler, modelin kesinlik (precision), duyarlılık (recall), F1 skoru, mAP50 (%50 IoU eşiğinde Ortalama Doğruluk) ve mAP50-95 (%50 ile %95 IoU eşiği arasında Ortalama Doğruluk) gibi değerlerini içermektedir. Ayrıca, modelin eğitim ve doğrulama kayıplarına ilişkin minimum değerler de tabloya dahil edilmiştir.


Tablo 2. Yolov10 Modelinin Farklı Varyantlarının Performans Sonuçları

DEĞERLENDİRME ÖLÇÜTÜ	YOLOv10-N	YOLOv10-S	YOLOv10-M	YOLOv10-B	YOLOv10-L	YOLOv10-X
Precision	87.7 %	71.7 %	82.8 %	89.6 %	84.8 %	<u>92.0 %</u>
Recall	63.4 %	64.9 %	15.2 %	16.0 %	<u>75.6 %</u>	24.2 %
F1-Score	65.5 %	68.1 %	23.4 %	25.0 %	<u>78.0 %</u>	31.0 %
mAP50	68.4 %	72.2 %	14.9 %	14.6 %	<u>80.5 %</u>	26.0 %
mAP50-95	33.4 %	34.2 %	10.0 %	9.0 %	<u>40.6 %</u>	13.7 %
Min Train Box Loss OM	1.68	1.65	2.21	2.21	<u>1.18</u>	1.54
Min Train Class Loss OM	1.06	0.97	1.05	1.04	<u>0.56</u>	0.65
Min Train DFL OM	1.01	1.02	1.04	1.03	<u>0.90</u>	0.91
Min Validation Box Loss OM	1.76	1.80	2.54	2.51	<u>1.72</u>	2.54
Min Validation Class Loss OM	1.17	1.10	1.60	1.63	<u>0.86</u>	1.66
Min Validation DFL OM	<u>1.0</u>	1.02	1.05	1.03	1.02	1.05

- ❖ **YOLOv10-X** modelinde en yüksek precision (%92.0) değerine ulaşılmış olmasına rağmen, mAP50 değeri (%26.0) diğer modellere göre oldukça düşüktür.
- ❖ **YOLOv10-L modeli**, %80.5 ile en yüksek mAP50 değerine ulaşmıştır.
- ❖ **YOLOv10-X modeli**, yüksek precision sağlarken düşük recall değerinden dolayı mAP50'de başarılı olamamıştır.
- ❖ Tabloda en düşük Min Train Box Loss OM değeri **YOLOv10-L** modelinde (1.18) elde edilmiştir. Bu sonuç, **YOLOv10-L** modelinin eğitim sürecinde diğer modellere kıyasla nesne konumlarını daha hassas biçimde öğrenebildiğini göstermektedir.
- ❖ Tabloya göre, **YOLOv10-L** modeli (0.56) en düşük eğitim sınıf kaybına ulaşmış ve bu, modelin sınıf ayrımında diğer modellere göre daha başarılı olduğunu göstermektedir.
- ❖ Tabloda, **YOLOv10-L** modeli (0.90) en düşük DFL kaybına ulaşmıştır, bu da kutu sınırlarının hassasiyetinde önemli bir avantaja işaret etmektedir.
- ❖ Tabloda, **YOLOv10-L** modelinde bu değer 1.72 ile en düşüktür ve modelin doğrulama verisinde kutu tahmininde en iyi performansı sergilediğini gösterir.
- ❖ Tabloda, **YOLOv10-L** modeli (0.86) bu metrikte de en düşük değeri elde etmiştir; bu da modelin sınıflandırma bilgisini görmediği veride de en iyi şekilde uygulayabildiğini göstermektedir.
- ❖ Tabloda, **YOLOv10-N (1.0)** ve **YOLOv10-L (1.02)** modelleri en düşük değerlere ulaşmıştır; bu, bu modellerin özellikle koordinat hassasiyetinde doğrulama verisinde daha stabil bir performans gösterdiğini belirtir.
- ❖ Tablo 2'de dikkat çeken önemli bir bulgu, **YOLOv10-L** modelinin, hem eğitim hem doğrulama aşamalarında kutu regresyonu ve sınıflandırma kayıplarında en düşük değerlere ulaşarak, genel olarak hem doğruluk (precision, recall, F1-score) hem de genelleme yeteneği açısından üstün performans sergilemesidir. Özellikle Min Train/Validation Box

Loss ve Class Loss değerlerinin düşük olması, modelin aşırı öğrenmeden (overfitting) kaçınarak istikrarlı ve güvenilir sonuçlar verdiğini göstermektedir

Ayrıca yapılan çalışmalar sonucunda elde edilen grafikler Şekil 6’te gösterilmiştir. Bu grafik, farklı sınıflar için Precision (Kesinlik) değerinin Confidence (Güven Skoru) seviyelerine göre değişimini göstermektedir. Grafik, her bir sınıfın ve genel olarak modelin doğruluk performansını değerlendirmek için kullanılabilir. Aşağıda bu grafiğin analizi yer almaktadır:




Şekil 6. Precision-Confidence Curve Analizi

- ❖ Mavi Kalın Çizgi , tüm sınıflar için ortalama kesinlik değerlerini göstermektedir. Grafik, tüm sınıflar için güven (confidence) skoru %89.9 seviyesine geldiğinde kesinlik (precision) değerinin 1.00’e ulaştığını belirtmektedir.
- ❖ Her sınıfın farklı güven (confidence) skoru seviyesinde performans gösterdiği görülmektedir.

- ❖ LPDA ve NORMAL sınıflarının yüksek güven (confidence) skorlarında daha yüksek ve daha istikrarlı kesinlik (precision) değerlerine sahip olduğu gözlemlenmektedir.
- ❖ MYB gibi bazı sınıflarda, kesinlik (precision) değeri düşük güven (confidence) skorlarında oldukça düşüktür ve model bu sınıflarda daha fazla yanlış pozitif tahmin yapmaktadır.
- ❖ Güven (confidence) skoru düşük olduğunda (0.0 ile 0.3 arası), birçok sınıf için precision değerinde ciddi dalgalanmalar vardır.
- ❖ Güven (confidence) skoru %0.5'i geçtiğinde, NORMAL ve diğer bazı sınıflar için precision değerleri daha kararlı hale gelmektedir.
- ❖ Ancak bazı sınıflar (örneğin MYB) düşük güven (confidence) skorlarında belirgin bir şekilde başarısızdır.
- ❖ Grafik, güven (confidence) skoru %89.9 civarında tüm sınıfların yüksek kesinlikte çalıştığını göstermektedir.
- ❖ Bu grafik ayrıca modelin performansını hem genel hem de sınıf bazında değerlendirerek, hangi alanlarda daha fazla iyileştirme gerektiğine dair önemli ipuçları sunmaktadır. Yüksek confidence eşiklerinde, modelin yanlış pozitif oranı azalmaktadır. Ancak düşük confidence eşiklerinde bazı sınıflar için kararsızlık görülmektedir.

Şekil 7'te, YOLO-v10 modeli tarafından KBTA görüntülerinde tespit edilen farklı varyasyonların ve NORMAL sınıfı için yapılan tahminleri göstermektedir. Görsellerde her bir sınıf için tahmin edilen sınır kutuları ve bu tahminlerin güven (confidence) skorları belirtilmiştir.

Görseller, **YOLOv10** modelinin koroner arter varyasyonları ve NORMAL sınıfı için yüksek doğruluk oranlarına sahip tahminler yaptığını göstermektedir. Model, sınıflarda güvenilir sonuçlar üretmiş ve tahminlerin büyük bir kısmında doğru sınıflandırmalar gerçekleştirmiştir. Görseller, modelin sınıflandırma kapasitesini ve çeşitli sınıflarda başarılı performansını ortaya koymaktadır. Ayrıca, modelin tespit ettiği sınırlayıcı kutular, koroner arter varyasyonların tespiti ve sınıflandırılması için güçlü bir temel sunmakta, tıbbi görüntüleme analizlerinde **YOLOv10'un** yüksek potansiyelini göstermektedir. Tahminlerin çeşitliliği ve güvenilirliği, modelin geniş bir uygulama alanında etkili olabileceğini vurgulamaktadır.



Şekil 7. : Görsellerde NORMAL, MYB, SLMCA, LHTO, LPDA, RCX, ELMCA, NLMCA, RBCX, DLAD, LRCA, NRCA ve DLCX sınıflarına ait tahminler yer almaktadır. NORMAL sınıfı en sık tespit edilen sınıf olup, neredeyse tüm görsellerde modelin yüksek güven skorlarıyla bu sınıfı tespit ettiği görülmektedir.

