

T.C.
AKDENİZ ÜNİVERSİTESİ



**DERİN ÖĞRENME YÖNTEMİNİN KORONER ARTER HASTALIĞINDA
İSKEMİ DEĞERLENDİRİLMESİ İÇİN SPECT GÖRÜNTÜLERİNE
UYGULANMASI**

Bedia ŞAYIK

**FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

OCAK 2023

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ



**DERİN ÖĞRENME YÖNTEMİNİN KORONER ARTER HASTALIĞINDA
İSKEMİ DEĞERLENDİRİLMESİ İÇİN SPECT GÖRÜNTÜLERİNE
UYGULANMASI**

Bedia ŞAYIK

**FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

OCAK 2023

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DERİN ÖĞRENME YÖNTEMİNİN KORONER ARTER HASTALIĞINDA
İSKEMİ DEĞERLENDİRİLMESİ İÇİN SPECT GÖRÜNTÜLERİNE
UYGULANMASI**

**Bedia ŞAYIK
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

OCAK 2023

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DERİN ÖĞRENME YÖNTEMİNİN KORONER ARTER HASTALIĞINDA
İSKEMİ DEĞERLENDİRİLMESİ İÇİN SPECT GÖRÜNTÜLERİNE
UYGULANMASI**

Bedia ŞAYIK
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Bu tez 18/01/2023 tarihinde jüri tarafından Oybirliği / Oyçokluğu ile kabul edilmiştir.

Prof. Dr. Ahmet BOZKURT (Danışman)

Doç. Dr. Evgin Göçeri

Doç. Dr. Emre DANDIL

ÖZET

DERİN ÖĞRENME YÖNTEMİNİN KORONER ARTER HASTALIĞINDA İSKEMİ DEĞERLENDİRİLMESİ İÇİN SPECT GÖRÜNTÜLERİNE UYGULANMASI

Bedia ŞAYIK

Yüksek Lisans Tezi, Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ahmet BOZKURT

Ocak 2023; 64 sayfa

Hayati organlardan biri olan kalbin anormal çalışmasının sebeplerinden biri koroner arter hastalığıdır (KAH). Kalbin yeteri kadar beslenmesini ve oksijenlenmesini sağlayan koroner arter damarların daralması-tıkanması sonucu kardiyovasküler sistemde iske mi gerçekleşmesi durumuna KAH denir. Kardiyovasküler sistemin fonksiyonel olarak değerlendirilmesine imkan sunan Single Photon Emission Computed Tomography (SPECT) görüntüleme tekniği KAH tanısında sık tercih edilen nükleer tıp uygulamalarından biridir. Stres-dinlenme çekimli SPECT görüntülerinin karşılaştırılması ile kalbin fonksiyonu ve risk durumu, koroner arter damarlardaki daralmanın-tıkanmanın konumu hakkında bilgi toplamayı sağlar. Mevcut durumda SPECT görüntülerinden elde edilen bilgiler uzmanlar tarafından yorumlanarak hastalık teşhisi konulur. Bu çalışmada, her geçen gün artış gösteren bilgi birikimin işlenebilmesini karşılayabilecek nitelikte olan bir sistem önerilmiştir. Evrişimli Sinir Ağı (ESA) algoritmaları ve güçlü donanım teknolojilerine yer verilerek tasarlanan derin öğrenme (DÖ) modeli KAH tanısını koymada uzmanlara yardımcı olabilir. SPECT MPI (Myocardial Perfusion Imaging) görüntü veri setinin eğitim ve test işlemleri çeşitli transfer öğrenme (TÖ) mimarileri üzerinden yürütülerek iske mi/canlı doku değerlendirilmesi yapılmıştır. Çalışmanın sonucunda, önceden eğitilmiş DenseNet121, InceptionResNetV2, InceptionV3, MobileNet, MobileNetV2, ResNet50, VGG16, VGG19, Xception mimarilerinin performans ölçütleri incelendiğinde en yüksek eğitim doğruluğunu %98.2 ile InceptionV3, en yüksek kesinliği %98, duyarlılığı %98, F1-skoru %98 ve AUC değeri 0.977 olarak Xception modelinde analiz edilmiştir. Test veri setinde ise VGG16 %98.3, VGG19 %85 ve MobileNetV2 %77.2 en düşük doğruluk değeri hesaplanırken geriye kalan modellerde doğruluk %100 başarıya ulaşmıştır. Literatürde yapılan diğer çalışmalara kıyasla SPECT MPI görüntülerinden yola çıkarak analiz yeteneği kazandırılan DÖ yöntemi ile iske mi/canlı doku değerlendirilmesi amaçlanmıştır.

ANAHTAR KELİMELE R: Derin öğrenme, iske mi, koroner arter hastalığı, SPECT (Single Photon Emission Computed Tomography), teşhis

JÜRİ: Prof. Dr. Ahmet BOZKURT (Danışman)

Doç. Dr. Evgin GÖÇERİ

Doç. Dr. Emre DANDIL

ABSTRACT

APPLICATION OF DEEP LEARNING METHOD TO SPECT IMAGES FOR EVALUATION OF ISCHEMIA IN CORONARY ARTERY DISEASE

Bedia ŞAYIK

MSc Thesis in Biomedical Engineering

Supervisor: Prof. Dr. Ahmet BOZKURT

January 2023; 64 pages

Coronary artery disease (CAD) is one of the causes of abnormal functioning of the heart, which is one of the vital organs. The occurrence of ischemia in the cardiovascular system as a result of narrowing-occlusion of the coronary artery vessels that provide adequate nutrition and oxygenation of the heart is called CAD. SPECT (Single Photon Emission Computed Tomography) imaging technique, which allows functional evaluation of the cardiovascular system, is one of the frequently preferred nuclear medicine applications in the diagnosis of CAD. By comparing stress-resting SPECT images, it provides information about the function and risk status of the heart, and the location of the narrowing-occlusion in the coronary arteries. In the current situation, the information obtained from the SPECT images is interpreted by the experts and the disease is diagnosed. In this study, a system that is capable of meeting the processing of knowledge that is increasing day by day has been proposed. Convolutional neural network (ESA) algorithms and deep learning (DL) model designed by including powerful hardware technologies can help experts in diagnosing CAD. The training and testing of the SPECT MPI image dataset was carried out on various transfer learning (BL) architectures, and ischemia/living tissue evaluation was performed. As a result of the study, when the performance performance criteria of the pre-trained DenseNet121, InceptionResNetV2, InceptionV3, MobileNet, MobileNetV2, ResNet50, VGG16, VGG19, Xception architectures are examined, the highest training accuracy is InceptionV3, with the highest accuracy %98, sensitivity %98, F1-score %98 and AUC value of 0.977 were analyzed in the Xception model. In the test data set, the lowest accuracy value was calculated for VGG16 %98.3, VGG19 %85 and MobileNetV2 %77.2, while the remaining models achieved %100 accuracy. Compared to other studies in the literature, it is aimed to evaluate ischemia/living tissue with the DS method, which has the ability to analyze based on SPECT MPI images.

KEYWORDS: Deep learning, ischemia, coronary artery disease, SPECT (Single Photon Emission Computed Tomography), diagnosis

COMMITTEE: Prof. Dr. Ahmet BOZKURT (Supervisor)

Assoc. Prof. Dr. Evgin GÖÇERİ

Assoc. Prof. Dr. Emre DANDIL

ÖNSÖZ

Yüksek Lisans eğitimim boyunca bana destek ve yön göstererek bu yolda başarılı bir şekilde ilerlememe katkı sağlayan, ülkemiz için değerli kılınan Nükleer Tıp alanında farklı bakış açısıylaengin bilgi ve tecrübesini yeni nesillere aktaran, her zaman gurur duyacağım saygıdeğer tez danışmanım Sayın Prof. Dr. Ahmet BOZKURT'a sonsuz teşekkürlerimi sunarım.

Akademik hayatımda destekleri ile her zaman gelişimime ışık tutan Akdeniz Üniversitesi Biyomedikal Mühendisliği Bölümü'nde bulunan tüm eğitimcimlere,

Ayrıca; uygulama sürecimde bana katkı sağlayan sevgili arkadaşım Esra SİVRİKAYA'ya da teşekkürlerimi borç bilirim.

Son olarak bu zamana kadar her kararımdayarımdayan ve beni destekleyen aileme sonsuz sevgi ve teşekkürlerimle....

İÇİNDEKİLER

| | |
|---|-----|
| ÖZET..... | i |
| ABSTRACT..... | ii |
| ÖNSÖZ | iii |
| İÇİNDEKİLER | iv |
| AKADEMİK BEYAN | vi |
| SİMGELER VE KISALTMALAR..... | vii |
| ŞEKİLLER DİZİNİ..... | ix |
| ÇİZELGELER DİZİNİ | xi |
| 1. GİRİŞ | 1 |
| 2. KAYNAK TARAMASI | 4 |
| 3. MATERYAL VE METOT | 12 |
| 3.1 Kalp ve Koroner Arter Hastalığı | 12 |
| 3.1.1 Kalbin Anatomisi ve Dolaşım Sistemi | 12 |
| 3.1.2 Koroner Arterler ve KAH..... | 13 |
| 3.2 Kardiyovasküler Hastalıklarda Kullanılan Tıbbi Görüntüleme Yöntemleri | 14 |
| 3.3 SPECT Görüntüleme Yöntemi | 18 |
| 3.3.1. SPECT Sisteminin Bileşenleri | 18 |
| 3.3.2 Kardiyovasküler Hastalıkların SPECT ile Görüntülenmesi | 20 |
| 3.3.3 Kardiyak SPECT Taramada Kullanılan Radyofarmasötikler..... | 21 |
| 3.4 Makine Öğrenimi, Yapay Sinir Ağları ve Derin Öğrenme..... | 22 |
| 3.4.1 Makine Öğrenimi..... | 23 |
| 3.4.2 Yapay Sinir Ağları..... | 25 |
| 3.4.3 Derin Öğrenme | 25 |
| 3.5 Görüntü İşleme Yöntemleri | 26 |
| 3.6 Evrişimli Sinir Ağı Katmanları ve Mimarileri | 27 |
| 3.6.1 Evrişimli Sinir Ağı Katmanları..... | 27 |
| 3.6.2 Evrişimli Sinir Ağı Mimarileri | 28 |
| 3.6.3 Aktivasyon Fonksiyonları..... | 32 |
| 3.7 Transfer Öğrenme | 33 |
| 3.8 Başarım Performans Ölçütleri..... | 34 |
| 3.9 Kalp Spect Verilerinin Toplanması ve ESA ile İskemi Değerlendirmesi | 36 |

| | |
|--|----|
| 4. BULGULAR..... | 37 |
| 4.1 Klinik SPECT_MPI Veri Setinin Oluřturulması..... | 37 |
| 4.2 İskemi Tanısı İin Önerilen Transfer Öğrenme Modelinin Tasarım Ařamaları .. | 38 |
| 4.3 Koroner Arter Hastalıęında SPECT_MPI_CNN_TL Modelin İskemi Deęerlendirmesi Sonuları | 39 |
| 5. TARTIřMA | 52 |
| 6. SONULAR | 57 |
| 7. KAYNAKLAR | 59 |
| ÖZGEMİř | |

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Derin Öğrenme Yönteminin Koroner Arter Hastalığında İskemi Değerlendirilmesi İçin SPECT Görüntülerine Uygulanması” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

18/01/2023

Bedia ŞAYIK

SİMGELER VE KISALTMALAR

Kısaltmalar

- AF : Aktivasyon Fonksiyonları
- AUC : Roc eğrisinin altındaki alan (area under the ROC curve)
- BDT : Bilgisayar Destekli Teşhis
- BT : Bilgisayarlı Tomografi
- DICOM: Digital Imaging and Communications in Medicine
- DÖ : Derin Öğrenme
- DSÖ : Dünya Sağlık Örgütü
- SVM : Support Vector Machine
- EKG : Elektrokardiyografi
- ESA : Evrişimli Sinir Ağı
- FDG : Fluoro-2-deoksi-glikoz
- FP : False Positive (Yanlış Pozitif)
- FN : False Negative (Yanlış Negatif)
- GCNN: Graphic-Convolutional Neural Networks
- ILSVRC: ImageNet Large Scale Visual Recognition Challenge
- İKA : İnvaziv Koroner Anjiyografi
- KAH : Koroner Arter Hastalığı
- KBT : Kardiyak Bilgisayarlı Tomografi
- KBTA : Koroner Bilgisayarlı Tomografi Anjiyografisi
- KKH : Koroner Kalp Hastalığı
- KMR : Kardiyak Manyetik Rezonans
- KVH : Kardiyovasküler Hastalık
- LLk : Low-Likelihood
- LV : Sol ventrikül (left ventricular)

MIBI : heksakis-2-metoksiizobutilizonitril

MPS : Miyokard Perfüzyon Sintigrafisi

MP/SPECT: Miyokardiyal Perfüzyon SPECT

MPG/MPI : Miyokardiyal Perfüzyon Görüntüleme / Myocardial Perfusion Imaging

MRG : Manyetik Rezonans Görüntüleme

MS COCO: Microsoft Common Objects in Context

MÖ : Makine Öğrenmesi

OKAH: Obstrüktif Koroner Arter Hastalığı

PET : Positron Emmision Tomography

PMT : Photo Multiplier Tube

ROC : Alıcı çalışma özellikleri (receiver operating characteristics)

ROI : İlgi Bölgesi (Region of Interest)

SPECT: Single Photon Emission Computed Tomography

TBA : Tam Bağlı Ağ

TP : True Positive (Gerçek Pozitif)

TN : True Negative (Gerçek Negatif)

QGS : Quantitative Gated SPECT

QPS : Quantitative Perfusion SPECT

WEKA: Waikato Environment for Knowledge Analysis

YSA : Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

| | |
|--|----|
| Şekil 1.1. Normal ve anormal koroner arter damarı yapısı..... | 1 |
| Şekil 1.2. Miyokardiyal perfüzyonun stress-rest çekimli SPECT ve PET görüntüleri..... | 2 |
| Şekil 3.1. Kalbin yapısı ve kan akışının yolu..... | 12 |
| Şekil 3.2. Koroner Arterler | 13 |
| Şekil 3.3. Koroner Arter Hastalığı ve Kan Akışı | 14 |
| Şekil 3.4. Normal MRG, BT, ve X-ışını Anjiyografisinin Temsili Örneği | 16 |
| Şekil 3.5. LMCA ve proksimal LAD (pLAD) görüntüleri. A - LMCA, B modu; B - pLAD, B modu; C - LMCA, Renkli Doppler haritalama; D - LMCA'nın çatallanması; Renkli Doppler haritalama | 16 |
| Şekil 3.6. (a) PET Görüntüleme Yöntemi; (b) PET Cihazı; (c) Örnek bir kalp SPECT/PET görüntüsü | 17 |
| Şekil 3.7. (a) SPECT Görüntüleme Yöntemi; (b) SPECT Cihazı; (c) Örnek bir kalp SPECT görüntüsü..... | 18 |
| Şekil 3.8. Geleneksel Anger Kamera ve SPECT | 19 |
| Şekil 3.9. EKG Kapılı SPECT Tarama..... | 20 |
| Şekil 3.10. SPECT ile stres-dinlenme durumunda elde edilen kalp görüntüsü | 22 |
| Şekil 3.11. Yapay zeka, MÖ, YSA, DÖ'nin Venn şeması ile gösterimi | 23 |
| Şekil 3.12. Makine Öğrenimi Teknikleri ve İlgili Veriler | 24 |
| Şekil 3.13. (a) İleri beslemeli sinir ağı; (b) Geri beslemeli sinir ağı | 25 |
| Şekil 3.14. ESA Mimarisinin şematik diyagramı | 27 |
| Şekil 3.15. LeNet-5 Mimarisi | 29 |
| Şekil 3.16. AlexNet Mimarisi | 30 |
| Şekil 3.17. NiNMimarisi..... | 30 |
| Şekil 3.18. VGGNet-16 Mimarisi (D konfigürasyonu) | 31 |
| Şekil 3.19. Çeşitli aktivasyon fonksiyonlar: (a) ReLU, (b) sigmoid, (c) hiperbolik tanjant (tanh) | 33 |
| Şekil 3.20. Karmaşıklık Matrisi | 36 |

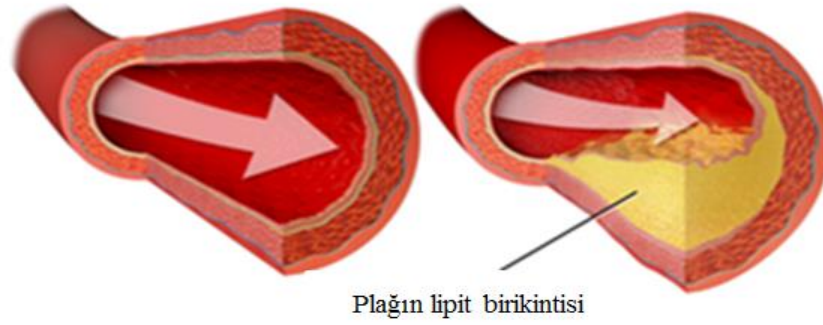
| | |
|---|----|
| Şekil 4.1. RGB_SPECT_MPI_CNN modeli için oluşturulan veri kümesinin şematik gösterimi..... | 38 |
| Şekil 4.2. Bir hastaya ait (a) Orijinal anormal, (b) FIJI programında kırılmış anormal SPECT MPI görüntüleri, (c) Orijinal normal, (d) FIJI programında kırılmış normal SPECT MPI görüntüleri..... | 39 |
| Şekil 4.3. Transfer öğrenme modellerinin doğruluk grafiği | 41 |
| Şekil 4.4. Transfer öğrenme modellerinin kayıp grafiği..... | 41 |
| Şekil 4.5. DenseNet121 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri..... | 42 |
| Şekil 4.6. Xception modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri..... | 43 |
| Şekil 4.7. MobileNet modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri..... | 44 |
| Şekil 4.8. VGG16 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri..... | 45 |
| Şekil 4.9. VGG19 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri..... | 46 |
| Şekil 4.10. ResNet50 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri..... | 47 |
| Şekil 4.11. InceptionV3 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri..... | 48 |
| Şekil 4.12. MobileNetV2 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri..... | 49 |
| Şekil 4.13. InceptionResNetV2 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri | 50 |

ÇİZELGELER DİZİNİ

| | |
|---|----|
| Çizelge 4.1. Transfer öğrenme modellerinde kullanılan hiperparametreler ve değerleri | 40 |
| Çizelge 4.2. Transfer öğrenme modellerine ait eğitim ve test veri kümesinin başarı performansı | 50 |

1. GİRİŞ


Kardiyovasküler hastalıklar (KVH'lar) dünyada olduğu gibi ülkemizde de yüksek oranda rastlanan rahatsızlıklardandır. Dünya Sağlık Örgütü'ne göre KVH dünya çapında önde gelen ölüm nedenlerinden biridir. Ülkelerin gelişmişlik düzeyi azaldıkça KVH'larda artış görülmektedir. KVH'ların büyük bir kısmını temsil eden KAH sıklıkla akut ve ateroskleroz kaynaklı gelişir (WHO 2021). En sık görülen KVH'lardan biri kalbin yeteri kadar beslenememesi ve oksijen alamamasından kaynaklanan KAH'dır. Bu mekanizmanın bozulmasına sıklıkla ateroskleroz (damar sertleşmesi) yol açar ve bu durum zararlı maddelerin damarda birikmesine neden olur. Zamanla damar çeperinde plak oluşumu şeklinde ortaya çıkarak damarların daralmasına veya tıkanmasına yol açar ve sonuçta KAH oluşur (Şekil 1.1; (Katz 2010)).



Şekil 1.1. Normal ve anormal koroner arter damarı yapısı

KVH'lara sebep olan hipertansiyon, diyabet ve hiperlipidemi gibi birçok hastalık için risk oluşturur. KAH'ın başlıca olumsuz etkileri, hastanın ölümü, sakat kalması, yaşam kalitesinin düşmesi gibi sorunlar şeklinde sıralanabilir. Bu etkilerden dolayı KAH'ın erken teşhisi son derece önemlidir.

Tıbbi görüntüleme yöntemleri, vücuttaki anormal durumların sebeplerini ve sonuçlarını araştırma imkanı sunarak hastalıkların erken teşhis ve tedavisine katkı sağlar (Xu, Kocyigit et al. 2020). KAH teşhisinde kullanılan görüntüleme yöntemleri arasında radyografi, floroskopi, bilgisayarlı tomografi (BT), ultrason, manyetik rezonans görüntüleme (MRG), miyokard perfüzyon sintigrafisi (MPS), ekokardiyografi, koroner anjiyografi, SPECT ve PET (Positron Emission Tomography) sayılabilir (Şekil 1.2) (Pearlman 2022).



Şekil 1.2. Miyokardiyal perfüzyonun stress-rest çekimli SPECT ve PET görüntüleri (Maddahi and Packard 2013)

KAH teşhisi koymada yararlanılan nükleer tıp görüntüleme yöntemlerinden biri olan SPECT, dinlenme ve stres sırasında çekilen kardiyak kan akışı görüntülerini karşılaştırarak hastalarda miyokardiyal enfarktüs (kalp krizi) ve miyokardiyal iskemi teşhisini girişimsel olmayan bir yöntemle gerçekleştirir. Bu yöntem ile elde edilen fonksiyonel görüntüler yardımıyla fizyolojik (metabolik aktivite, kan akışı) ve içsel lezyon lokalizasyonu hakkında bilgiler de elde edilir.

SPECT görüntüleme, hastaya enjekte edilen bir radyofarmasötüğün vücuttaki dokular tarafından farklı oranlarda tutulması ve her doku vokselinden yayılan gama fotonlarının hasta etrafında dönen dedektörler sayesinde algılanması ilkesine dayanır (Bailey and Humm 2014). Dedektördeki bilginin anlamlandırılabilmesi için bilgisayarda tekrarlamalı (iterative) veya geri-izdüşümlü (backprojection) filtreleme teknikleri kullanılarak vücut bölgesinin kesitsel görüntüleri elde edilir ve sonuç olarak hasta vücudunda radyofarmasötik aktivitesi birikmiş organların bir görüntü haritası ortaya çıkar.

SPECT görüntüleme, en sık KAH teşhisinde kullanılan bir teknik olup, kardiyak SPECT görüntüler üzerinde genellikle bazı iyileştirme çalışmaları yapmak gerekir. Literatürde artefakt ve gürültü giderme ile filtreleme üzerine yapılmış çalışmalar mevcuttur (Rosenthal, Cullom et al. 1995, Dorbala, Ananthasubramaniam et al. 2018). Ayrıca stres-dinlenme çekimli görüntülerin karşılaştırılması ve yorumlanması için donanım ve yazılım geliştirme çalışmaları da yapılmıştır (Notghi and Low 2011).

KAH teşhisini SPECT ile yapmada uzmanlara yardımcı olmak üzere geliştirilecek bir yapay zeka modeli, kardiyak SPECT görüntülerini daha anlamlı hale getirerek uzmanın KAH tanısı koymadaki başarısını arttırabilecek yardımcı bir parametre olarak değerlendirilebilir. Her geçen gün artış gösteren tıbbi görüntü veri setlerinin eğitilmesinde klasik makine öğrenmesi algoritmaları yetersiz kalmakta ve uzmanın bilgisi doğrultusunda model oluşturulmasını gerektirmektedir. Son yıllarda,

tıbbi görüntülerde olduğu gibi büyük veri setlerinin eğitilmesi için derin öğrenme (DÖ) algoritmalarının kullanılması yaklaşımı öne çıkmaya başlamıştır. DÖ modelleri, yapay sinir ağının (YSA) ham görüntüler ile eğitilerek uzman yardımına gerek kalmadan doğru tanı, hızlı tahmin ve zamanında müdahale sağlayabilmektedir (Razzak, Naz et al. 2018). İskemi değerlendirmesi için geliştirilecek bir DÖ modeli ile görüntü işleme teknikleri de kullanılarak görüntü analizi yapılabilir ve hastalık değerlendirmesi daha az hata ile gerçekleştirilebilir.

Bu çalışmada, tasarlanan bir derin öğrenme modeli yardımıyla KAH'ın SPECT görüntüleri üzerinden doğru teşhis edilmesi ve iskemi değerlendirilmesi amaçlanmıştır. Stres-dinlenme çekimli SPECT görüntüler üzerinden kardiyovasküler sistemde yer alan kalp ve koroner arter damarlardaki iskemi durumu DÖ tekniği kullanılarak araştırılmıştır. Dinlenme durumundaki kalbe yeterli düzeyde kan pompalanırken stres durumundaki kalbe yeterli düzeyde kan pompalanmadığı durumlar karşılaştırılarak KAH teşhisi konulmaktadır. Çalışma sonucunda geliştirilen derin öğrenme modeli, hastanın kardiyak SPECT görüntü veri setini otomatik olarak anlamlı hale getirip KAH'ın teşhisine yardımcı olan iskemi değerlendirmesini yaparak literatüre katkıda bulunmuştur.

Bu tez çalışmasının birinci bölümünde kardiyovasküler hastalıklardan biri olan koroner arter hastalığının, bir tıbbi görüntüleme yöntemi olan SPECT ile teşhisi, görüntü işleme teknikleri, yapay zeka ve derin öğrenme modelleri hakkında genel bilgiler verilmiştir. İkinci bölümde literatür taraması yapılarak konu ile ilgili yapılmış bazı çalışmalara değinilmiştir. Üçüncü bölümde çalışmanın gerçekleştirilmesi için gerekli olan kardiyak SPECT görüntülerinin ön işleme, yeniden yapılandırma, segmentasyon ve sınıflandırma adımları hakkında bilgi verilmiştir. Dördüncü bölümde çalışma sonucunda elde edilen derin öğrenme modelinin başarı parametreleri gösterilmiş ve değerlendirmeleri yapılmıştır. Beşinci bölümde ise çalışma sonucunda elde edilen veriler karşılaştırılarak, çalışmanın literatürdeki önemi vurgulanmış ve gelecekte yapılacak benzer çalışmalar için önerilere değinilmiştir.

2. KAYNAK TARAMASI

SPECT taramaları, miyokardiyal perfüzyon ve miyokardiyal enfarktüs görüntüleme ile kalp hastalıkları teşhisinin yanı sıra kemik, safra kesesi, tiroit, Alzheimer ve Parkinson gibi hastalıklara tanı koymada da kullanılan bir nükleer tıp görüntüleme tekniğidir (Trägårdh, Hasbak et al. 2018, Soo, Cain et al. 2019). Diğer teşhis yöntemleri ile birlikte kullanıldığında tamamlayıcı bir role sahiptir. Örneğin SPECT tarama ile beyin perfüzyon görüntüleri elde edilerek Alzheimer hastalığının teşhisini beyinde yapısal değişikliklere yol açmadan mümkün kılar. Ayrıca anatomik ve fonksiyonel görüntülerin birlikte değerlendirildiği SPECT/MR ve SPECT/BT gibi hibrit görüntüleme teknolojileri de geliştirilmiştir (Valotassiou, Sifakis et al. 2011, Yoneyama, Nakajima et al. 2019).