- Şekil 7-a: MYB sınıfına ait tespit(Güven skoru: Normal sınıf -0.69, MYB -0.73)
- Şekil 7-b: SLMCA sınıfına ait tespit(Güven skoru: Normal sınıf -0.70, SLMCA-0.64)
- Şekil 7-c:LHTO sınıfına ait tespit(Güven skoru: Normal sınıf -0.85, LHTO-0.80)
- Şekil 7-d: LPDA sınıfına ait tespit (Güven skoru: Normal sınıf - 0.65, LPDA-0.72)
- Şekil 7-e: RCX sınıfına ait tespit (Güven skoru: Normal sınıf-0.79, RCX-0.92)
- Şekil 7-f: ELMCA sınıfına ait tespit(Güven skoru: Normal sınıf-0.76, ELMCA-0.81)
- Şekil 7-g: NLMCA sınıfına ait tespit (Güven skoru: Normal sınıf -0.83, NLMCA-0.93)
- Şekil 7-h: RBCX sınıfına ait tespit (Güven skoru: Normal sınıf-0.80, RBCX-0.85)
- Şekil 7-i: DLAD sınıfına ait tespit (Güven skoru: Normal sınıf-0.87, DLAD-0.83)
- Şekil 7-j: LRCA sınıfına ait tespit (Güven skoru: Normal sınıf-0.60, LRCA-0.88)
- Şekil 7-k: NRCA sınıfına ait tespit (Güven skoru: Normal sınıf -0.66, NRCA-0.66)
- Şekil 7-l: DLCX sınıfına ait tespit (Güven skoru: Normal sınıf-0.69, DLCX-0.77)

7.TARTIŞMA

Bu araştırmanın temel amacı, KBTA görüntülerinde koroner artere ait sık görülen varyasyonları tespit edebilen derin öğrenme tabanlı bir sistem geliştirmektir. Bu sistemin, YOLOv10 mimarisinin sağladığı hız ve doğruluk dengesini kullanarak, klinik ortamlarda uygulanabilir bir çözüm sunması hedeflenmektedir. Ayrıca, veri seti hazırlığı, model eğitimi ve değerlendirme süreçleri titizlikle ele alınarak, önerilen yöntemin güvenilirliği ve etkinliği değerlendirilmiştir.

Bu çalışmada, KBTA görüntülerinde koroner arter varyasyonların tespiti için önerilen YOLOv10 tabanlı yöntemin sonuçları sunulmakta ve elde edilen bulgular detaylı bir şekilde tartışılmaktadır. Modelin performansı, kesinlik(precision), duyarlılık(recall), F1 skoru, özgüllük (specificity) ve Ortalama Doğruluk (mean Average Precision, mAP) gibi çeşitli metrikler kullanılarak değerlendirilmiştir. Elde edilen sonuçlar, önerilen yöntemin güçlü ve zayıf yönlerini vurgulamak için mevcut yöntemlerle karşılaştırılmıştır. Ayrıca, bulguların klinik uygulamalardaki etkileri tartışılmış ve modelin erken teşhis süreçlerini destekleme ve karar verme süreçlerini iyileştirme potansiyeline dikkat çekilmiştir.

Son yıllarda derin öğrenme tabanlı yöntemler, özellikle görüntü işleme alanında kalp hastalıklarının otomatik olarak analiz edilmesi üzerinde durmuşlardır. Koroner arter varyasyonlarının tespiti ve sınıflandırılması, kardiyovasküler hastalıkların doğru teşhisi açısından kritik öneme sahiptir.

YOLO tabanlı modeller, anjiyografik ve tomografik görüntülerde koroner arter dallarının hızlı ve yüksek doğrulukta tespiti için tercih edilmektedir. Özellikle YOLOv5 ve sonrası sürümler, arter segmentlerinin gerçek zamanlı algılanmasında etkin sonuçlar göstermiştir. Bu modeller, varyasyonların sınıflandırılması için ön aşama olarak dal segmentasyonunu sağlamaktadır. Segmentasyon görevlerinde ise, U-Net ve türevleri geniş çapta uygulanmaktadır. Bu mimariler, koroner arterlerin ince dallarını detaylı şekilde ayırarak varyasyon analizine zemin hazırlar. Ayrıca, ResNet ve Vision Transformer (ViT) gibi derin CNN ve transformer tabanlı modeller, sınıflandırma aşamasında yüksek performans sergilemektedir (95).

Bununla birlikte, çalışmalar genellikle anjiyografi ve bilgisayarlı tomografi (CT) görüntüleri üzerinde yoğunlaşmaktadır. Veri kalitesi ve sınıf dengesizliği, modellerin başarısını etkileyen başlıca zorluklar arasında yer almakta, bu sebeple veri artırma ve ağırlıklı kayıp fonksiyonları

gibi teknikler kullanılmaktadır. Bu gibi durumlar YOLO10v gibi daha yüksek model ve bunların alt modellerine ihtiyaç doğurmuştur (111).

Singh ve Rajesh, kalp hastalığı olan hastaları kümelere ayırmak için genişletilmiş K-means kümeleme yöntemini kullanmıştır. Kümeleme, algoritmanın başlangıç noktasını seçme sorunuyla karşılaşmakta ve bu hem bulunan küme sayısı hem de merkezleri açısından sonuçları etkilemektedir. Bu makalede, K-means kümeleme algoritmasını geliştirme yöntemleri tartışılmıştır (114). Liu ve arkadaşları, en yakın ters komşulara (RNN-LDH) dayalı hiyerarşik yerel yoğunluk kümeleme algoritmasını önermiştir. En yakın ters diyagramı oluşturarak ve kullanarak, genişletilmiş çekirdek bölgeler birincil kümeler olarak bulunmuştur. Her örneğin yoğunluğunu hesaplamak için yeni bir yerel yoğunluk kriteri tanımlanmıştır (115). Geleneksel yöntemlerin aksine, YOLOv10 derin öğrenme ve gelişmiş özellik çıkarım mekanizmalarını kullanarak, karmaşık KBTA görüntü veri setlerini yüksek doğrulukla analiz edebilmektedir. Veri setindeki çeşitlilik ve anotasyon kalitesi, modelin anormal ya da varyatif bölgeleri normal kalp anatomisinden ayırt edebilme yeteneğini güçlendirmektedir.

Balasubramani, M ve ark. yakın zamanda yapay zeka temelli bir çalışma yayınladılar. Bu çalışmada araştırmacılar, ekokardiyografik görüntülerde sol ventrikül (LV) segmentasyonunu otomatikleştirmek amacıyla YOLOv8 tabanlı bir derin öğrenme modeli geliştirmişlerdir. Mevcut yöntemlerin sınırlamalarını aşmayı hedefleyen bu yaklaşım; sınıf dengesizliği, anatomik farklılıklar, patolojik varyasyonlar, düşük kaliteli görüntüler ve artefaktlar gibi yaygın zorluklara karşı dayanıklı, doğru ve genellenebilir bir çözüm sunmayı amaçlamaktadır. Ek olarak, modelin klinik uygulamalara entegrasyonunu kolaylaştırmak adına hızlı ve hesaplama açısından verimli bir yapı kurgulanmıştır. Çalışma sonucunda yüksek doğrulukla sol ventriküle segmentasyonu yapmayı başardıklarını bildirmişlerdir (116).

Yapılan özgün bir çalışmada katater anjiyografik görüntüleri kullanarak ARCADE veri seti üzerinden koroner damar segmentasyonu ve darlık tespiti görevlerinde YOLOv8, YOLOv9 ve YOLOv11 modellerinin performanslarını karşılaştırmalı olarak değerlendirmiştir. Elde edilen bulgulara, YOLO tabanlı mimarilerin tıbbi görüntü segmentasyonu bağlamında hem yüksek doğruluk hem de gerçek zamanlı işlem kabiliyeti sunduğunu ortaya koymaktadır. Modeller arasında, YOLOv11-X mimarisi her iki görevde de istikrarlı biçimde en yüksek F1 skorlarına ulaşarak üstün performans sergilemiştir. Bu durum, YOLOv11'e entegre edilen mimari iyileştirmelerin çeşitli anatomik yapı ve görüntüleme koşullarına etkin uyum sağladığını göstermektedir. Özellikle darlık tespiti görevinde, YOLOv11-X'in UNet++ ve DeepLab v3+ gibi yaygın olarak kullanılan klasik segmentasyon yöntemlerine kıyasla daha yüksek performans sergilemesi, söz konusu modelin bilgisayar destekli tanı sistemlerinde (CAD) güçlü

ve etkili bir alternatif olarak değerlendirilebileceğini ortaya koymaktadır. Yaptığımız çalışmada da benzer şekilde koroner arter varyasyonların tespitinde Yolov10-X modeli en yüksek kesinlik (precision) değeri ile ön plana çıkmaktadır (39).