SPECT tekniği ile fonksiyonel görüntüleme yapılabildiği için beyindeki anormal kan akışı hakkında bilgi de elde edilebilmektedir. Bu modalite ile nöro-dejeneratif hastalıklardan biri olan Parkinson hastalığının teşhisine yönelik olarak bazı derin öğrenme çalışmaları gerçekleştirilmiştir (Alkan and Keleş 2019, Pahuja, Nagabhusan et al. 2020). Ayrıca vücudun metabolizmasını kontrol etmek için hayati önem taşıyan tiroid hormonu üreten tiroit bezinin SPECT görüntüleri organın-dokunun metabolik aktivitesi hakkında bilgi verebildiği için tiroit hastalığının teşhisinde de DÖ modelleri ile takviye edilmiştir (Ma, Ma et al. 2019). Miyokardiyal perfüzyon ve miyokardiyal enfarktüs görüntülerindeki iskemi/enfarktüs klinik durumunun derin öğrenme mimarileri yardımıyla daha doğru bir şekilde değerlendirilebileceğine dair çalışmalar literatürde mevcuttur.

KAH erken tanı ve tedavisi için çeşitli görüntüleme cihazları kullanılarak hastalığın tespiti birçok mevcut yöntemlerle sağlanmaktadır. Son zamanlarda non-invaziv görüntüleme yöntemleri ile hastalığın durumu hakkında detaylı, güvenilir ve tekrarlanabilir bilgiler elde etmek için akademik çalışmalar yapılmıştır. Bilgisayar destekli tanı sistemlerinin medikal görüntüleme cihazları ile entegrasyon sağlayabilmesi hastalıklar hakkında bilginin artmasını ve aktarılmasını mümkün kılmıştır. Kardiyak SPECT taramadan elde edilen görüntü veri setlerinden KAH tanısı ile ilgili bilgilerin yorumlanması için DÖ yaklaşımının kullanılabilirliği büyük ilgi odağı toplamıştır. Bu konu ile ilgili bazı akademik çalışmalar bize mevcut yöntemlerin geliştirilebileceğini göstermiştir. Literatürde çeşitli görüntüleme cihazları ile bilgisayar destekli tanı sistemleri birleştirilerek yapılan bazı akademik çalışmalar hastalığın erken tanı ve tedavisinde başarılı olabileceğini ve uzmanlara destek sağlayabileceğini düşündürmüştür. Bu bölümde SPECT görüntüleme veri setleri ile MÖ, YSA, DÖ ve ESA algoritmaları kullanılarak kardiyak rahatsızlıkların tespiti ile ilgili çalışmalara yer verilmiştir.

El Rafaie ve ark. 2012 yılında yapmış oldukları çalışmada kalbin dinlenme ve stres sonrasında çekilen SPECT görüntüleri için otomatik sınıflandırma yapmışlardır (El Rafaie, Salem et al. 2012). Bu çalışmanın amacı veri madenciliği tekniğinin bir alt dalı olan kaba kümeler algoritması ile SPECT veri setlerinin sonuçlarını analiz edebilecek bir mekanizma oluşturmaktır. UCI KKD veri havuzunda yer alan 55'i kalp hastalığı olmayan, 212'si kalp hastalığı olan 267 hasta kaydından ve 22 özellik ile 1 karar sınıfından oluşan SPECT kalp hastalığı veri kümesi çalışmada kullanılmıştır. Yayınlanan sonuçlar, iskemik kalp hastalığının teşhisi açısından %83 düzeyinde

(eğitilmiş kardiyolağa göre) UCI’de barındırılan bir veri setinden genel doğruluklar sağlamıştır. Bu çalışmadan elde edilen sonuçlar %85 özgüllük, %95 duyarlılık, %93 ($\pm 3,8$) genel sınıflandırma doğruluğu sağlamıştır. Bu çalışmanın sonucunda kaba kümeler yaklaşımı ile SPECT veri kümesini yüksek bir genel doğruluk, özgüllük ve duyarlılıkla sınıflandırabildiğini göstermiştir.

Arsanjani ve ark. 2013 yılında yapmış oldukları çalışmada KAH’ın tahmininde destek vektör makinası (Support Vector Machine; SVM) algoritmasını kullanarak kantitatif perfüzyon ve fonksiyonel miyokard perfüzyon SPECT değişkenlerinin entegrasyonunu sağlamışlardır. SVM ile ileri stenozu öngörmeye otomatik analiz tanıtılma doğruluğunda iyileşme gösterip göstermediğini araştırmışlardır. (Arsanjani, Xu et al. 2013). Çalışmada kullanılan veri seti, korelatif anjiyografiye sahip 623 hasta (anormal) ve LLk (low-likelihood: düşük olasılık) KAH’ı olan 334 hasta (normal) olarak iki gruba ayrılmıştır. MP/SPECT’in yorumlanmasında rutin olarak kullanılan 3 ortak kantitatif özellik (stres toplam perfüzyon açığı, iskemik değişiklikler ve stres sonrası ejeksiyon fraksiyon değişiklikleri) seçilmiştir. SVM’nin duyarlılığı (%84), ISCH (%75) ve EFC’den (%31) daha yüksek hesaplanmıştır. SVM’nin özgüllüğü (%88), TPD (%78) ve EFC’den (%77) daha iyi sonuç vermiştir. SVM’nin sırasıyla tanıtılma doğruluğu (%86) ile ROC-AUC (0.92) değeri, TPD (%81-0.90), ISCH (%81-0.87) ve EFC’ye (%46-0.60) göre daha iyi olduğu gözlemlenmiştir. Çalışmanın sonucunda kantitatif perfüzyon ve fonksiyonel değişkenlerin SVM yaklaşımı ile hesaplamalı entegrasyonu, MP/SPECT’in tanıtılma doğruluğunun önemli ölçüde iyileştirilmesine izin vermiş ve ROC analizine dayalı görsel değerlendirmede önemli ölçüde iyi performans gösterebilmiştir.

Arsanjani ve ark. 2013 yılında yapmış oldukları çalışmada, SPECT görüntülerinden elde edilen kantitatif perfüzyon ve klinik verilerin makine öğrenmesi (MÖ) algoritmaları ile hesaplamalı entegrasyonunu gerçekleştirerek, KAH tanıtılma kullanılan MPS’nin yorumlama başarısını artırmayı amaçlamışlardır (Arsanjani, Xu et al. 2013). Bu çalışmada, ensemble MÖ algoritması (LogitBoost) uygulanarak kantitatif perfüzyon ve klinik değişkenlerin tam otomatik entegrasyonu yapılmıştır. Ensemble MÖ, her bir sınıflandırıcıya ait karar topluluğunun birleştirilmesi ile elde edilen tek bir karar sınıflandırıcı algoritması oluşturma işlemidir (Dietterich 2000). Çalışmada kullanılan veri seti, korelatif anjiyografiye sahip 713 hasta (anormal) ve LLk (düşük olasılık) KAH’ı olan 468 hasta (normal) olarak iki gruba ayrılmıştır. Sınıflandırma işleminde WEKA (Waikato Environment for Knowledge Analysis; (Garner 1995) yöntemi tercih edilerek karar kütüklerine LogitBoost prosedürü uygulanmıştır. Çalışmanın sonucunda kantitatif perfüzyon ve klinik verilerin LogitBoost yaklaşımı ile hesaplamalı entegrasyonu, MP/SPECT’in tanıtılma doğruluğunu önemli ölçüde artırmış ve uzman analizine rakip olacak düzeyde daha iyi performans gösterebilmiştir.

Nakajima ve ark. 2017 yılında yapmış oldukları çalışmada miyokardiyal perfüzyon görüntüleri (MPG) üzerinden KAH’ın teşhisini koymada kullanılabilecek YSA ile istatistiksel kantitasyonun tanıtılma doğruluğunu karşılaştırmayı amaçlamışlardır (Nakajima, Kudo et al. 2017). İsviçre veri tabanlarını kullanarak YSA sistemi, bu çalışma kapsamında Japon SPECT MPG görüntüleri ile de eğitilmiş ve KAH tanıtılma doğruluğu artırılmaya çalışılmıştır. Nükleer kardiyoloji uzmanları MPG verilerinin görsel yorumlamasını yaparak tüm bölgelerin anormal (doğru) ve normal (yanlış) değerlendirmesini sağlamışlardır. Geliştirilen YSA sistemi yardımıyla iskemi/enfarktüs varlığı, ciddiyet derecesi, kapsamı ve lokasyon bilgileri elde edilmiştir. YSA’nın eğitim

veri setindeki stres bozukluğu için AUC 0.912 (hassasiyet %86, özgüllük %77, doğruluk %82), dinlenme bozukluğu için AUC 0.834 (hassasiyet %83, özgüllük %74, doğruluk %78) ve iskemi için AUC 0.888 (hassasiyet %82, özgüllük %77, doğruluk %80) elde edilmiştir. Çalışma sonucunda, farklı klinik ortamlarda elde edilen SPECT MPI görüntülerine YSA yaklaşımı uygulanarak KAH teşhisine katkı sağlayabileceğini belirtmişlerdir.

Betancur ve ark. 2018 yılında yapmış oldukları çalışmada, klinik bilgi ve SPECT MPG görüntü verilerini kullanarak makine öğrenmesi yöntemi ile majör advers kardiyak olayların (MACE) tahmini değerlendirilmesindeki başarısını artırmaya çalışmışlardır (Betancur, Otaki et al. 2018). Çalışma kapsamında 2010-2011 arası dönemde Sacred Heart Tıp Merkezi'ne stres MPG için sevk edilen 2639 hastanın SPECT MPI görüntü verileri kullanılmıştır. MÖ teknikleri, açık kaynaklı Waikato Environment for Knowledge Analysis (WEKA) (Waikato Üniversitesi, Hamilton, Yeni Zelanda) platformu 3.8.0'da uygulanmıştır. LogitBoost algoritma topluluğu ile MACE puanlaması yapabilecek tahmin sınıflandırıcıları geliştirilmiştir. Bunlar; mevcut tüm verilerle MÖ (MÖ-birleştirilmiş), yalnızca görüntüleme verileriyle MÖ (MÖ-görüntüleme), 5 puanlık ölçekte görsel tanı (MD teşhisi) ve otomatik kantitatif görüntüleme analizi (stres TPD ve iskemik TPD) olmak üzere dört farklı sınıflandırıcıdır. Çalışmanın sonucunda, MÖ modeli ile klinik bilgi ve görüntüleme veri değişkenlerinin birleştirilmesi, 3 yıllık MACE risk tahmininin doğruluğunu artırmıştır. Ayrıca MÖ algoritmasının perfüzyon değerlendirmedeki başarı oranının görsel veya otomatik perfüzyon değerlendirmesine göre üstün olduğu bulunmuştur.

Betancur ve ark. 2018 yılında yapmış oldukları çalışmada obstrüktif koroner arter hastalığı (OKAH) tahminini SPECT MPG görüntüleri ile analiz edebilecek bir ESA modeli tasarlamışlardır (Betancur, Commandeur et al. 2018). Dinlenme-stres çekimli SPECT MPG görüntülerinin karşılaştırılmasına imkan sunan veri tabanları TPD kantifikasyonunu nicelendirilerek OKAH teşhisi sağlanmıştır. Ulusal ve uluslararası 9 farklı bölgede 2008-2015 yılları arasında SPECT MPG görüntüleri çekilen ve 180 gün sonra invaziv koroner anjiyografisi (İKA) çekilen 1638 hasta (%67'si erkek) ile çalışılmıştır. DÖ modeli öncelikle kutup harita özelliklerini çıkararak eğitilip sonra da damar başına/hasta başına KAH olasılığı tahmin edilmiştir. DÖ yöntemi ile hastalık tahmini için alıcı-çalışma karakteristik eğrisinin altındaki alan TPD'den daha yüksek hesaplanmıştır (hasta başına: 0.80 (DÖ), 0.78 (TPD); damar başına: 0.76 (DÖ), 0.73 (TPD)). DÖ eşiği TPD ile aynı özgüllüğe ayarlandığında, hasta başına duyarlılık %79.8'den (TPD) %82.3'e (DÖ) ve damar başına duyarlılık %64.4'ten (TPD) %69.8'e (DÖ) yükselmiştir. Çalışmanın sonucunda önerilen DÖ yöntemi ile MPG görüntülerinin otomatik değerlendirilmesi yapılmış ve TPD yöntemine göre OKAH teşhisini geliştirdiği gösterilmiştir.

Spier ve ark. 2019 yılında yapmış oldukları çalışmada MPG'den elde edilen kutupsal harita verilerini grafik-evrimsel sinir ağları (Graphic-Convolutional Neural Networks; GCNN) ile sınıflandırarak KAH'ın teşhisi ve lokalizasyonu bulmada uzmanlara yardımcı bir model geliştirmeye çalışmışlardır (Spier, Nekolla et al. 2019). Çalışmada 503'ü dinlenme testi (237'si anormal ve 266'sı normal) ve 443'ü stres testi (206'sı anormal ve 237'si normal) olmak üzere toplamda 946 etiketli kutupsal harita veri seti kullanılmıştır. İlk olarak modellerin, belirli bir kutupsal haritayı lokalizasyondan bağımsız bir şekilde normal/anormal olarak sınıflandırmadaki başarısı

değerlendirilmiştir. Chebyshev filtrelerini kullanarak geliştirilen GCNN modeli, uzman gözlemci ile sırasıyla %89.3 ve %91.2'lik bir uyum gösteren hem dinlenme hem de stres testleri için en yüksek algılama performansını elde etmiştir. Son olarak modellerin, kutupsal haritalarının 17 bölümlü ince segmentasyonu ve 3 bölümlü kaba segmentasyonu ile KAH lokalizasyonundaki başarısı hesaplanmıştır. Chebyshev filtrelerini kullanarak geliştirilen GCNN modeli, uzman gözlemci ile sırasıyla %83.1 ve %78.8'lik bir uyum göstermiştir. Çalışmanın sonucunda önerilen model ile KAH teşhisini ve lokalizasyonunu değerlendirmek için kullanılan kutupsal harita veri setlerinin analizi uzmanlara yardımcı olabileceği vurgulanmıştır.

Wang ve ark. 2020 yılında yapmış oldukları çalışmada kapılı MPS görüntülerinden sol ventrikül (LV; left ventricular) segmentasyonunu ve kantifikasyonunu MÖ yöntemi kullanarak gerçekleştirmeye çalışmışlardır (Wang, Lei et al. 2020). Böylece kapılı MPS görüntüleme ile LV miyokardiyumu otomatik olarak segmentlere ayrılmış olup LV miyokardiyumun hacmi ölçülmüştür. Bu işlemler sayesinde LV fonksiyonel değerlendirmenin performansı artırılarak KAH teşhisi/prognozu ve hasta risk değerlendirmesi yapılmak istenmiştir. Çalışma kapsamında retrospektif olarak incelenen 32 normal hasta ve 24 anormal hasta olmak üzere toplamda 56 hastanın MPS görüntü veri seti kullanılmıştır. SPECT LV miyokardiyumun otomatik segmentasyonunu yapabilecek modeli geliştirmede ESA olan çok sınıflı 3D V-Net mimarisi kullanılmıştır. Doktorlar tarafından çizilmiş SPECT LV miyokardiyumun endokardiyal ve epikardiyal yüzeyinin klinik konturları önerilen modelin hedefi olarak belirlenmiştir. Orijinal MPS görüntülerine uygulanan çeşitli işlemlerden sonra MPS veri seti hacim tabanlı bir derin öğrenme ağı ile eğitilmiştir. Geliştirilen modelin performansını değerlendirmede otomatik LV miyokard segmentasyonu ile klinik LV miyokard segmentasyonu arasındaki kontur farkları karşılaştırılmıştır. LV miyokardiyum hacminin, klinik LV segmentasyonu ile otomatik LV segmentasyonu arasındaki korelasyon katsayısı 0.910 ± 0.061 ve ortalama bağıl hatası $\%1.09 \pm 3.66$ olarak hesaplanmıştır. Bu bulgular otomatik MPS segmentasyonunun klinik MPS segmentasyonuna yakın sonuçlar verebileceğini göstermiştir.

Trung ve ark. 2020 yılında yapmış oldukları çalışmada SPECT MPI görüntülerinden elde edilen kutup haritaları ve kesit görüntüleri sayesinde KAH tanısını analiz edebilecek bir derin öğrenme (DÖ) modeli geliştirmişlerdir (Trung, Ha et al. 2020). Bu çalışmada, 108 Askeri Merkez Hastanesi Nükleer Tıp Bölümü'nde 2015-2018 yılları arasında SPECT tarama ile elde edilmiş 1413 kalp SPECT görüntüsü kullanılmıştır. DÖ modelin çıktısı bir hastanın çıktı ağırlığına göre değerlendirilmiş (0-1 aralığında) ve çıktı ağırlığı 0.7'den büyükse KAH, 0.7 veya 0.7'den küçükse KAH olmayan olarak sınıflandırılmıştır. Orijinal boyutu $1920 \times 1080 \times 3$ olan görüntülerin normalizasyonunu sağlamak için kesit görüntüleri $1080 \times 1640 \times 3$ 'e, kutup haritası görüntüleri $314 \times 314 \times 3$ 'e kırılmıştır. DÖ ağı, 16 evrişimli katman içeren VGG ağına dayalı olarak geliştirilmiştir. Çalışmada kullanılan dilim MPI görüntüleri ile kutup harita görüntüleri geliştirilen ağa beslenerek KAH teşhisi konulmuştur. Ortalama hassasiyet, dilim MPI görüntüleri kullanılarak $\%86.14 \pm \%2.14$, kutup haritası görüntüleri kullanılarak $\%82.57 \pm \%2.33$ elde edilmiştir. Çalışma sonucunda, derin öğrenme modeli ile dilim MPI görüntülerinin kutup haritası görüntülerine göre KAH tanısında daha başarılı olduğu çıkarımı yapılmıştır.

Berkaya ve ark. 2020 yılında yapmış oldukları çalışmada, SPECT MPI görüntü verilerini kullanarak perfüzyon anomalilerin (miyokardiyal iskemi ve/veya enfarktüs) otomatik analizini yapabilecek DÖ tabanlı ve bilgi tabanlı olmak üzere iki farklı bilgisayar destekli sınıflandırma modeli geliştirmeye çalışmışlardır (Berkaya, Sivrikoz et al. 2020). Önceden eğitilmiş çeşitli DSA'lardan çıkarılan derin ve sığ özelliklere sahip destek vektör makineleri (SVM) ile veriler yüksek doğrulukta sınıflandırılmıştır. Bilgi tabanlı modelin tasarımı aşamasında uzmanların bilgileri uygun görüntü işleme yöntemlerine (belirli renk eşikleme, bölümlenme, özellik çıkarma ve bazı buluşsal yöntemler) dönüştürülerek SPECT görüntülerinin sınıflandırılması yapılmıştır. Çalışmada, kısa eksen (SA), yatay uzun eksen (HLA) ve dikey uzun eksen (VLA) dilimlerine sahip yeni SPECT MPI görüntü veri seti oluşturulmuştur. Veri seti rastgele olarak her sınıf için eğitim (%66), doğrulama (%17) ve test (%17) olmak üzere üç gruba ayrılmış halde araştırma topluluğunun kullanımına sunulmuştur (<https://www.kaggle.com/selcankaplan/spect-mpi>(Anonim 1: 2022)). 2018-2019 arası dönemde Eskişehir Osmangazi Üniversitesi Nükleer Tıp Anabilim Dalı'na istirahat ve stres SPECT MPI taraması için sevk edilen 192 hasta ile çalışılmıştır. Uzmanlar tarafından iki farklı sınıf etiketi (1: normal ve 2: anormal) ile etiketlenen SPECT MPI görüntüleri sınıflandırılarak yorumlanmıştır. Bir milyondan fazla görüntü üzerinden önceden eğitilmiş olan ve görüntüleri 1000 farklı nesne kategorisinde sınıflandırabilen GoogLeNet, AlexNet, ResNet-18, VGG16, VGG19, DenseNet-201, NASNet-Large DSA ağ mimarileri transfer öğrenmede kullanılmıştır. DÖ tabanlı model için maksimum doğruluk %94, duyarlılık %88, özgüllük %100 ve bilgi tabanlı model için maksimum doğruluk %93, duyarlılık %100, özgüllük %86 olarak hesaplanmıştır. Çalışmanın sonucunda, geliştirilen her iki modelin de miyokardiyal iskemi ve/veya enfarktüs ile ilgili perfüzyon anomalilerin tespitini uzman yorumuna yakın şekilde yapabildiği gösterilmiştir.

Ramon ve ark. 2020 yılında yapmış oldukları çalışmada düşük doz radyonüklid kullanılan SPECT MPI taraması görüntüleri üzerinde DÖ yöntemi uygulayarak gürültü gidermeye (denoising) ve perfüzyon kusurlarının analizini iyileştirmeye çalışmışlardır (Ramon, Yang et al. 2020). DÖ modelinde, biri evrişimli otomatik kodlayıcı (CAE) ve diğeri ESA olmak üzere iki sinir ağı kullanılmıştır. CAE'nin girdi katmanında bulunan yığılmış kodlayıcı yapısı sayesinde düşük dozlu girdi görüntüsü kodlanmış, çıktı katmanında bulunan yığılmış kod çözücü yapısı sayesinde ise çıktı görüntüsü çözülerek sonuçta gürültü gidermesi yapılmıştır. ESA'nın tüm katmanlarında bulunan evrişimli katmanlar yardımıyla da gürültü giderilmiş yeni görüntüler ile ESA ağı eğitilmiştir. Bu çalışmada, Massachusetts Üniversitesi Tıp Fakültesi'ne 2013-2018 yılları arasında başvuran 1052 hastanın SPECT/CT tarama ile elde edilen düşük doz (girdi) ve tam doz (hedef) klinik kardiyak SPECT MPI görüntü çiftine sahip veri setleri kullanılmıştır. Bu görüntülerin 490'ı normal, 372'si perfüzyon veya hareket anomalili ve 190'ı biraz normal olarak gruplanarak DÖ modelinin eğitimi (740 hasta), testi (190 hasta) ve doğrulanması (122 hasta) yapılmıştır. Çalışma sonucunda elde edilen veriler, önerilen DÖ yaklaşımının gürültü giderme konusunda önemli fayda sağladığı ve böylece düşük doz hızlı verilerde tanısal doğruluğu geliştirdiği görülmüştür. Konvansiyonel yöntemlerle kıyaslandığında, DÖ ile gürültü giderme işleminin SPECT/MPI görüntülerinde tanısal doğruluğu azaltmadan doz azaltımı sağladığı belirtilmiştir.

Badano ve ark. 2020 yılında yapmış oldukları çalışmada ekokardiyografi,

kardiyak manyetik rezonans (KMR), kardiyak bilgisayarlı tomografi (KBT) ve nükleer kardiyak görüntüleme yöntemleri ile elde edilen kardiyovasküler görüntülerdeki anormalliklerin tanısının yapay zeka algoritmaları ile de mümkün olabileceğini gösteren son uygulamaları özetlemeye çalışmışlardır (Badano, Keller et al. 2020). 2D ekokardiyografi görüntüleri ile yapılan bir çalışmada, geliştirilen ESA'ya dayalı bir derin öğrenme (DÖ) modeli (EchoNet), görüntüdeki kardiyak yapıları belirleyebilmiş, işlevlerini değerlendirebilmiş ve sistemik fenotipleri tahmin etmiştir. Moghaddasi vd. 3D ekokardiyografi görüntüleri ile yaptıkları çalışmada, SVM sınıflandırıcısını kullanarak kalp kapak hastalıklarından biri olan mitral yetersizliğinin ciddiyetini belirlemeyi hedeflemişlerdir (Moghaddasi and Nourian 2016). SVM sınıflandırıcısı ile 139 hasta arasında normal mitral kapak tespiti için %99.52 ve hafif, orta ve şiddetli mitral yetersizliğinin belirlenmesi için sırasıyla %99.38, %99.31, %99.59 doğruluk kaydedilmiştir (Genel duyarlılık=%99.38 ve özgüllük=%99.63). KMR görüntüleri için yapılan ve 1049 hastadan oluşan diğer bir çalışmada MÖ ile miyokardiyal kan akışında ve miyokardiyal perfüzyon rezervinde bir azalma (otomatik çevrimiçi kantifikasyon stresi MBF ve miyokardiyal perfüzyon rezervi ile ölçülmüştür), diğer klinik risk belirteçlerinden bağımsız olarak hem ölüm hem de majör advers kardiyak olaylarla bağımsız olarak ilişkilendirilmiştir (Knott, Seraphim et al. 2020). Kardiyak bilgisayarlı tomografi görüntüleri için yapılan çalışmada ise, Wolterink vd., koroner arter kalsifikasyonunun (CAC) AI ile CCT anjiyografide doğru bir şekilde tanımlanabileceğini ve ölçülebileceğini ortaya koymuştur (Wolterink, Leiner et al. 2016). ConvPairs (CNN çiftleri) kullanan yöntemler ile %72 hassasiyete ulaşmıştır. Çalışmanın sonucunda yapay zeka modelleri ile kardiyak görüntülerin analizi sağlanarak iş yükünü, gereksiz testleri ve hasta sonuçlarını iyileştirerek sağlık hizmeti maliyetlerini azaltabileceği düşünülmüştür.

Chen ve ark. 2021 yılında yapmış oldukları çalışmada Kaohiung Chang Gung Memorial Hastanesi'nde CZT SPECT taraması ile toplanmış miyokardiyal perfüzyon görüntülerinden KAH teşhisini yapabilecek bir derin öğrenme modeli geliştirmişlerdir (Chen, Su et al. 2021). Bu çalışmada, 601'i sağlıklı, 378'i sağlıklı olmayan 979 denek kullanılmıştır. 601 sağlıklı denekten eğitim veri setine rastgele 550 denek, test veri setine 51 denek seçilmiştir. Aynı şekilde 378 sağlıklı denekten eğitim veri setinde rastgele 340 denek, test veri setinde 38 denek bulunmaktadır. İlk olarak görüntülerdeki miyokardiyal olmayan kısımları çıkarmak için görüntülere kırpma işlemi, sonra görüntü seçme yöntemiyle kesit görüntüleri için merkeze yakın görüntüleri seçme işlemi ve son olarak görüntüyü tekrar kırparak miyokardiyumu merkeze hizalama işlemi uygulanmıştır. Geliştirilen DÖ modelinin performansı için kullanılan tahmin doğruluğu %87.64, duyarlılığı %81.58 ve özgüllüğü %92.16 olarak elde edilmiştir. Çalışmanın sonucunda DÖ yöntemi ile CZT SPECT MPI görüntülerinden elde edilen miyokardiyal iskeminin değerlendirmesi yapılarak KAH tanısında uzmanlara yardımcı bir sistem geliştirilebileceği gösterilmiştir.