Yanjun Li, ve ark. 2024 yılında temel amacı; anjiyografik görüntülerdeki küçük ve uzak damar yapılarını daha etkin biçimde tespit edebilmek için, "Hessian Matrisi" tabanlı çok ölçekli filtreleme ile görüntü füzyonunu birleştiren yeni bir ön işleme yöntemi geliştirmek olan bir çalışma yayınladılar. Yazarlar, bu yöntemle damar kalibrasyonlarını daha belirgin hale getirerek derin öğrenme tabanlı modellerin öğrenme kapasitesini artırmayı ve böylece koroner arter görüntülerinde daha başarılı segmentasyon ve tespit sonuçları elde etmeyi hedeflemişlerdir. Çalışmanın bazı sınırlamalarına rağmen, önerilen yöntem koroner arter stenozu tespitinde önemli ilerlemeler kaydetmiştir. Ancak özellikle yandallar ve karmaşık anjiyografik görüntülerde modelin doğruluk ve dayanıklılığının artırılması için ek araştırmalara ihtiyaç vardır. Bu doğrultuda, veri çeşitliliğinin artırılması, daha gelişmiş model sürümlerinin kullanılması ve eğitim sürecinin iyileştirilmesi gibi çalışmaların devam ettirilmesi önem taşımaktadır (117).

Yine Bazı araştırmacılar koroner BTA görüntüleri kullanarak koroner arter segmentasyonu değerlendiren yapay zeka çalışması sundular. Elle tanımlanan varsayımlar yerine, gözetimli öğrenme yaklaşımıyla açıklamalı eğitim verilerinden öğrenilen modeller aracılığıyla damar segmentasyonu gerçekleştirmeyi amaçladıklarını bildirdiler. Özellikle şekil ve görünüm bilgilerini bir araya getiren bu yöntem, küçük çaplı ve düşük kontrastlı damar yapılarını daha güvenilir biçimde segmentlemeye yönelik olarak tasarlanmıştır. Çalışmanın sonunda elde edilen bulgular ile geliştirilen yaklaşımın, koroner BTA verileri üzerinden arter segmentasyonu ve lümen görseelliği gibi karmaşık anatomik yerlerde, hem nicel metrikler hem de görsel incelemeler yoluyla elde edilen yüksek başarı düzeyiyle doğrulanmıştır (118).

Isaac Shiri ve arkadaşları tarafından 2025 yılında yayımlanan bir çalışmada, nadir görülmesine rağmen ani kardiyak ölüm riski taşıyan anormal aortik koroner arter çıkışı (AAOCA) anomalisinin, üç boyutlu koroner BT anjiyografi (3B-KBTA) görüntüleri üzerinden otomatik olarak tespit edilmesi ve anatomik özelliklerine göre sınıflandırılması amacıyla yapay zeka tabanlı bir tarama aracı geliştirildiği bildirilmiştir. Araştırmacıların geliştirdiği sistem, iki aşamalı bir derin öğrenme algoritması kullanarak ilk aşamada kalp ve damar yapılarının segmentasyon ve görüntü kırpma işlemlerini gerçekleştirmekte, ikinci aşamada ise AAOCA varlığını tespit ederek anormal damarın sağ (R-AAOCA) ya da sol (L-AAOCA) çıkışlı olup olmadığını ve anatomik risk düzeyini (yüksek/düşük) belirlemektedir. Klinik değerlendirme sürecine entegre edilebilecek şekilde tasarlanan bu yapay zeka temelli araç, hekimlere gerçek

zamanlı karar desteği sağlayarak, özellikle nadir görülen bu anomalinin tanısında deneyim eksikliği bulunan merkezlerde AAOCA'nın erken ve doğru şekilde saptanmasına katkı sağlamayı ve hasta yönetimini iyileştirmeyi amaçlamaktadır. AAOCA gibi nadir ancak klinik olarak hayati öneme sahip koroner arter anomalilerini üç boyutlu koroner BT anjiyografi (3B-CCTA) görüntülerinde yüksek doğrulukla tespit edebildiği gösterilmiştir (119).

Yukarıda detaylı şekilde yazıldığı gibi kardiyovasküler hastalıkları ya da normal anatomi tespitinde YOLO başta olmak üzere yapay zeka temelli birçok çalışma olduğunu bilmekteyiz. Bu çalışmaların klinik uygulamaya ve görüntüleme tekniklerine entegre edildiğini gün geçtikçe daha sık karşılaşıyoruz. Sonuç olarak, koroner arter varyasyonlarının otomatik analizi için derin öğrenme temelli çoklu model yaklaşımları geliştirilmekte olup, YOLO ve U-Net tabanlı modeller öncü konumdadır. İleriye dönük çalışmaların, 3D görüntü işleme ve multimodal veri entegrasyonuna odaklanması beklenmektedir.

Yaptığımız kapsamlı literatür taramasında KBTA görüntüleri üzerinden YOLOv10 modelini koroner arter varyasyonlarının tespitini ve sıklığını yapan bir çalışmaya rastlamadık. Yine aynı doğrultuda alt modelleri (YOLOv10-X,L ,N vb) metrik değerleri üzerinden kıyaslayan ya da tespit etme başarı oranını öne süren herhangi bir çalışma olmadığını bilmekteyiz . Ayrıca koroner arterler varyasyonlarını bu denli detaylı sınıflayarak örnekler halinde radyolojik görüntüler üzerinden tespit etme doğruluğunu irdeleyen yapay zeka temelli ilk çalışma olduğunu bildirmek isteriz. Bu çalışmada vardığımız sonuçlardan biri de bundan önceki yayınlanan koroner arter yapay zeka çalışmalarına katkı sağlayacağını ve bazı eksiklikleri de ortaya koyduğunu düşünmekteyiz. Diğer organ anatomilerin tespitinde ve bu organlara ait varyatif-anomali bulgularını ortaya koymada örnek bir çalışma olacağını ümit ediyoruz.

Çalışmamızda YOLOv10-X modelinde en yüksek precision (%92.0) değerine ulaşılmış olmasına rağmen, mAP50 değeri (%26.0) diğer modellere göre oldukça düşüktür. Bunun temel nedenleri YOLOv10-X modelinde precision değeri yüksek olduğundan, yanlış pozitiflerin sayısı düşüktür. Ancak bu, modelin yalnızca yüksek doğruluk oranıyla sınırlı sayıda pozitif örneği tahmin ettiği anlamına gelebilir. Bu durum, modelin duyarlılığını (Recall) ciddi şekilde düşürerek (%24.2) mAP50 değerinin düşük çıkmasına yol açabilir.

YOLOv10-X modeli, yalnızca çok yüksek doğrulukla tahmin ettiği nesneleri pozitif olarak sınıflandırabilir. Bu durum, bazı nesnelerin tamamen gözden kaçmasına ve mAP50'nin düşmesine neden olabilir.

IoU Hesaplamasında Yetersizlik: mAP50, tahmin edilen kutuların gerçek değerli kutularla örtüşme oranını dikkate alır. YOLOv10-X modeli, düşük örtüşme oranlarına sahip tahminler yapıyor olabilir ve bu da mAP50 değerini düşürür.

YOLOv10-L modeli, %80.5 ile en yüksek mAP50 değerine ulaşmıştır. Bunun nedeni YOLOv10-L modeli, precision (%84.8) ve recall (%75.6) değerleri arasında iyi bir denge kurmuştur. Bu durum hem yanlış pozitiflerin düşük olmasını hem de doğru pozitiflerin büyük bir kısmının tespit edilmesini sağlar ve IoU hesaplamalarındaki başarıyı artırır. YOLOv10-L, tahmin doğruluğu ve genel genelleme performansı açısından iyi bir optimizasyona sahiptir. Eğitim ve doğrulama sırasında daha düşük kayıplara ulaşmış olması (%1.18 minimum eğitim kutu kaybı), modelin daha doğru tahminler yapmasını sağlamış olabilir.

IoU Uyumluluğu: **YOLOv10-L**, gerçek değerli sınır kutularıyla yüksek düzeyde örtüşen tahminler ürettiği için olabilir. Bu, mAP50'nin yüksek çıkmasının temel nedenlerinden biridir.

YOLOv10-X modeli, yüksek precision sağlarken düşük recall değerinden dolayı mAP50'de başarılı olamamıştır. Neden olarak, modelin aşırı seçici davranarak yalnızca çok güvenli tahminler yapmasından kaynaklandığını düşünmekteyiz .

YOLOv10-L'nin Avantajı ise, dengeli precision ve recall değerleri sayesinde mAP50'de en iyi performansı göstermiştir. Bu model, IoU uyumluluğunu optimize ederken aynı zamanda genel doğrulukta yüksek bir performans sergilemiştir. Sonuç olarak, **YOLOv10** varyantları arasında seçim yapılırken, uygulama ihtiyaçlarına göre precision, recall, ve mAP değerlerinin dengesi dikkate alınmalıdır. Örneğin, bir uygulamada yüksek doğruluk isteniyorsa **YOLOv10-X**, ancak genel performans ve genelleme yeteneği gerekiyorsa **YOLOv10-L** tercih edilebilir.

Tüm sınıflar için güven skoru %89.9 seviyesine geldiğinde kesinlik değerinin 1.00'e ulaştığını farkettik. Bu durum modelin yüksek güven skoru eşiklerinde daha az yanlış pozitif tahmin yaptığını ve doğru tahminlerin oranının arttığını gösterir. Güven skoru düşük olduğunda (0.0 ile 0.3 arası), birçok sınıf için kesinlik değerinde ciddi dalgalanmalar oldu. Bu durum, düşük güven skoru seviyelerinde modelin tahminlerinde daha fazla belirsizlik yaşadığını ve yanlış pozitif oranlarının arttığını gösterir. Modelin optimal performans göstermesi için uygun bir güven (confidence) skor eşiği belirlenmelidir. Örneğin, %0.9 güven (confidence) skor eşiği, yanlış pozitifleri en aza indirerek yüksek kesinlik sağlamak için iyi bir seçim olabilir. Ancak, bu durum duyarlılığı (recall) düşürebileceği için dikkatli bir dengeleme yapılmalıdır.

MYB ve benzeri düşük performans gösteren sınıflar için anotasyon kalitesinin artırılması, veri artırma (data augmentation) veya sınıf dengesizliği gibi problemleri çözmeye yönelik ek

alışmalar yapılabilir. Özellikle düşük performanslı sınıflarda daha fazla veri işleme ve model optimizasyonu gerektirebilir.

Boxx Loss OM , Class Loss OM ve DFL Loss OM değerlerini (Tablo 1 ‘de) göz önünde bulundurulduğunda Yolov10-L modeli tüm eğitim loss’larda en düşük değere sahiptir. Bu durum modelin öğrenme aşamasında en verimli biçimde hataları minimize ettiğini göstermektedir.

Çalışmamızda üzerinde durulması gereken bazı kısıtlılıklar mevcuttur;

Kullanılan veri setinin sınırlı sayıda örnek ve belli başlı varyasyon tiplerini içermesi, modelin genelleme yeteneğini ve gerçek klinik ortamlarındaki performansını sınırlayabilir. Bundan sonraki çalışmalarda koroner arter anomalileri de içeren daha geniş kapsamlı bir varyasyonlu olguları dahil edilmesi bu kısıtlılıkların ortadan kaldırılıcağının öngörüsünü taşıyoruz

YOLOv10-X modelinin yüksek precision değerine rağmen düşük mAP50 skoru, modelin sadece yüksek güvenilirlikteki tahminlere odaklanması ve bazı doğru pozitiflerin kaçırılması riskini taşımaktadır. Modelin düşük recall oranı, özellikle küçük veya karmaşık damar yapılarında tespit yetersizlikler yaşanmasına yol açabilir ve bu da klinik uygulamalarda kritik olayların gözden kaçmasına neden olabilir. IoU hesaplamalarında ve sınır kutu optimizasyonlarında yaşanan yetersizlikler, modelin gerçek nesne sınırlarını doğru tespit etme oranını olumsuz etkileyebilir. Veri anotasyon kalitesinin sınırlı olması ve sınıf dengesizliği, özellikle düşük performans gösteren sınıfların tespitinde modelin başarısını

kısıtlayabilir.Çalışmamızda göreceli olarak tek modelli ve 2D görüntüler üzerinde odaklanmış olup, 3D ve multimodal görüntüleme teknikleriyle entegrasyonun yapılmamış olması, daha kapsamlı ve klinik açıdan uygun bir çözüm geliştirilmesini engelleyebilir.

8. SONUÇ ve ÖNERİLER


Bu çalışmada, YOLO-v10 modeli, KBTA görüntüleri kullanılarak koroner arter varyasyonların tespiti ve sınıflandırılması için başarıyla uygulanmıştır. Yöntem, veri setinin notasyonu ve bölünmesi ile başlayan, ardından modelin eğitimi, doğrulaması ve test edilmesiyle devam eden sağlam bir süreç içermiştir. Sonuçlar, modelin hem normal hem de varyatif koroner arter segmentlerini tespit etmede yüksek doğruluk ve güvenilirlik sağladığını göstermiştir.

Modelin performansı oldukça başarılı bulunmuştur. Kesinlik (Precision) ve mAP gibi metrikler, modelin doğru tahminler yaparken aynı zamanda verimliliğini koruyabildiğini ortaya koymuştur. Kesinlik (Precision), Duyarlılık, F1 skoru ve mAP gibi metrikler üzerinden yapılan detaylı analizler, YOLO-v10'un tıbbi görüntüleme uygulamalarındaki güçlü yönlerini açıkça ortaya koymuştur. Sonuçların görselleştirilmesi, modelin varyasyonları yerelleştirme yeteneğini ve klinik uygulamalar için değerli bir araç olma potansiyelini doğrulamıştır. Kesinlik-güven eğrisi ve sınır kutularının görselleştirilmesi, modelin farklı güven eşiklerinde etkin bir şekilde çalışabildiğini ve gerçek dünya tıbbi senaryolarına kolayca uyarlanabileceğini göstermiştir. Genel olarak, bu çalışma, YOLO-v10'un koroner arter varyasyonlarının tespiti ve sınıflandırılmasında ileri düzey bir araç olarak potansiyelini ortaya koymuştur.


Modelin tıbbi tanı süreçlerine entegrasyonu; koroner arter varyasyonların tespitinde, normal anatomik seyirli ve yapıdaki koroner arterin kalibrasyon belirlenmesinde klinik sahada iz bırakacağını öngörmekteyiz. Ayrıca varyasyonların erken ve doğru teşhisi , özellikle diagnostik –terapötik katater anjiyografi görüntüleme işlemlerinde yol haritası çizmede , işlem esnasında karar verme aşamasının hız kazanmasında ve dolayısıyla gelişebilecek komplikasyonları önlemede önemli katkılar sunacağını umuyoruz.

Gelecekteki çalışmalar, veri setinin genişletilmesi, modelin temsil gücü düşük sınıflar için daha fazla optimize edilmesi ve farklı tıbbi görüntüleme alanlarında uygulanması üzerine odaklanabilir, böylece modelin etkisi daha da genişletilebilir.


9. OLGU ÖRNEKLERİ




1.Olgu : Göğüs ağrısı nedeniyle KBTA çekilen 45 yaşındaki erkek hastada insidental olarak tespit edilen RCA'dan orjin alan LCx varyasyonunu görmekteyiz. Sağda tanımlı varyasyonun ve normal koroner arterlerin Yolov10 yapay zeka algoritması ile tespit edilen sınır kutuları ve güven skoru (RCx: 0.92) gösterilmektedir.




2.Olgu : Ailede genç yaşta ani kardiyak ölüm nedeniyle KBTA istenen çekilen 32 yaşındaki kadın olguda sağ koroner sinüste ve normal trasesinde RCA izlenmediğini görmekteyiz. Sağda tanımlı varyasyonun ve normal koroner arterlerin Yolov10 yapay zeka algoritması ile tespit edilen sınır kutuları ve güven skoru (NRCA: 0.59) gösterilmektedir.




3.Olgu : Atipik göğüs ağrısı nedeniyle KBTA çekilen 49 yaşındaki erkek hastada tespit edilen bir koroner seyir varyasyonu olan miyokardiyal köprüleşme(MYB)’ yi görmekteyiz. Tanımlı varyasyonun ve normal koroner arterlerin Yolov10 yapay zeka algoritması ile tespit edilen sınır kutuları ve güven skoru (MYB: 0.73) gösterilmektedir.



4.Olgu: NSTMI ön tanısı ile hastaneye başvuran 53 yaşındaki kadın olguda çekilen KBTA görüntülerinde LMCA'nın izlenmediği LAD ve LCx orifislerin farklı aortik segmentlerden orjin aldığı gösterilmektedir. Tanımlı varyasyonun ve normal koroner arterlerin Yolov10 yapay zeka algoritması ile tespit edilen sınır kutuları ve güven skoru (NLMACA:0.93) gösterilmektedir.(NSTMI : ST derivasyon elevasyonu olmayan miyokardiyal infarktüsü)



5.Olgu : Göğüs ağrısı nedeniyle KBTA çekilen 62 yaşındaki kadın hastada insidental olarak tespit edilen Sol aortik sinüsten orjin alan RCA varyasyonunu görmekteyiz. Tanımlı varyasyonun ve normal koroner arterlerin Yolov10 yapay zeka algoritması ile tespit edilen sınır kutuları ve güven skoru (LRCA: 0.88) gösterilmektedir.