Liu ve ark. 2021 yılında yapmış oldukları çalışmada sadece stres SPECT MPI görüntüleri üzerinden miyokardiyal perfüzyon anormalliklerinin otomatik teşhisini ve tanısız doğruluğunu artırmayı sağlayabilecek bir DÖ modeli geliştirmişlerdir (Liu, Wu et al. 2021). 2005-2016 arası dönemde Yale New Haven Hastanesi'nde sadece stres ve stres/dinlenme SPECT MPI uygulanan toplamda 37243 hastanın MPS görüntü veri seti kullanılmıştır. Bu veri setinden sadece stres SPECT MPI görüntüleri DÖ modelini

geliştirmek için kullanılmıştır. Geleneksel bir kantitatif perfüzyon kusur boyutu (DS; defect size) yöntemi ile tasarlanan model karşılaştırılarak başarı performansları değerlendirilmiştir. Geliştirilen ESA ağ yapısı iki adım ve 41 katmandan oluşturulmuştur. İlk adımda, ImageNet veri tabanında 1000 kategori sınıflandırma görevi için son teknoloji bir artık ağ olan ResNet-34 mimarisini kullanarak giriş görüntüsünden özellikler çıkarılmıştır. İkinci adımda, olasılığı hesaplamada ise ResNet-34 mimarisi ile 518 özelliği çıkararak ReLU aktivasyonlu iki tam bağlı (FC) katman ve softmax aktivasyonlu bir FC katmanına verilmiştir. Bu ağa toplam 21,3 milyon parametre dahil edilerek DÖ çerçevesi PyTorch platformunda uygulanmıştır. DÖ yönteminin AUC değeri (0.872 ± 0.002), DS yönteminden elde edilen AUC değerine göre (0.838 ± 0.003) önemli ölçüde daha yüksek sonuç vermiştir. Çalışmada oluşturulan sekiz alt grupta DÖ yöntemi, kantitatif DS yöntemine göre karşılaştırıldığında daha küçük standart sapma, yüksek tanısal doğruluk (DÖ Doğruluk: $\%82.7 \pm \%2.5$, DS Doğruluk: $\%78.5 \pm \%3.6$) ve özgüllük (DÖ Özgüllük: $\%84.9 \pm \%3.7$, DS Özgüllük: $\%77.5 \pm \%6.5$), tutarlı AUC değerleri (AUC DÖ: 0.865 ± 0.010 , AUC DS: 0.838 ± 0.019) elde edilmiştir ancak DS yöntemine göre ise daha düşük duyarlılık (DÖ Duyarlılık: $\%74.4 \pm \%4.2$, DS Duyarlılık: $\%79.8 \pm \%5.8$) değerine sahiptir. Çalışmanın sonuçları, DÖ yöntemi ile yalnızca stresli MPI görüntülerinin miyokardiyal perfüzyon durumunun değerlendirilmesinde tanısal performansını iyileştirebileceğini gösterilmiştir.

Papandrianos ve ark. 2021 yılında yapmış oldukları çalışmada, SPECT_MPI taraması yapılan hastaların iskemi veya enfarktüs durumunu DÖ metodu kullanarak değerlendirilmesi amaçlanmıştır (Papandrianos and Papageorgiou 2021). Nükleer kardiyolojik görüntülerin yorumlanmasında standart bir uygulama haline getirilebilecek TÖ yaklaşımının KAH tanısındaki doğruluğu, hızlılığı ve kararlılığı incelenmiştir. Slart ve ark. nükleer kardiyovasküler görüntüleme tekniklerini kullanarak elde edilen görüntüler üzerinde teşhis performansını artırmak için karmaşık görüntü analizinin yorumlanmasını DÖ yöntemleri ile standartlaştırmayı amaçlamışlardır (Slart, Williams et al. 2021). Çalışma kapsamında 2013-2017 arası dönemde Diagnostik Tıp Merkezi Nükleer Tıp Kliniğinde (“Diagnostiko-Iatriki A.E.”, Larisa, Yunanistan) dinlenme ve stres SPECT MPI çekimi uygulanan 224 hastaya ait retrospektif görüntülerden oluşturulan veri seti kullanılmıştır. İskemi veya enfarktüs değerlendirilmesi araştırılan bu çalışmada enfarktüslü 8 hasta, iskemili 142 hasta, hem enfarktüslü hem de iskemili 8 hasta ve 61 hasta normal olarak dağılım göstermiştir. DÖ modelinin eğitim ve test aşamasında normal (1) ve anormal (2) olmak üzere iki sınıflı bir etiket oluşturulmuştur. Geliştirilen ESA mimarisi tarafından her görüntüye belirli bir etiket atanarak sınıflandırma işlemi yapılmıştır. Yakın zamanda kemik sintigrafisi görüntülerinin sınıflandırılmasında kullanılan RGB_CNN algoritması ile TÖ algoritmalarının (VGG16, DenseNet, MobileNet ve InceptionV3) görüntüleri yüksek doğrulukta kategorize etme yetenekleri araştırılmıştır. Çeşitli ağ yapısı denemeleri yapılan en iyi RGB_CNN mimarisinde piksel boyutu $250 \times 250 \times 3$, yığın boyutu 8, bırakma değeri 0.2, evrişimli katman sayısı 5 (16-32-64-128-256), yoğun düğümleri 32-32 ve devir sayısı 500 olan algoritma yer almıştır. Önerilen çalışmada sınıflandırma doğruluğu $\%94$, duyarlılığı $\%78$, özgüllüğü $\%94$ ve AUC değeri 0.93 olarak hesaplanmıştır. Çalışmanın sonucunda, küçük SPECT MPI görüntü veri seti kullanılarak basit ağ yapısına sahip RGB_CNN mimarisi ile KAH tanısının yüksek doğrulukta genelleştirilebileceği düşünülmektedir.

Bu tez kapsamında yapılan çalışmanın literatürdeki çalışmalardan farkı, kardiyak SPECT görüntüleme veri setlerinin ESA kullanılarak gözetimsiz bir şekilde iskemi değerlendirmesinin yorumlanmasına katkı sağlaması ve KAH tanısını doğru ve hızlı bir biçimde gerçekleştirmesi olacaktır. İskemi değerlendirmesini yapan ESA'nın başarı performansını artırmak için TÖ tekniği kullanılmıştır. Akdeniz Üniversitesi Nükleer Tıp Anabilim Dalı'nda Mart 2021-Aralık-2021 tarihleri arasında kardiyak SPECT tarama uygulanmış hastalara ait görüntüler kullanılarak veri setleri oluşturulmuştur. Böylece ESA ile KAH tanısı için önemli parametre olan iskemi değerlendirmesi yapılmıştır.

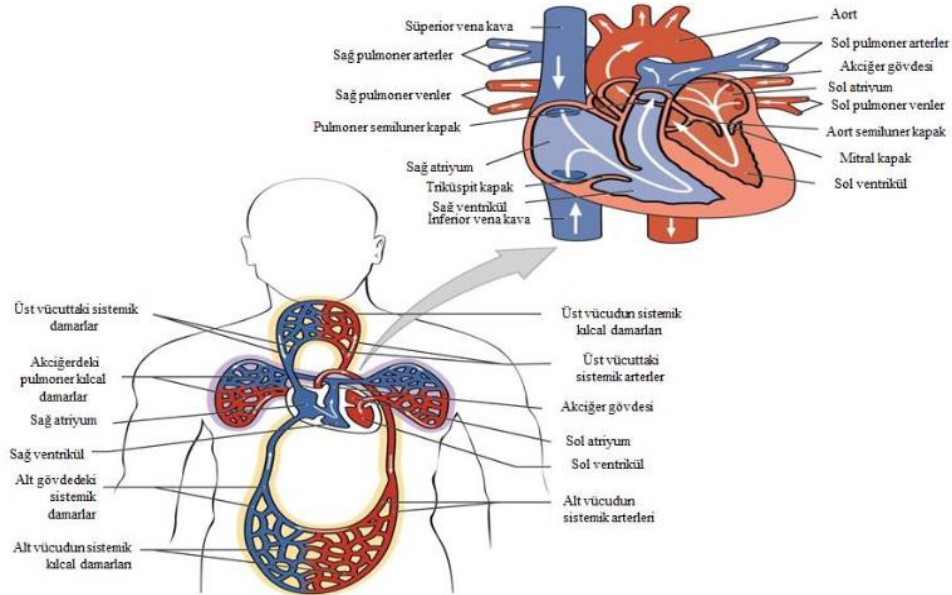
3. MATERYAL VE METOT

3.1 Kalp ve Koroner Arter Hastalığı

3.1.1 Kalbin Anatomisi ve Dolaşım Sistemi

Dolaşım sistemi temel olarak kalp, kan ve damarlardan oluşur ve vücuttaki başlıca görevi, gerekli besin maddelerini taşıma ve doku metabolizmasının atık ürünlerini ortamdaki uzaklaştırarak insan vücudundaki hücrelerin canlı kalmasını sağlamaktır (Sataloff et al., n.d.). Dolaşım sistemi, *pulmoner dolaşım* ve *sistemik dolaşım* olmak üzere iki farklı sistemin birleşimidir. Pulmoner dolaşım, kalp ve akciğerler arasında kapalı bir devre oluşturan bir kan damarı sisteminden oluşur, sadece kalbe ve akciğerlere kan sağlar. Sistemik dolaşım, vücuttaki tüm dokulara oksijenli kanı ulaştıran ve oksijeni giderilmiş kanı geri toplayan bir damar devresinden oluşur.

Dolaşım sisteminin önemli organlarından biri olan kalp, insan vücudunda pompa görevi üstlenerek kanı damarlar aracılığıyla organlara, dokulara ve hücrelere ileterek vücudun oksijen ile besin ihtiyacını karşılar (Şekil 3.1). Kalbin vücutta anatomik konumu, göğüs kemiğinin (sternum) arkasında, nefes borusunun (trakea), yemek borusunun ve inen aortun önünde, akciğerler arasında ve diyaframın üzerinde göğüs boşluğunda bulunur. Kalbin yaklaşık üçte ikisi sternumun solunda, geri kalanı ise sağında yer alır. Kalbin duvarı epikardiyum (dış katman), miyokardiyum (orta katman) ve endokardiyum (iç katman) olarak üç ayrı katmandan oluşur.



Şekil 3.1. Kalbin yapısı ve kan akışının yolu (Anonim 2: 2022)

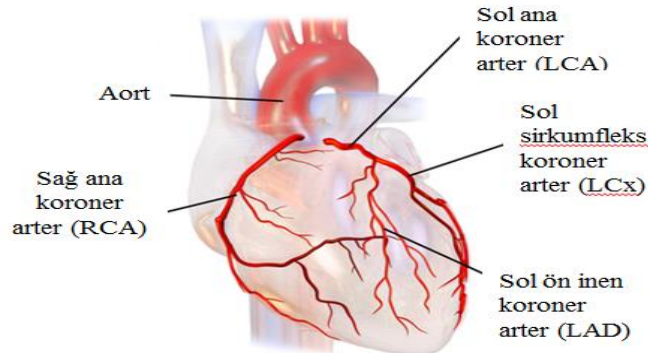
İnsan kalbi dört odacıklı bir sisteme sahiptir. Kalp boşluğu, ortadan sağ ve sol kalp olmak üzere ikiye bölünmüştür. Alt odacıklar ventrikül ve üst odacıklar atriyum olarak adlandırılmıştır. Süperior vena kava ve inferior vena kava damarlar ile vücuttaki

venöz kan sağ atriyuma toplanır. Kan daha sonra triküspit kapaktan sağ ventriküle geçer ve kanı pulmoner arterden akciğerlere gönderir. Akciğerlerde venöz kan temiz hava ile oksijenlenir. Oksijenli kan, pulmoner damarlar yoluyla sol atriyuma gönderilir.

Sağ kulakçığın kasında bulunan sinoatriyal (SA) düğümünden gelen elektriksel uyarılarla kalp uyarılır ve miyokardiyal kasılmalar oluşur. Sinoatriyal düğümünden gelen bir uyarı, iki kulakçığın kasılmasına neden olarak kanı ventriküllere gönderir. Ventriküllerin kasılması, iki kulakçığın birleşim yerinde bulunan atriyoventriküler (AV) düğümünden gelen uyarılarla kontrol edilir. Kasılmanın ardından ventriküller gevşer ve içlerindeki basınç düşer. Kan tekrar kulakçıklara akar ve sinoatriyal düğümünden gelen bir dürtü döngüyü yeniden başlatır. Bu sürece *kalp döngüsü* denir.

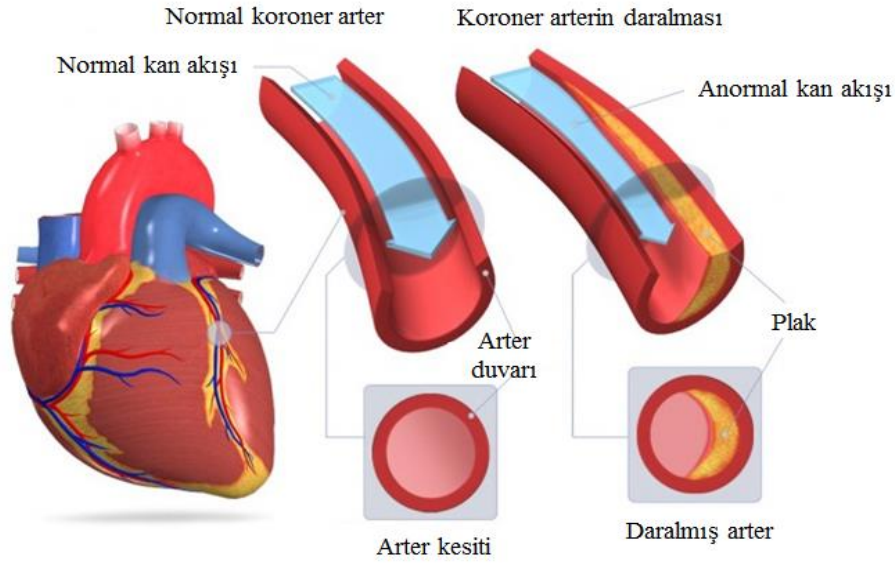
3.1.2 Koroner Arterler ve KAH

Kalp, sağ (RCA) ve sol (LCA) olmak üzere iki ana koroner arterden oluşur. LCA, sol ön inen arter (LAD) ve sol sirkumfleks (LCx) olarak adlandırılan iki ana dala ayrılır. Sağ, sol, ön inen ve sol sirkumfleks koroner arterlerin birçok dalı vardır (Şekil 3.2). Kalp kesintisiz bir şekilde oksijene ihtiyaç duyar. Koroner arterlerin tıkanması, kalbin işlevsel bozukluğuna yol açarak kardiyak miyositlerin ölümüne sebep olur. Bunun sonucunda *miyokard enfarktüsü* adı verilen *iskemik miyokardiyal hücre ölümü* meydana gelir.