6.Olgu: Sonradan Miyokardit tanısı alan 35 yaşındaki erkek olguda koroner arter patolojilerin ekartasyonu için çekilen KBTA görüntülerde insidental olarak tespit edilen LAD duplikasyonu görmekteyiz. Tanımlı varyasyonun ve normal koroner arterlerin Yolov10 yapay zeka algoritması ile tespit edilen sınır kutuları ve güven skoru (DLAD: 0.83) gösterilmektedir.

10. KAYNAKLAR

1. Aldallal A, Al-Moosa AAA, editors. Using data mining techniques to predict diabetes and heart diseases. 2018 4th international conference on Frontiers of signal processing (ICFSP); 2018: IEEE.
2. Bou Rjeily C, Badr G, Hajjarm El Hassani A, Andres E. Medical data mining for heart diseases and the future of sequential mining in medical field. Machine learning paradigms: Advances in data analytics: Springer; 2018. p. 71-99.
3. Shaji SP, editor Prediction and diagnosis of heart disease patients using data mining technique. 2019 international conference on communication and signal processing (ICCSP); 2019: IEEE.
4. Kotu V, Deshpande B. Data science: concepts and practice: Morgan Kaufmann; 2018.
5. Wang A, Chen, Hui, Liu, Lihao, Chen, Kai, Lin, Zijia, Han, Jungong Ding, Guiguang Yolov10: Real-time end-to-end object detection. arXiv preprint arXiv:14458. 2024.
6. Zhuang Z, Liu G, Ding W, Raj ANJ, Qiu S, Guo J, et al. Cardiac VFM visualization and analysis based on YOLO deep learning model and modified 2D continuity equation. Computerized Medical Imaging and Graphics. 2020;82:101732.
7. Pacal I, Karaman A, Karaboga D, Akay B, Basturk A, Nalbantoglu U, et al. An efficient real-time colonic polyp detection with YOLO algorithms trained by using negative samples and large datasets. 2022;141:105031.
8. Tan L, Huangfu T, Wu L, Chen W. Comparison of RetinaNet, SSD, and YOLO v3 for real-time pill identification. BMC medical informatics and decision making. 2021;21:1-11.
9. Chen J-L, Cheng L-H, Wang J, Hsu T-W, Chen C-Y, Tseng L-M, et al. A YOLO-based AI system for classifying calcifications on spot magnification mammograms. Biomedical engineering online. 2023;22(1):54.
10. Baccouche A, Garcia-Zapirain B, Olea CC, Elmaghraby AS. Breast Lesions Detection and Classification via YOLO-Based Fusion Models. Computers, Materials & Continua. 2021;69(1).
11. Abdulrahman S. ENHANCING BRAIN TUMOUR DIAGNOSIS WITH AI: A COMPARATIVE ANALYSIS OF RESNET AND YOLO ALGORITHM FOR TUMOUR CLASSIFICATION IN MRI SCANS. 2024.
12. Liu C, Hu S-C, Wang C, Lafata K, Yin F-F. Automatic detection of pulmonary nodules on CT images with YOLOv3: development and evaluation using simulated and patient data. Quantitative Imaging in Medicine and Surgery. 2020;10(10):1917.
13. Petersen SE, Abdulkareem M, Leiner T. Artificial intelligence will transform cardiac imaging—opportunities and challenges. Frontiers in cardiovascular medicine. 2019;6:133.
14. Bernard O, Lalande A, Zotti C, Cervenansky F, Yang X, Heng P-A, et al. Deep learning techniques for automatic MRI cardiac multi-structures segmentation and diagnosis: is the problem solved? IEEE transactions on medical imaging. 2018;37(11):2514-25.
15. Zhang N, Yang G, Gao Z, Xu C, Zhang Y, Shi R, et al. Deep learning for diagnosis of chronic myocardial infarction on nonenhanced cardiac cine MRI. Radiology. 2019;291(3):606-17.
16. Camara O, Mansi T, Pop M, Rhode K, Sermesant M, Young A. Statistical Atlases and Computational Models of the Heart: Imaging and Modelling Challenges: Third International Workshop, STACOM 2012, Held in Conjunction with MICCAI 2012, Nice, France, October 5, 2012, Revised Selected Papers: Springer; 2013.
17. Leonardi B, Taylor AM, Mansi T, Voigt I, Sermesant M, Pennec X, et al. Computational modelling of the right ventricle in repaired tetralogy of Fallot: can it provide insight into patient treatment? European Heart Journal—Cardiovascular Imaging. 2013;14(4):381-6.

18. Zellweger MJ, Brinkert M, Bucher U, Tsirkin A, Ruff P, Pfisterer ME. A new memetic pattern based algorithm to diagnose/exclude coronary artery disease. *International journal of cardiology*. 2014;174(1):184-6.
19. Khamis H, Zurakhov G, Azar V, Raz A, Friedman Z, Adam D. Automatic apical view classification of echocardiograms using a discriminative learning dictionary. *Medical image analysis*. 2017;36:15-21.
20. Narula S, Shameer K, Salem Omar AM, Dudley JT, Sengupta PP. Machine-learning algorithms to automate morphological and functional assessments in 2D echocardiography. *Journal of the American College of Cardiology*. 2016;68(21):2287-95.
21. Sanchez-Martinez S, Duchateau N, Erdei T, Kunszt G, Aakhus S, Degiovanni A, et al. Machine learning analysis of left ventricular function to characterize heart failure with preserved ejection fraction. *Circulation: cardiovascular imaging*. 2018;11(4):e007138.
22. Tabassian M, Alessandrini M, Herbots L, Mirea O, Pagourelas ED, Jasaityte R, et al. Machine learning of the spatio-temporal characteristics of echocardiographic deformation curves for infarct classification. *The international journal of cardiovascular imaging*. 2017;33:1159-67.
23. Larroza A, Materka A, López-Lereu MP, Monmeneu JV, Bodí V, Moratal D. Differentiation between acute and chronic myocardial infarction by means of texture analysis of late gadolinium enhancement and cine cardiac magnetic resonance imaging. *European journal of radiology*. 2017;92:78-83.
24. Lenstrup M, Kjaergaard J, Petersen C, Kjaer A, Hassager C. Evaluation of left ventricular mass measured by 3D echocardiography using magnetic resonance imaging as gold standard. *Scandinavian journal of clinical and laboratory investigation*. 2006;66(8):647-58.
25. Vaid A, Johnson KW, Badgeley MA, Somani SS, Bicak M, Landi I, et al. Using deep-learning algorithms to simultaneously identify right and left ventricular dysfunction from the electrocardiogram. *Cardiovascular Imaging*. 2022;15(3):395-410.
26. Neelakantan Saikrishnan GK, Sawaya FJ, Lerakis S, Yoganathan AP. Accurate assessment of aortic stenosis. *Circulation*. 2014;129(2):244-53.
27. Japp AG, Gulati A, Cook SA, Cowie MR, Prasad SK. The diagnosis and evaluation of dilated cardiomyopathy. *Journal of the American college of cardiology*. 2016;67(25):2996-3010.
28. Shrivastava S, Cohen-Shelly M, Attia ZI, Rosenbaum AN, Wang L, Giudicessi JR, et al. Artificial intelligence-enabled electrocardiography to screen patients with dilated cardiomyopathy. *The American Journal of Cardiology*. 2021;155:121-7.
29. Elias P, Poterucha TJ, Rajaram V, Moller LM, Rodriguez V, Bhawe S, et al. Deep learning electrocardiographic analysis for detection of left-sided valvular heart disease. *Journal of the American College of Cardiology*. 2022;80(6):613-26.
30. Kwon JM, Lee SY, Jeon KH, Lee Y, Kim KH, Park J, et al. Deep learning-based algorithm for detecting aortic stenosis using electrocardiography. *Journal of the American Heart Association*. 2020;9(7):e014717.
31. Lima JL, Macêdo D, Zanchettin C, editors. Heartbeat anomaly detection using adversarial oversampling. 2019 International Joint Conference on Neural Networks (IJCNN); 2019: IEEE.
32. Kavitha M, Gnaneswar G, Dinesh R, Sai YR, Suraj RS, editors. Heart disease prediction using hybrid machine learning model. 2021 6th international conference on inventive computation technologies (ICICT); 2021: IEEE.
33. Bharti R, Khamparia A, Shabaz M, Dhiman G, Pande S, Singh PJCi, et al. Prediction of heart disease using a combination of machine learning and deep learning. 2021;2021(1):8387680.