Şekil 3.2. Koroner Arterler (Anonim 3: 2022)

- **Koroner Arter Hastalığı (KAH):** Kalbi besleyen damardaki kan akışının tıkanmasına neden olan hastalıkları tanımlar. Koroner kalp hastalığı (KKH), ilerlemiş KAH'ndan kaynaklanabilecek tüm semptom ve özellikleri tanımlamak için kullanılan bir terimdir. Aynı semptomlar, iskemik kalp hastalığı olarak da teşhis edilir, çünkü semptomlar miyokardiyal iskeminin (kalp kasına kan akışının azalması) gelişmesinden kaynaklanır. Koroner ateroskleroz ile KAH'nın klinik semptomları arasında veya KAH ile KKH arasında bire bir ilişki yoktur. KAH'na en sık ateroskleroz neden olmakla birlikte, nadir durumlarda kan damarlarının iltihaplanması, koroner damarların tıkaçıcı lezyonlarına neden olabilir (Şekil 3.3). KAH'nı KKH'na dönüştüren etkilerin başında koroner tromboz (kan pıhtılarının oluşumu), koroner spazm ve kalp kasının hemodinamik (kan akışı) gösterilebilir (Sataloff et al., n.d.).



Şekil 3.3. Koroner Arter Hastalığı ve Kan Akışı (Anonim 2: 2022)

- **Koroner Kalp Hastalığı (KKH):** Birbirine bağlı bir dizi sendromu içerir. Bu diziler, anjina pectoris, akut miyokardiyal enfarktüs ve ani kalp ölümüdür. Ayrıca miyokardiyal iskeminin (miyokardiyuma veya kalp kasına kan beslemesinin olmaması) varlığını gösteren koroner arter tıkanıklığının özellikleri de vardır.

Kardiyovasküler hastalıkların birçoğu, ateroskleroz komplikasyonlarından kaynaklanır. Ateroskleroz, genellikle atardamar duvarında lipidlerin, fibröz elementlerin ve inflamatuvar hücrelerin ve moleküllerin birikmesi ile karakterize edilen ilerleyici bir hastalıktır. Ateroskleroz lezyonları esas olarak büyük ve orta büyüklükteki elastik ve kaslı arterlerde ortaya çıkar ve kalp, beyin veya ekstremitelerde *iskemiye* yol açarak enfarktüsle sonuçlanabilir. Çevre, yaşam tarzı ve genetik faktörlerin etkileriyle ilerleyen kronik bir hastalık sürecidir (Sydorova, n.d.).

3.2 Kardiyovasküler Hastalıklarda Kullanılan Tıbbi Görüntüleme Yöntemleri

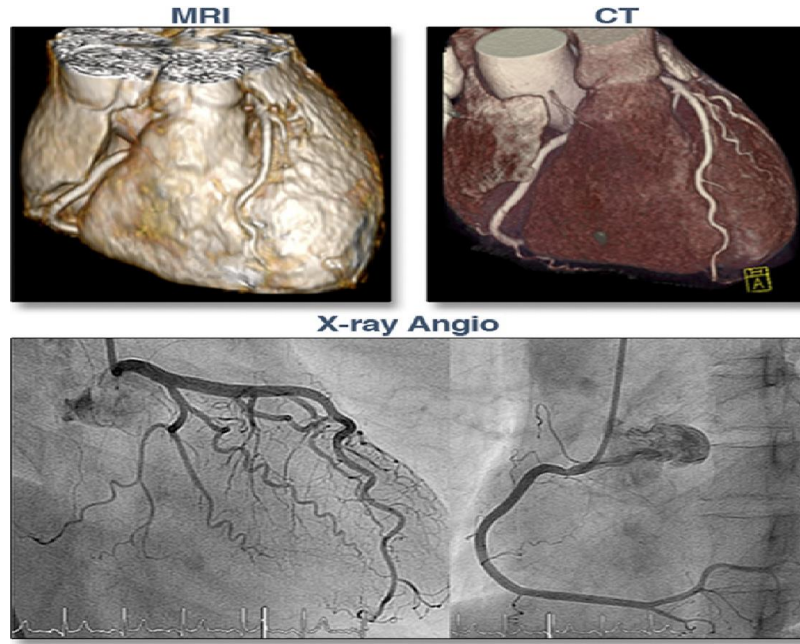
Kardiyovasküler hastalıkların tanı ve tedavisi için radyografik, ultrasonik, manyetik rezonans ve nükleer tıp teknikleri sıralanabilir. Birçok kalp hastalığı, kardiyak pompa aktivitesinin performansı üzerinde bir etkiye sahip olduğundan, kalp performansının (kardiyak fonksiyon) doğru ve tekrarlanabilir bir şekilde değerlendirilmesi, hastalığın ciddiyetini belirlemek ve tedavinin etkinliğini değerlendirmek için çok önemlidir.

- **X-Işını Anjiyografisi:** Radyografik prosedürlere standart göğüs röntgeni ve anjiyografi örnek olarak verilebilir. Anjiyografinin amacı, kan damarlarının tanısal amaçlarla ya da müdahaleler için görüntülenmesini sağlar. Çoğu standart X-ışını anjiyografisi, ilgili organa, özellikle beyine veya kalbe giden bir kateterin sokulması yoluyla bir artere kontrast maddenin enjekte edilmesini içerir. Kateter femoral artere, radyal artere hatta nadir durumlarda karotis artere yerleştirilebilir ve ardından floroskopi kılavuzluğunda potansiyel patolojinin bulunduğu yere yönlendirilebilir.

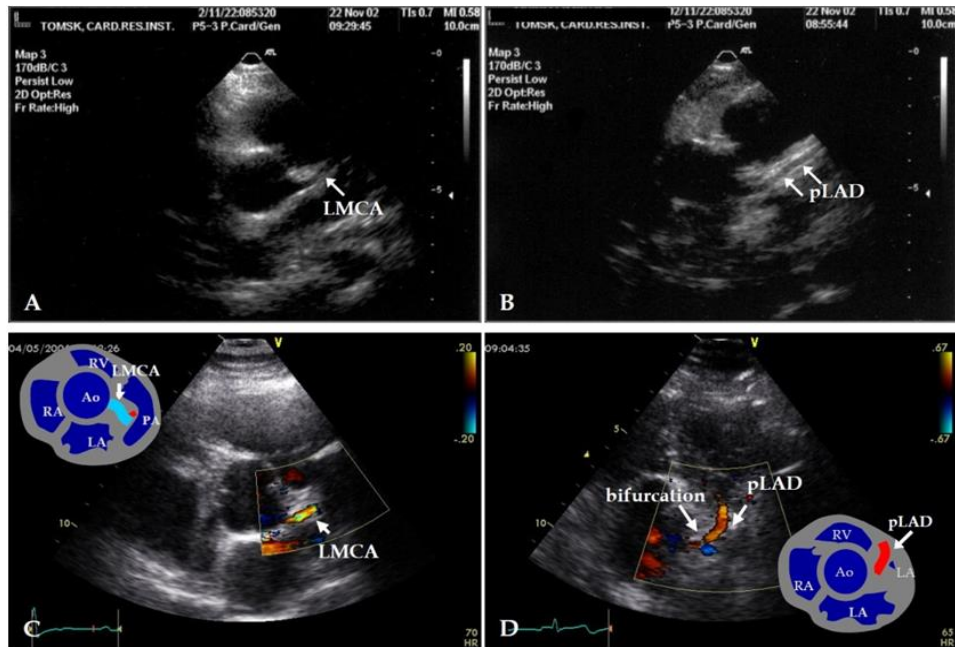
Hastaya kontrast madde uygulandıktan sonra genellikle perkütan erişim yoluyla kalp ve koroner arterlerdeki X-ışını zayıflamasının büyüklüğü değerlendirilerek kalbin ve koroner arterlerin büyük anatomik değişiklikleri değerlendirilebilir. Damar dallanmasını görselleştirmek için bu lokalizasyon prosedürü sırasında iyot kontrast maddesi enjekte edilebilir. İyot miktarı ve konsantrasyonu damara, boyutuna ve akış hızına ve kateter ucundaki enjeksiyon orijininin ilgi alanına (ROI) olan mesafesine bağlıdır. Kontrast ortamının kan tarafından kontrastın saptanamayacağı noktaya kadar seyreltildiği hızın belirlenmesi, kan akışına ve damar dallanma yapısına bağlı olacaktır.

- **BT Anjiyografisi:** Bilgisayarlı tomografi anjiyografi (BTA), kan dolaşımına enjekte edilen bir boya olarak da bilinen bir kontrast madde yardımıyla görülebilen kan damarlarını ve organlardan kan akışını değerlendirmek için kullanılır. Tanısal BT tarayıcıları, 0.5 mm'lik uzamsal çözünürlüklerde ve %1'lik kontrast farklılıklarında daha iyi 3D anatomik insan görüntüleri verir. Bu tarayıcıların klinik bir amacı, aort, koroner ve nörolojik arterlerdeki tıkanıklıkları ve anörizmaları (zayıflamış bir damar duvarında bir çıkıntı) teşhis etmektir. Diğer bir klinik amaç, organdaki kan akışını ve kardiyak işlevi ölçerek çoğunlukla dinamik tarama yoluyla organ işlevini değerlendirmektir.
- **Manyetik Rezonans Görüntüleme (MRG) Yöntemi:** Kalpte proton yoğunluğunun uzaysal dağılımını değerlendirerek kalbin ve koroner arterlerin anatomik ve fonksiyonel bilgisini sağlar. Kardiyak MRG teknikleri, KAH hastalarında öncelikli olarak KAH'ın iskemik sonuçlarını değerlendirmede kullanılır. Miyokardiyal perfüzyon ve geri dönüşü olmayan miyokardiyal hasar hakkında da bilgi verir. Kardiyak MRG, tıpkı insan vücudunun diğer bölümlerinin MRG'sinde olduğu gibi proton rezonansına dayanır. Kardiyak MRG, EKG senkronizasyonu sırasında elde edilir. Özellikle kardiyomiyopati, konjenital hastalık ve enfarktüsün değerlendirilmesi ve noninvazif karakterizasyonunda çok sayıda kalp hastalığının değerlendirilmesi için uygundur. Kardiyak MRG, invazif bir prosedürden kaçınmayı sağlar ve/veya sonraki invazif prosedürlerin kılavuzluğunu geliştirerek doğruluklarını artırır. Kardiyak MRG'nin temel avantajı, iyonlaştırıcı radyasyon dozunun tamamen yokluğuna ve en güvenli kontrast ortamlarından biri olarak kabul edilen paramanyetik kontrast ortamının minimum uygulanmasına dayanır.
- **Ekokardiyografi Görüntüleme Yöntemi:** Ultrasonik prosedürlere ekokardiyografi örnek verilebilir. Ekokardiyografi, kardiyovasküler sistemin çalışırken gerçek zamanlı görüntülerini oluşturmak için ultrason kullanır. Kalbin farklı görünümünü elde etmek için farklı projeksiyonlara bir dönüştürücü yerleştirilir. Ekokardiyografik görüntüler, dönüştürücü farklı kalp dokuları arasındaki akustik empedanstaki farklılıklar nedeniyle yansıyan dalgaları aldığı ve sonrasında ultrasonu elektrik sinyallerine dönüştürdüğünde oluşturulur. Yankı sinyalleri elektronik olarak güçlendirilir ve gri tonları (siyahtan beyaza) kullanılarak bir monitörde görüntülenir. Ekokardiyografi, kardiyak anatomi ve fonksiyonun invazif olmayan değerlendirmesi için ilk seçenek yöntemdir. Tanıda daha fazla bilgi elde etmek için Doppler etkisi gibi ek fiziksel prensipler de kullanılabilir (Şekil 3.5). Ekokardiyografi, iyonlaştırıcı radyasyona maruz kalmadan, temel olarak güvenli noninvaziv yöntem ile ilgili birçok avantajı olan sağlam bir araçtır. Ayrıca, ucuzdur ve kalbin yapısını ve işlevini hızlı bir şekilde değerlendirmek için anlık yapılabilir. Öte yandan ultrason görüntülemenin bazı dezavantajları vardır. Örneğin ultrason, sesin nüfuz edemediği kötü bir ekokardiyografik penceresi olan hastaları incelemekte bazı zorluklar yaşar.

Ekokardiyografinin diğer bir önemli dezavantajı, sağ ventriküler hacimleri ve ejeksiyon fraksiyonunu görselleştirme ve ölçmedeki zorluktur.

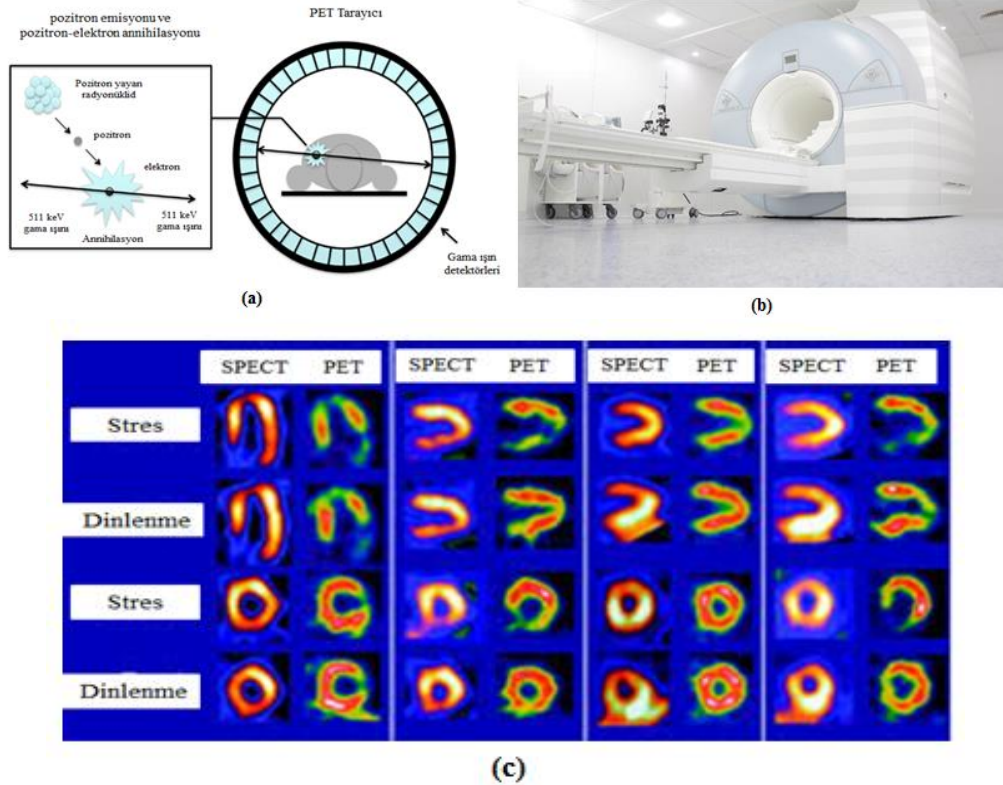


Şekil 3.4. Normal MRG, BT ve X-Işını Anjiyografisinin Temsili Örneği (Hamdan, Asbach et al. 2011)



Şekil 3.5. LMCA ve proksimal LAD (pLAD) görüntüleri. A - LMCA, B modu; B - pLAD, B modu; C - LMCA, Renkli Doppler haritalama; D - LMCA'nın çatallanması; Renkli Doppler haritalama (Boshchenko, Vrublevsky et al. 2011)

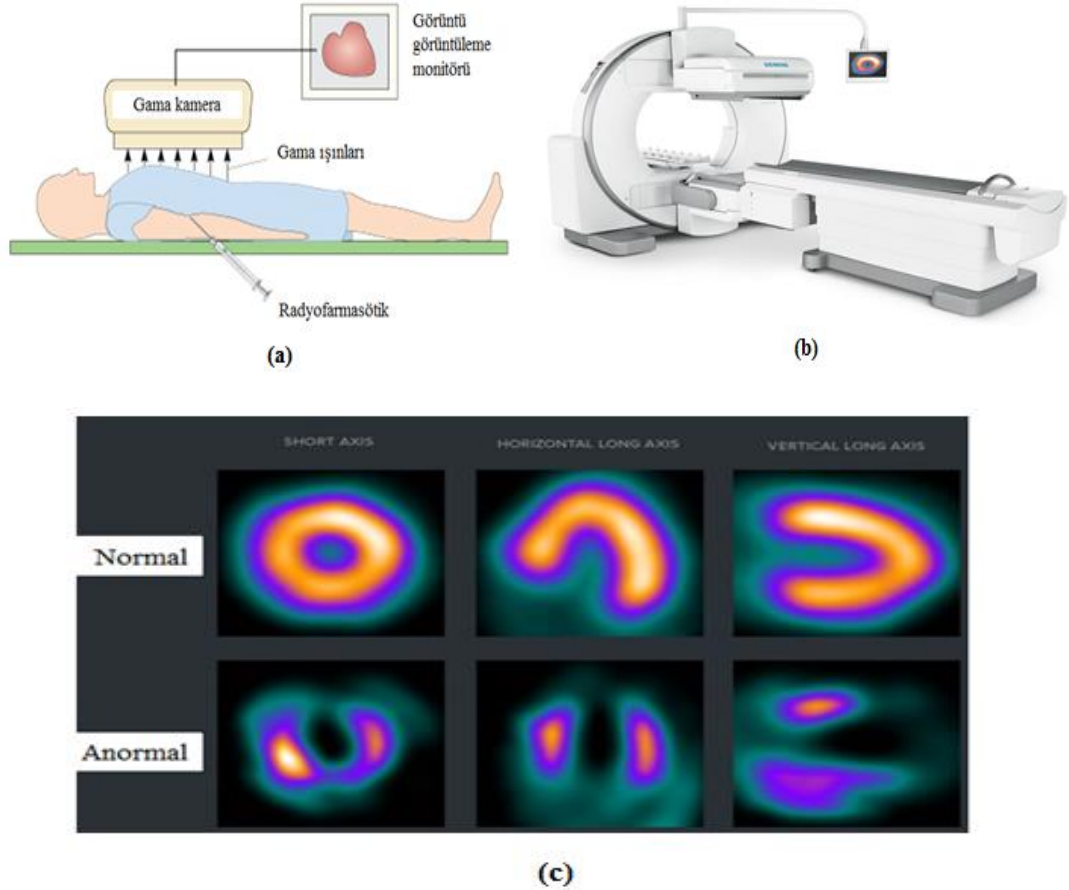
- Pozitron Emisyon Tomografisi Yöntemi (PET Görüntüleme):** Hem elektronun hem de pozitronun yok olması mantığına dayanır, yaklaşık olarak zıt yönlerde hareket eden bir çift yok etme (gama) fotonu üretir. PET, ilgilenilen organlarda radyonüklit dağılımının kesitsel 3B görüntülerini üretmek için kullanılır. PET'te radyonüklit pozitron emisyonu yoluyla bozunur ve ardından serbest bir elektronla yok edilme sonrası doğrusal yol alan iki eş 511 keV gama ışını üretimiyle sonuçlanır (Şekil 3.6). Miyokardiyal perfüzyon PET, ekipmanın maliyetinin yüksek olması nedeniyle daha az sıklıkla gerçekleştirilir, ancak rutin zayıflama düzeltmesi, stres/dinlenme miyokardiyal kan akışını ölçme yeteneği ve perfüzyon akış rezervi gibi SPECT'e göre bazı avantajlar sunar. SPECT'ten daha fazla duyarlılığa ve özgüllüğe sahiptir. PET'in temel dezavantajı, perfüzyon radyotraktörlerinin çok düşük yarı ömrü olması özelliğinden dolayı yakınlarda pahalı bir siklotron bulundurma ihtiyacıdır.



Şekil 3.6. (a) PET Görüntüleme Yöntemi (van der Veldt, Smit et al. 2013); (b) PET Cihazı (Anonim 3: 2022); (c) Örnek bir kalp SPECT/PET görüntüsü (Merhige, Breen et al. 2007)

- Tek Fotonlu Emisyon Tomografisi Yöntemi (SPECT Görüntüleme):** KAH'da iskemi değerlendirilmesi için en çok tercih edilen görüntüleme yöntemidir. KAH'da kalp dinlenme durumundayken beslenebilir, egzersiz durumuna geçtiğinde kalbi besleyen arter damarlardaki daralma veya tıkanmadan dolayı beslenemez hale gelir ve yetersiz oksijenlenen organ-dokularda iskemi gerçekleşmektedir. SPECT sistemi, stres-dinlenme çekimli görüntüler oluşturarak kalbi besleyen dokuların ve

damarların iskemik/canlılık durumunu değerlendirmeye yardımcı olur. SPECT tarama sisteminde vücuda enjekte edilen radyofarmasötik hedef doku tarafından tutulur ve o bölgeden yayımlanan gama fotonları Şekil 3.7’de gösterildiği gibi hasta etrafına konan gama kameraları ile algılanır. Toplanan ham veriler bilgisayarda işlenerek kalbin tomografik görüntüsü oluşturulur.



Şekil 3.7. (a) SPECT Görüntüleme Yöntemi; (b) SPECT Cihazı (Anonim 4: 2022) ; (c) Örnek bir kalp SPECT görüntüsü (Anonim 5: 2022)

3.3 SPECT Görüntüleme Yöntemi


3.3.1. SPECT Sisteminin Bileşenleri

SPECT sistemi ile anatomik görüntülerin toplanması için kullanılan gama kamerası sisteminin temel bileşenleri kolimatör, sintilasyon (parıldama) kristali, foton çoğaltıcı tüpler, pozisyonlayıcı mantık devresi, puls yükseklik analizörü ve görüntü kayıt biriminden oluşur (Şekil 3.8; (Bailey and Humm 2014)). Kolimatör, hasta vücuduna dağılmış radyofarmasötiğin (radyoaktif bileşik) yaydığı gama ışınlarının sadece belli doğrultuda olanlarının görüntüye katkı sunması için gerekli olan kolimasyonu sağlar. Kolimatör, gama ışınlarının içinden geçebileceği farklı geometrik yapıya sahip binlerce

kare, yuvarlak veya hegzagonal paralel kanallardan oluşur. Vücuttan her yöne çeşitli açılarda yayılan gama ışınlarından sadece kolimatörler tarafından izin verilen yönlerden gelen fotonlar geçirilerek sintilasyon kristali üzerine düşmeleri sağlanır. Diğer yönlerden gelen ve kolimatörden geçmeyen fotonlar ise kolimatörün hacminde soğurulur.

Kolimatörün hemen altında çok hassas olan NaI(Tl) kristali yer alır. NaI(Tl) kristali üzerine düşen gama fotonlarından anlamlı bilgi elde edebilmek için gama fotonları görünür dalga boyunu kapsayan sintilasyon fotonlarına dönüştürülür. Kolimatörü geçen gama ışınları NaI(Tl) kristaline ulaştığında kristalin hacminde yer alan safsızlık atomları tarafından tuzaklandığında görünür ışık fotonları meydana gelir. Bu fotonlar daha sonra bir foto-katot yüzeyden geçirildiğinde elektron koparır. Kristalin hemen arkasında bulunan foton çoğaltıcı tüpler (PMT-Photo Multiplier Tube) ise sinyal oluşturma süreci için bu elektronları toplarlar.

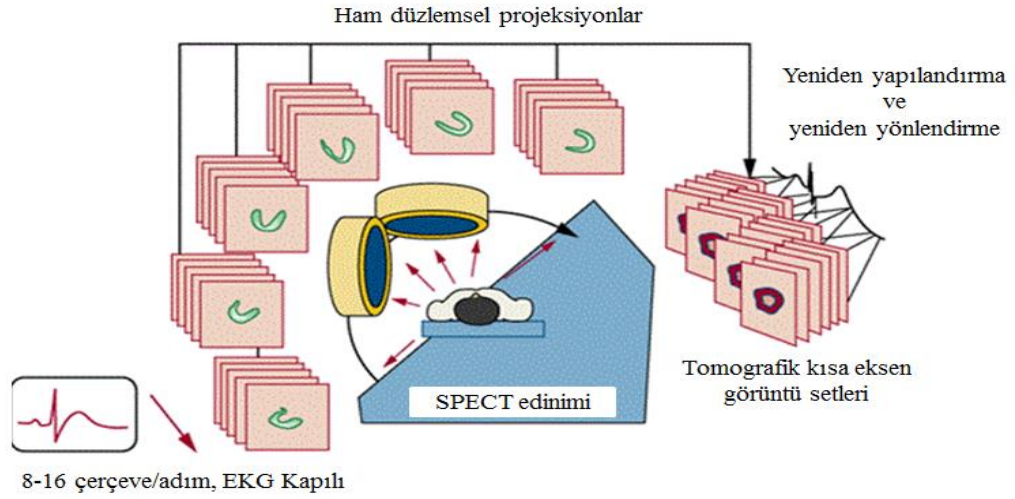
Foton çoğaltıcı tüplerin işlevi, ışın giriş penceresinden tüpe giren elektronları anoda ulaşana kadar dinodlar arasında çoğaltmak ve aşamalı olarak hızlandırmaktır. Dinodlar arasında çoğalan ve enerjileri artan bu elektronlar anotta toplanır ve böylece sintilasyon fotonu anot çıkışında elektrik sinyaline dönüştürülür. Daha sonra bir fotonun oluşturduğu her “darbe” için (puls), detektör üzerindeki çarpma noktası (x, y), farklı PMT’ler tarafından toplanan ışık fotonlarının fraksiyonunun analizi ile elde edilir; ilişkili enerji Z penceresi içindeyse, enerji ayırma devresi olayın bir bilgisayar matrisinde veya “projeksiyon görüntüsünde” toplanmasına izin veren bir sinyal üretir. Bu sinyallerin uzamsal dağılımı vücudun o bölgesinin görüntüsünü meydana getirir.