34. Choi AD, Marques H, Kumar V, Griffin WF, Rahban H, Karlsberg RP, et al. CT evaluation by artificial intelligence for atherosclerosis, stenosis and vascular morphology (CLARIFY): a multi-center, international study. *Journal of Cardiovascular Computed Tomography*. 2021;15(6):470-6.
35. Lin A, Manral N, McElhinney P, Killekar A, Matsumoto H, Kwiecinski J, et al. Deep learning-enabled coronary CT angiography for plaque and stenosis quantification and cardiac risk prediction: an international multicentre study. *The Lancet Digital Health*. 2022;4(4):e256-e65.
36. Knott KD, Seraphim A, Augusto JB, Xue H, Chacko L, Aung N, et al. The prognostic significance of quantitative myocardial perfusion: an artificial intelligence-based approach using perfusion mapping. *Circulation*. 2020;141(16):1282-91.
37. Zeleznik R, Foldyna B, Eslami P, Weiss J, Alexander I, Taron J, et al. Deep convolutional neural networks to predict cardiovascular risk from computed tomography. *Nature communications*. 2021;12(1):715.
38. Eisenberg E, McElhinney PA, Commandeur F, Chen X, Cadet S, Goeller M, et al. Deep learning-based quantification of epicardial adipose tissue volume and attenuation predicts major adverse cardiovascular events in asymptomatic subjects. *Circulation: Cardiovascular Imaging*. 2020;13(2):e009829.
39. Díaz-Gaxiola E, Yee-Rendon A, Vega-Lopez IF, Campos-Leal JA, García-Aguilar I, López-Rubio E, et al. Experimental Assessment of YOLO Variants for Coronary Artery Disease Segmentation from Angiograms. *Electronics*. 2025;14(13):2683.
40. Ku J, Lee Y-H, Shin J, Lee IK, Kim H-W. Mpsseg: Multi-phase strategy for coronary artery segmentation. *arXiv preprint arXiv:2311.10306*. 2023.
41. Zhou Z, Rahman Siddiquee MM, Tajbakhsh N, Liang J, editors. Unet++: A nested u-net architecture for medical image segmentation. *Deep learning in medical image analysis and multimodal learning for clinical decision support: 4th international workshop, DLMIA 2018, and 8th international workshop, ML-CDS 2018, held in conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, proceedings 4; 2018: Springer*.
42. He K, Zhang X, Ren S, Sun J, editors. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition; 2016*.
43. Tan M, Le Q, editors. Efficientnet: Rethinking model scaling for convolutional neural networks. *International conference on machine learning; 2019: PMLR*.
44. Singh P, Singh S, Pandi-Jain GS. Effective heart disease prediction system using data mining techniques. *International journal of nanomedicine*. 2018;13(sup1):121-4.
45. Nanehkaran Y, Licai Z, Chen J, Jamel AA, Shengnan Z, Navaei YD, et al. Anomaly Detection in Heart Disease Using a Density-Based Unsupervised Approach. *Wireless Communications and Mobile Computing*. 2022;2022(1):6913043.
46. Šabić E, Keeley D, Henderson B, Nannemann SJA, Society. Healthcare and anomaly detection: using machine learning to predict anomalies in heart rate data. 2021;36(1):149-58.
47. del Monte G, Casanova JC, Guadix JA, MacGrogan D, Burch JB, Pérez-Pomares JM, et al. Differential Notch signaling in the epicardium is required for cardiac inflow development and coronary vessel morphogenesis. *Circulation research*. 2011;108(7):824-36.
48. Grieskamp T, Rudat C, Lüdtke TH-W, Norden J, Kispert A. Notch signaling regulates smooth muscle differentiation of epicardium-derived cells. *Circulation research*. 2011;108(7):813-23.
49. Red-Horse K, Ueno H, Weissman IL, Krasnow MA. Coronary arteries form by developmental reprogramming of venous cells. *Nature*. 2010;464(7288):549-53.
50. Zeini M, Hang CT, Lehrer-Graiwer J, Dao T, Zhou B, Chang C-P. Spatial and temporal regulation of coronary vessel formation by calcineurin-NFAT signaling. *Development*. 2009;136(19):3335-45.

51. Waldo KL, Willner W, Kirby ML. Origin of the proximal coronary artery stems and a review of ventricular vascularization in the chick embryo. *American journal of anatomy*. 1990;188(2):109-20.
52. Vrancken Peeters MP, Gittenberger-de Groot A, Mentink M, Hungerford J, Little C, Poelmann R. The development of the coronary vessels and their differentiation into arteries and veins in the embryonic quail heart. *Developmental dynamics: an official publication of the American Association of Anatomists*. 1997;208(3):338-48.
53. Volz KS, Jacobs AH, Chen HI, Poduri A, McKay AS, Riordan DP, et al. Pericytes are progenitors for coronary artery smooth muscle. *Elife*. 2015;4:e10036.
54. Chen HI, Poduri A, Numi H, Kivela R, Saharinen P, McKay AS, et al. VEGF-C and aortic cardiomyocytes guide coronary artery stem development. *The Journal of clinical investigation*. 2014;124(11):4899-914.
55. Ivins S, Chappell J, Vernay B, Suntharalingham J, Martineau A, Mohun TJ, et al. The CXCL12/CXCR4 axis plays a critical role in coronary artery development. *Developmental cell*. 2015;33(4):455-68.
56. de la Pompa JL, Epstein JA. Coordinating tissue interactions: Notch signaling in cardiac development and disease. *Developmental cell*. 2012;22(2):244-54.
57. Luxán G, Casanova JC, Martínez-Poveda B, Prados B, D'amato G, MacGrogan D, et al. Mutations in the NOTCH pathway regulator MIB1 cause left ventricular noncompaction cardiomyopathy. *Nature medicine*. 2013;19(2):193-201.
58. D'Amato G, Luxán G, de la Pompa JL. Notch signalling in ventricular chamber development and cardiomyopathy. *The FEBS journal*. 2016;283(23):4223-37.
59. D'Amato G, Luxán G, del Monte-Nieto G, Martínez-Poveda B, Torroja C, Walter W, et al. Sequential Notch activation regulates ventricular chamber development. *Nature cell biology*. 2016;18(1):7-20.
60. van den Akker NM, Caolo V, Molin DG. Cellular decisions in cardiac outflow tract and coronary development: an act by VEGF and NOTCH. *Differentiation*. 2012;84(1):62-78.
61. Abdulla R-i, Blew G, Holterman M. Cardiovascular embryology. *Pediatric cardiology*. 2004;25(3):191-200.
62. Ramai D, Lai J, Monzidelis C, Reddy S. Coronary artery development: origin, malformations, and translational vascular reparative therapy. *Journal of cardiovascular pharmacology and therapeutics*. 2018;23(4):292-300.
63. Kini S, Bis KG, Weaver L. Normal and variant coronary arterial and venous anatomy on high-resolution CT angiography. *American Journal of Roentgenology*. 2007;188(6):1665-74.
64. Ozturk E, Duran C, Sonmez G, Sildiroglu HO, Velioglu M, Bozlar U, et al. Arterial supply of the posterior interventricular sulcus: a CT coronary angiographic study. *Surgical and Radiologic Anatomy*. 2011;33(1):27-34.
65. Sundaram B, Patel S, Bogot N, Kazerooni EA. Anatomy and terminology for the interpretation and reporting of cardiac MDCT: part 1, structured report, coronary calcium screening, and coronary artery anatomy. *American Journal of Roentgenology*. 2009;192(3):574-83.
66. Ganga KP, Goyal A, Ojha V, Deepti S, Sharma S, Kumar S. Prevalence rates of congenital coronary anomalies and coronary variations in adult Indian population using dual-source computed tomography coronary angiography: analysis of regional distribution of coronary anomalies and the need for standardized reporting formats. *Indian Journal of Radiology and Imaging*. 2021;31(01):138-49.
67. Sidhu NS, Wander GS, Monga A, Kaur A. Incidence, characteristics and atherosclerotic involvement of coronary artery anomalies in adult population undergoing catheter coronary angiography. *Cardiology research*. 2019;10(6):358.

68. Dodge-Khatami A, Mavroudis C, Backer CL. Congenital Heart Surgery Nomenclature and Database Project: anomalies of the coronary arteries. *The Annals of thoracic surgery*. 2000;69(3):270-97.
69. Angelini P. Normal and anomalous coronary arteries: definitions and classification. *American heart journal*. 1989;117(2):418-34.
70. Angelini P. Coronary artery anomalies: an entity in search of an identity. *Circulation*. 2007;115(10):1296-305.
71. Villa AD, Sammut E, Nair A, Rajani R, Bonamini R, Chiribiri A. Coronary artery anomalies overview: the normal and the abnormal. *World journal of radiology*. 2016;8(6):537.
72. Shriki JE, Shinbane JS, Rashid MA, Hindoyan A, Withey JG, DeFrance A, et al. Identifying, characterizing, and classifying congenital anomalies of the coronary arteries. *Radiographics*. 2012;32(2):453-68.
73. Guenther TM, Sherazee EA, Wisneski AD, Gustafson JD, Wozniak CJ, Raff GW. Anomalous origin of the right coronary artery from the pulmonary artery: a systematic review. *The Annals of thoracic surgery*. 2020;110(3):1063-71.
74. de Jonge G, van Ooijen P, Piers L, Dijkers R, Tio R, Willems T, et al. Visualization of anomalous coronary arteries on dual-source computed tomography. *European radiology*. 2008;18(11):2425-32.
75. JAMES TN. Anatomy of the coronary arteries in health and disease. *Circulation*. 1965;32(6):1020-33.
76. Spindola-Franco H, Grose R, Solomon N. Dual left anterior descending coronary artery: angiographic description of important variants and surgical implications. *American heart journal*. 1983;105(3):445-55.
77. Sajja LR, Farooqi A, Shaik MS, Yarlagadda RB, Baruah DK, Pothineni RB. Dual left anterior descending coronary artery: surgical revascularization in 4 patients. *Texas Heart Institute Journal*. 2000;27(3):292.
78. Chiurlia E, Ligabue G, Ratti C, Modena MG. Type IV dual left anterior descending coronary artery evaluated using multislice computed tomography: anatomy of a rare coronary anomaly. *ITALIAN HEART JOURNAL*. 2003;4(12):900-1.
79. Sawaya FJ, Sawaya JI, Angelini P. Split right coronary artery its definition and its territory. *Texas Heart Institute Journal*. 2008;35(4):477.
80. Angelini P. ACAOS is better revealed by intravascular ultrasonography than by computed tomographic angiography. *Texas Heart Institute Journal*. 2015;42(3):246-7.
81. Kastellanos S, Aznaouridis K, Vlachopoulos C, Tsiamis E, Oikonomou E, Tousoulis D. Overview of coronary artery variants, aberrations and anomalies. *World journal of cardiology*. 2018;10(10):127.
82. STEINBERG I, BALDWIN JS, DOTTER CT. Coronary arteriovenous fistula. *Circulation*. 1958;17(3):372-90.
83. Wong GR, Nelson AJ, Rajwani A. Cor Medusae: Giant Coronary Arteriovenous Fistula. *Revista Espanola de Cardiologia (English ed)*. 2016;69(10):976-7.
84. Zenooz NA, Habibi R, Mammen L, Finn JP, Gilkeson RC. Coronary artery fistulas: CT findings. *Radiographics*. 2009;29(3):781-9.
85. Challoumas D, Pericleous A, Dimitrakaki IA, Danelatos C, Dimitrakakis G. Coronary arteriovenous fistulae: a review. *International Journal of Angiology*. 2014;23(01):001-10.
86. Sun EX, Shi J, Mandell JC. *Core radiology: A visual approach to diagnostic imaging*: Cambridge University Press; 2021.
87. Janai J, Güney F, Behl A, Geiger A. Computer vision for autonomous vehicles: Problems, datasets and state of the art. *Foundations and trends® in computer graphics and vision*. 2020;12(1–3):1-308.

88. Redmon J, Divvala S, Girshick R, Farhadi A, editors. You only look once: Unified, real-time object detection. Proceedings of the IEEE conference on computer vision and pattern recognition; 2016.
89. WHO. World Health Organization (WHO)-The top 10 causes of death. 2021.
90. Redmon J, Farhadi A, editors. YOLO9000: better, faster, stronger. Proceedings of the IEEE conference on computer vision and pattern recognition; 2017.
91. Bochkovskiy A, Wang C-Y, Liao H-YM. Yolov4: Optimal speed and accuracy of object detection. arXiv preprint arXiv:2004.10934. 2020.
92. Jocher G, Stoken A, Borovec J, Changyu L, Hogan A, Diaconu L, et al. ultralytics/yolov5: v3. 1-bug fixes and performance improvements. 2020.
93. Wang C-Y, Bochkovskiy A, Liao H-YM, editors. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition; 2023.
94. Wang A, Chen H, Liu L, Chen K, Lin Z, Han JJAiNIPS. Yolov10: Real-time end-to-end object detection. 2024;37:107984-8011.
95. Mortada MJ, Tomassini S, Anbar H, Morettini M, Burattini L, Sbrollini AJD. Segmentation of anatomical structures of the left heart from echocardiographic images using deep learning. 2023;13(10):1683.
96. Baccouche A, Garcia-Zapirain B, Olea CC, Elmaghraby ASJC, Materials, Continua. Breast Lesions Detection and Classification via YOLO-Based Fusion Models. 2021;69(1).
97. Santos C, Aguiar M, Welfer D, Belloni BJS. A new approach for detecting fundus lesions using image processing and deep neural network architecture based on YOLO model. 2022;22(17):6441.
98. Zeng P, Liu S, He S, Zheng Q, Wu J, Liu Y, et al. TUSPM-NET: A multi-task model for thyroid ultrasound standard plane recognition and detection of key anatomical structures of the thyroid. 2023;163:107069.
99. Tan L, Huangfu T, Wu L, Chen WJBmi, making d. Comparison of RetinaNet, SSD, and YOLO v3 for real-time pill identification. 2021;21:1-11.
100. Li M, Jia J, Lu X, Zhang YJWC, Computing M. A method of surface defect detection of irregular industrial products based on machine vision. 2021;2021(1):6630802.
101. Nawaratne R, Alahakoon D, De Silva D, Yu XJIToII. Spatiotemporal anomaly detection using deep learning for real-time video surveillance. 2019;16(1):393-402.
102. Kamilaris A, Prenafeta-Boldú FXJC, agriculture ei. Deep learning in agriculture: A survey. 2018;147:70-90.
103. Generosi A, Ceccacci S, Mengoni M, editors. A deep learning-based system to track and analyze customer behavior in retail store. 2018 IEEE 8th International Conference on Consumer Electronics-Berlin (ICCE-Berlin); 2018: IEEE.
104. Zhuang Z, Liu G, Ding W, Raj ANJ, Qiu S, Guo J, et al. Cardiac VFM visualization and analysis based on YOLO deep learning model and modified 2D continuity equation. 2020;82:101732.
105. Jadhav R, Patil R, Diwan A, Rathod S, Inamdar M, editors. Aerial object detection and tracking using YOLOv4 and DeepSORT. 2022 International Conference on Industry 40 Technology (I4Tech); 2022: IEEE.
106. Ren S, He K, Girshick R, Sun JJAinips. Faster r-cnn: Towards real-time object detection with region proposal networks. 2015;28.
107. Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, et al., editors. Going deeper with convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition; 2015.
108. Bochkovskiy A, Wang C-Y, Liao H-YMJapa. Yolov4: Optimal speed and accuracy of object detection. 2020.

109. Shriki JE, Shinbane JS, Rashid MA, Hindoyan A, Withey JG, DeFrance A, et al. Identifying, characterizing, and classifying congenital anomalies of the coronary arteries. 2012;32(2):453-68.
110. Nedelcu B, Sgârciu V, Jigau A, editors. Mining medical data. 2018 10th international conference on electronics, computers and artificial intelligence (ECAI); 2018: IEEE.
111. Zreik M, Van Hamersvelt RW, Wolterink JM, Leiner T, Viergever MA, Išgum IJItomi. A recurrent CNN for automatic detection and classification of coronary artery plaque and stenosis in coronary CT angiography. 2018;38(7):1588-98.
112. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. 2017;42:60-88.
113. Smistad E, Østvik A, Salte IM, Leclerc S, Bernard O, Lovstakken L, editors. Fully automatic real-time ejection fraction and MAPSE measurements in 2D echocardiography using deep neural networks. 2018 IEEE International Ultrasonics Symposium (IUS); 2018: IEEE.
114. Singh R, Rajesh EJIJoCS, Engineering. Prediction of heart disease by clustering and classification techniques prediction of heart disease by clustering and classification techniques. 2019.
115. Liu Y, Liu D, Yu F, Ma ZJMPiE. A novel local density hierarchical clustering algorithm based on reverse nearest neighbors. 2019;2019(1):2959017.
116. Balasubramani M, Sung C-W, Hsieh M-Y, Huang EP-C, Shieh J-S, Abbod MF. Automated left ventricle segmentation in echocardiography using YOLO: a deep learning approach for enhanced cardiac function assessment. Electronics. 2024;13(13):2587.
117. Li Y, Yoshimura T, Horima Y, Sugimori H. A preprocessing method for coronary artery stenosis detection based on deep learning. Algorithms. 2024;17(3):119.
118. Schaap M, van Walsum T, Neefjes L, Metz C, Capuano E, de Bruijne M, et al. Robust shape regression for supervised vessel segmentation and its application to coronary segmentation in CTA. IEEE transactions on medical imaging. 2011;30(11):1974-86.
119. Shiri I, Baj G, Mohammadi Kazaj P, Bigler MR, Stark AW, Valenzuela W, et al. AI-based detection and classification of anomalous aortic origin of coronary arteries using coronary CT angiography images. Nature Communications. 2025;16(1):3095.

11. EKLER

11.1. Ek 1: Özgeçmiş

Adı Soyadı: Önder DURMAZ

2004 - Yalova Lisesi

2012 - Manisa Celal Bayar Üniversitesi, Tıp Fakültesi

Yabancı Dil

İngilizce (Orta)

Mesleki Deneyim

2012 – 2013 : Necmettin Erbakan Üniversitesi, Meram Tıp Fakültesi / Kardiyoloji A.B.D.

2013 – 2014 : Muş Devlet Hastanesi / Acil Servis

2014 – 2015 : Muş 112 ASHİ / Komuta Kontrol Merkezi

2015 – 2021 : Muş Halk Sağlığı / 49 Nolu Aile Sağlığı Birimi

2021 – Halen : Binali Yıldırım Üniversitesi, Tıp Fakültesi Mengücek Gazi Eğitim Araştırma Hastanesi / Radyoloji A.B.D.

Bilimsel Yayınlar

- ✓ Durmaz, Ö., Fatihoğlu, E., & Gülmez, A. O. (2022). Magnetic resonance measurement of lateral ventricular diameters in cases of colpocephaly and corpus callosum agenesis. Curr Res MRI, 1(3), 79-81.

- ✓ Durmaz, Ö., Yalçın, G. S., Binay, U. D., Balcı, M. G., Çetin, T., & Ünver, E. (2023). A Rare Coupling: Central Tuberculous and Brucella Co-infection.
- ✓ Durmaz, Ö., Memiş, K. B., Karavaş, E., & İrgül, B. Intradural Venous Sinus Cyst Mimicking Sinus Vein Thrombosis on Magnetic Resonance Venography.
- ✓ Çetin, T., & Durmaz, Ö. (2024). An Assessment of the Impact of Smoking and Vaping During Pregnancy on Placental Dysfunction Using Shear-Wave Elastography. Archives of Basic and Clinical Research.
- ✓ Durmaz, O., Fatihoglu, E., Ozkan, B. H., Memis, K. B., & Aydin, S. (2024). The Ovarian Volume in Girls Presented as Precocious Puberty. Journal of Medical Ultrasound, 10-4103.
- ✓ Kızılgöz, V., Aydın, S., Kantarcı, M., & Durmaz, Ö. (2024). Association between the most superior point of patella-entrance of femoral trochlea distance ratio (SP-ET index) and chondromalacia patella: an investigation via magnetic resonance imaging. Polish Journal of Radiology, 89, e54.
- ✓ Kara, A. V., Inan, H., Durmaz, O., & Ozdemir, R. (2024). The relationship between serum uric acid level and carotid intima-media thickness in hemodialysis patients. Hemodialysis International, 28(4), 397-404.
- ✓ Aydın, S., Durmaz, O., Fatihoglu, E., Kadirhan, O., & Karavas, E. (2024). Assessing Femoral Head Medialization in Developmental Hip Dysplasia Type 1 and Type 2 Hip Separation. Diagnostics, 14(20), 2317.
- ✓ Kantarcı, M., Kızılgöz, V., Terzi, R., Kılıç, A. E., Kabalcı, H., Durmaz, Ö. & Aydın, B. (2023). Evaluating artificial intelligence for a focal nodular hyperplasia diagnosis using magnetic resonance imaging: preliminary findings. Diagnostic and Interventional Radiology (Ankara, Turkey).

Bildiriler

Sözlü Bildiri (Ulusal): Tek umbilikal arterli fetüslerde normal doppler spektral değerleri (TRD-2023).

Poster Bildiri (Ulusal): Patella'nın en üst noktası – Femoral troklea girişi mesafe oranı (SP-ET İndeksi) ve kondromalazi patella arasındaki ilişki; Manyetik rezonans görüntüleme yoluyla bir inceleme (TRD-2023).

İlgi Alanları

Diagnostik Radyoloji

Girişimsel Radyoloji

11.2. Ek 2: Etik Kurul Karar Formu



**ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ GİRİŞİMSSEL OLMAYAN KLİNİK
ARAŞTIRMALAR ETİK KURULU KARAR FORMU**

ÇALIŞMANIN AÇIK ADI	Kardiyak BT Görüntülerinde Sık İzlenen Koroner Arter Varyasyonların Yolov10 Mimarisi Kullanılarak Yapay Zeka Temelli Tespiti ve Sıklığının Araştırılması
KARAR BİLGİLERİ	Girişimsel Olmayan Klinik Araştırma Toplantı No:05 Karar No: 2025-05/04 Tarih: 06/03/2025 Yukarıda bilgileri verilen başvuru dosyası ile ilgili belgeler araştırmanın/çalışmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş ve uygun bulunmuş olup araştırmanın/çalışmanın başvuru dosyasında belirtilen merkezlerde gerçekleştirilmesinde etik ve bilimsel sakınca bulunmadığına toplantıya katılan etik kurul üyelerin oy birliğiyle karar verilmiştir. Klinik Araştırmalar Hakkında Yönetmelik kapsamında yer alan araştırmalar/çalışmalar için Türkiye İlaç ve Tıbbi Cihaz Kurumu'ndan izin alınması gerekmektedir.

EBYU GİRİŞİMSSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU	
ETİK KURULUN ÇALIŞMA ESASI	Klinik Araştırmalar Hakkında Yönetmelik, İyi Klinik Uygulamaları Kılavuzu, Helsinki Bildirgesi
BAŞKANIN UNVANI / ADI / SOYADI:	Doç. Dr. Ertuğrul ERHAN

Unvanı/Adı/Soyadı	Uzmanlık Alanı	Kurumu	Cinsiyet		Araştırma ile ilişki		Katılım *		İmza
Doç. Dr. Ertuğrul ERHAN	Kulak Burun Boğaz	EBYU Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Doç. Dr. Sonay AYDIN	Radyoloji	EBYU Tıp Fakültesi	E ☒	K ☐	E ☒	H ☐	E ☒	H ☐	
Doç. Dr. Ayhan KARS	Kulak Burun Boğaz	EBYU Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Doç. Dr. Ferdane DANIŞMAN KALINDEMİRTAŞ	Fizyoloji	EBYU Tıp Fakültesi	E ☐	K ☒	E ☐	H ☒	E ☒	H ☐	
Dr. Öğr. Üyesi Özlem ÇELİK AYDIN	Tıbbi Farmakoloji	EBYU Tıp Fakültesi	E ☐	K ☒	E ☐	H ☒	E ☒	H ☐	
Dr. Öğr. Üyesi Bülent DABANLIOĞLU	Tıbbi Mikrobiyoloji	EBYU Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Dr. Öğr. Üyesi Betül KALKAN	Kadın Hastalıkları ve Doğum	EBYU Tıp Fakültesi	E ☐	K ☒	E ☐	H ☒	E ☒	H ☐	
Dr. Öğr. Üyesi Tuğba ERKMEN DOĞRU	Tıbbi Biyokimya	EBYU Tıp Fakültesi	E ☐	K ☒	E ☐	H ☒	E ☒	H ☐	
Dr. Öğr. Üyesi Ersan GÜRSOY	Aile Hekimliği	EBYU Tıp Fakültesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	

2

Etik Kurul Başkanı
Unvanı/Adı/Soyadı: Doç. Dr. Ertuğrul ERHAN
İmza:

Not: Etik kurul başkanı, imzasının yer almadığı her sayfaya imza atmalıdır.

11.3. Ek 3: Benzerlik Raporu

[Klasik Görünüme Git](#)

1 / 1: ÖNDER DURMAZ

TEZ

Benzerlik 5%

Bayraklar 1

Yapay Zeka Yazımı --%



Standart Rapor ⓘ

İngilizce Rapor Kullanılamıyor

[Daha Fazla Bilgi](#)

ERZİNCAN

5% Standart

Benzerlik

[Filtreler](#)

Kaynaklar

Çakışan kaynakları göster ⓘ



KARDİYAK BT GÖ
ARTER VARYASYONI
YAPAY ZEKA TEMELİ

1

1



1 Öğrenci makaleleri



(school name not available)

<1%

5 metin blok

123 eşleşen sözcük



2 İnternet



docplayer.biz.tr

<1%

6 metin blok

62 eşleşen sözcük



3 İnternet



avesis.ebyu.edu.tr

<1%

2 metin blok

52 eşleşen sözcük



4 İnternet



www.mdpi.com

<1%

3 metin blok

51 eşleşen sözcük



5 İnternet



www.polradiol.com

<1%

1 metin blok

40 eşleşen sözcük



6 Öğrenci makaleleri