Şekil 3.8. Geleneksel Anger Kamera ve SPECT

SPECT görüntüleme yönteminin özellikle kardiyovasküler hastalıkların değerlendirilmesinde kullanılan bir tekniği Kapılı (Gated) SPECT'dir. SPECT görüntülerinin elde edilmesinde, detektör hastanın uzun eksenini etrafında dönerek birçok açılarda konumun her birinden projeksiyon görüntüsü elde eder. Görüntü kapılı biçimde elde edildiğinde, her projeksiyon açısında bir kaç (8 veya 16) görüntü alınır ve bu görüntüler kardiyak döngünün “çerçeve” olarak adlandırılan belirli bir aşamasına karşılık gelir (Şekil 3.9). Belirli bir aralık için elde edilen projeksiyon görüntülerinin tümü, bir SPECT veya tomografik görüntü hacmin meydana getirir. Çeşitli kapılı

SPECT aralıklarından gelen görüntü hacimleri 4D formatında (x , y , z ve t) görüntülenebilir ve dinamik kardiyak fonksiyonun değerlendirilmesine olanak sağlar (Cavedon and Rudin 2015). Literatürdeki bazı çalışmalarda Gated SPECT'in zayıflama artefaktlarının farklılaşmasındaki değeri, üç damarlı KAH'nın daha iyi saptanması, kadınlarda KAH tanısı ve iskemik şiddetin değerlendirilmesi açısından klinik olarak daha yararlı bilgi verdiği gözlemlenmiştir (Cullom, Case et al. 1998).



Şekil 3.9. EKG Kapılı SPECT tarama

3.3.2 Kardiyovasküler Hastalıkların SPECT ile Görüntülenmesi

KVH'ler, hem gelişmekte olan hem de gelişmiş ülkelerde en sık görülen morbid hastalıklardandır. Bu hastalıkların anatomi ve patofizyolojisini anlamak oldukça önemli ancak aynı zamanda zor bir süreçtir. Görüntüleme dünyasındaki son yıllarda ortaya çıkan yenilikçi değişiklikler bu algıyı değiştirmede yardımcı olmuştur (Shah, Gnanasegaran et al. 2009). Yeni radyofarmasötiklerin, medikal cihazların ve görüntüleme yöntemlerinin gelişmesi nükleer tıp ile kalbin patofizyolojisinin değerlendirilmesinde ivme kazandırmıştır. Çeşitli noninvaziv görüntüleme yöntemlerinde kullanılan radyoizotoplar kardiyovasküler fizyoloji hakkında bilgi toplamayı sağlayabilmiş, kardioloji alanında mevcut yöntemlerin geliştirilmesi KAH'nın tanı ve prognoz değerlendirilmesini pratik ve hızlı hale gelmesini sağlamıştır (Amiel, Maseri et al. 2012).

KAH tanısına yardımcı olan miyokardiyal iskemi durumu, nükleer tıp teknikleriyle izlenebilmektedir. Böylece koroner arterlerin sağladığı kan dolaşımı, kardiyovasküler sistemin patofizyolojisi hakkında bilgi verir. Nükleer kardioloji teknikleri ile miyokardiyal iskeminin incelenmesinde miyokardiyal kan akışı, miyokardiyal hücre perfüzyonu, miyokardiyal metabolizma, miyokardiyal hücre nekrozu ve miyokardiyal fonksiyon (hemodinamik) ile ilgili çalışmalar yapılır (Dziuk and Kamiński 2012). Nükleer kardiolojide en yaygın görüntüleme tekniği, teknesyum-99m etiketli izonitriller veya difosfin bileşikler gibi izotoplarla fiziksel veya farmasötik miyokardiyal perfüzyon stresi ve dinlenme testleri sırasında gerçekleştirilen SPECT'dir.

SPECT tarama ile elde edilen kalp görüntülerine yeniden yapılandırma teknikleri uygulanarak görüntülerin kaliteli ve niceliksel doğruluğunun iyileştirilmesi için foton zayıflaması, mesafeye bağlı uzaysal çözünürlük, saçılma ve gürültü gibi fiziksel faktörlerin görüntü üzerindeki etkileri iyileştirilmeye çalışılır (Rosenthal, Cullom et al. 1995) (Medicine, 2010). SPECT sistemlerindeki bu olumsuz faktörleri yeterince iyileştirmek için 3B (boyutlu) yeniden yapılandırma yöntemleri gereklidir. MPS (Miyokardiyal Perfüzyon Sintigrafisi) alanındaki gelişmeler, KAH tanısının ve prognozunun değerlendirilmesini önemli ölçüde iyileştirmiştir. Bu gelişmelerden bazıları, SPECT cihazının geliştirilmesi, yeni ^{99m}Tc bazlı radyofarmasötiklerin klinik uygulamalara eklenmesi ve farmakolojik stres ajanlarının kullanılması olarak sayılabilir.

KAH tanısını koymada kullanılan planar MPS, gerçekleştirilmesi basit, yaygın olarak erişilebilir, doğru kantitatif analize izin veren ve SPECT'ten daha az kalite kontrol gerektiren geleneksel bir tekniktir. Düzlemsel bir görüntüleme tekniği olarak sintigrafisi, enjekte edilen radyoizotoplardan yayılan radyasyonu yakalamak ve iki boyutlu projeksiyon görüntüleri oluşturmak için gama kameraları kullanır. Düzlemsel görüntüleme ile genel tanısallık doğruluğunu sınırlayan normal ve anormal olarak perfüze olmuş miyokardiyumda önemli bir örtüşme vardır. Düzlemsel görüntülemenin var olan bir takım sınırlamalarının üstesinden doğası gereği üç boyutlu bir teknik olan SPECT ile gelinebilmektedir. Koroner arter stenozunun genel tespiti ve lokalizasyonu için üç boyutlu miyokardiyal radyoniklid aktivitenin iki boyutlu kutupsal haritaları bilgisayarda oluşturulur ve normal bir hasta veri bankası ile istatistiksel olarak karşılaştırılır. SPECT'in miyokardiyal skar ve iskeminin kapsamını ölçmedeki yeteneği sayesinde önemli prognostik bilgiler verdiği kabul edilmiştir.


3.3.3 Kardiyak SPECT Taramada Kullanılan Radyofarmasötikler

201-Tl perfüzyon görüntüleme, miyokard canlılığının değerlendirilmesinde kullanılır. Özellikle miyokardiyal perfüzyon görüntüleme (MPG) için hastaların durumuna göre birçok farklı protokol geliştirilmiştir. Hastaya enjekte edilen 201-Tl, nekrotik dokular tarafından değil, sadece sağlam miyokardiyum tarafından tutulur. Genel olarak hastanın stres-istirahat durumundaki MPG'leri karşılaştırılarak egzersize bağlı perfüzyon kusurları tespit edilebilir ve miyokardiyumun canlılığı hakkında bilgi toplanır.

^{99m}Tc-sestamibi ile MPG, enfarktüsli bölgeyi değerlendirmede tercih edilir. Bu radyoizotop, hastaya enjekte edildiğinde yalnızca nekrotik dokular tarafından alınır ve enfarktüsli bölgeyi gösterir (Şekil 3.11). Temel özelliklerinden biri önemli ölçüde yeniden dağıtım olmaması olan ^{99m}Tc-sestamibi, miyokardiyumda yoğunlaştığından ve yeniden dağıtılmadığından, bu görüntüleme tekniği stres kaynaklı kusurları dinlenme kusurlarından ayırmak için iki ayrı enjeksiyon gerektirir. Dinlenme ve stres görüntülerini elde etmek için uygulanan protokoller iki farklı günde veya aynı gün içinde yapılabilir. Ayrıca her kurumun ve hastanın durumuna göre sadece stres çekimi veya stres-istirahat çekimi protokolleri de uygulanabilir.

Planar veya SPECT sintigrafisi ile miyokardiyal görüntülerin elde edilmesi için elektrokardiyografik kapılı SPECT kullanmanın fizibilitesi, kalbin hareketini en aza indirerek görüntülerin kalitesini iyileştirir. Bilgisayar teknikleri ile ^{99m}Tc-sestamibi görüntülerinden miyokardiyumun duvar hareketini ve miyokardiyal kalınlılaşmayı kantitatif olarak değerlendirebilir.

İkili izotop görüntüleme ile KAH tespitinde hastaya istirahatte 201-Tl, stres sırasında 99m-Tc sestamibi enjeksiyonu uygulanır (Şekil 3.10). Bir günlük çekim protokolünden oluşan bu uygulama aynı gün 99m-Tc-sestamibi protokollerinden daha kısa sürede gerçekleştirilir ve hasta verimini arttırmak için tasarlanmıştır. Bu protokolün dezavantajları, istirahatte 201-Tl kullanımı, sayım yoğunluğunu ve görüntüleme kalitesini etkileyen farklı fiziksel özelliklere sahip iki izleyicinin kullanılmasıdır.



Şekil 3.10. SPECT ile stres-dinlenme durumunda elde edilen kalp görüntüsü

MPG tekniğinde tercih edilen ve miyokardiyal kan akışını 201-Tl veya 99m-Tc-sestamibi'den daha iyi izlediği gözlenmiş bir diğer ajan 99m-Tc-teboroxime'dir. Bu radyofarmasötüğün biyokinetiği miyokardtan hızlı bir temizliğe sahip olduğu için 201-Tl ve 99m-Tc-sestamibi'nin biyokinetiğinden önemli ölçüde farklıdır. Bu özelliğinden dolayı özellikle SPECT görüntüleme kullanılırken sürekli olarak iyi kalitede görüntülerin elde edilmesini engeller. Özel olarak tasarlanmış hızlı görüntüleme protokolleri hariç bu radyofarmasötik yaygın olarak kullanılmamaktadır.

MPG için en son geliştirilen radyofarmasötik ajanlardan biri de 99m-Tc-tetrofosmin'dir. 99m-Tc-sestamibi'ye benzer şekilde bu ajan, birkaç saat boyunca seri görüntülemeye izin veren miyokardtan çok yavaş bir temizlik gösterir. Ayrıca 99m-Tc-tetrofosmin kullanımı, ilk geçiş ve kapılı SPECT çalışmalarının elde edilmesini de sağlar.

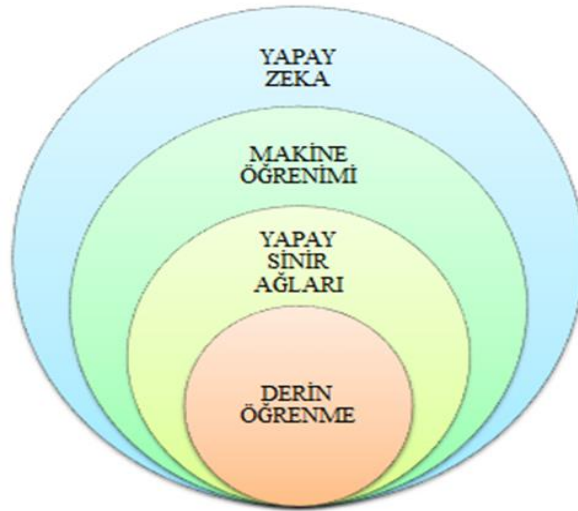
3.4 Makine Öğrenimi, Yapay Sinir Ağları ve Derin Öğrenme

Tıbbi görüntüler, hastalıkların teşhisi, tedavisi ve takibi gibi klinik uygulamalarda uzmanların karar vermesine katkı sağlayan araçlardır. Biyomedikal görüntüler, tıbbi görüntülere ek olarak biyolojik sistemlerden elde edilen görüntüleri de kapsar. Son yıllarda bilgisayar destekli teşhis (BDT) ile biyomedikal görüntülerin analizi otomatikleştirilerek görüntülerdeki bilgilerin anlamlandırılması ve geliştirilmesi üzerine

yapılan çalışmalar hız kazanmıştır. BDT yöntemlerinden biri olan MÖ tekniği ile veriler arasında açık olmayan, karmaşık ilişkiler otomatik olarak bulunabilir ve tahmine dayalı modeller geliştirilebilir. Karmaşık biyomedikal problemleri çözmeye MÖ yöntemlerinin biyomedikal görüntülere uygulanması yaklaşımı son yıllarda büyük ilgi görmüştür. Biyomedikal görüntü işleme ve analizi yapılırken karşılaşılan teknik kısıtlamalar ve artefaktlar gibi çeşitli faktörler bilgi kaybına sebep olur. Bunlar görüntü kalitesini olumsuz etkileyerek uzmanların klinik karar almadaki başarısını zorlaştırır (Gonzalez and Romero 2009). Günümüzde uzmanlar tarafından yorumlanan görüntüler, hastalıkların tanı ve tedavisini koymada subjektif bir yöntemdir. Bu çoğalan bilgi birikimi ile MÖ tekniği entegre edilerek uzmanlara destek olabilecek objektif bir yöntem geliştirilebilir. Böylece uzmanların görüntüyü anlamlandırma deneyimleri kullanılarak MÖ yöntemi ile kişisel hasta verileri başarılı bir şekilde yorumlanabilir.

3.4.1 Makine Öğrenimi

Yapay zeka, insanın zeka yapısını makinelere simüle ederek makineye öğrenme yeteneği kazandıran uygulamaların genel adıdır (Şekil 3.11). Makine öğrenimi ise makinelerin akıllı yazılımlar (makinelerin öğrenmesini sağlayacak ve tahmin gibi görevleri yerine getirmesini sağlayacak bilgisayar programları) kullanarak işlerini ustaca yapmalarını sağlamayı amaçlayan bir yapay zeka dalıdır (Mohammed, Khan et al. 2016). Bu yöntemin amacı, gerçek dünyanın gözlemlerini (“eğitim verileri” olarak adlandırılır) kullanarak, insanlar tarafından açıkça kurallar veya mantık tanımlanmadan (eğitmen/gözetmen) doğrudan öğrenme gerçekleştiren yöntemler tasarlamaktır (Khan, Rahmani et al. 2018).



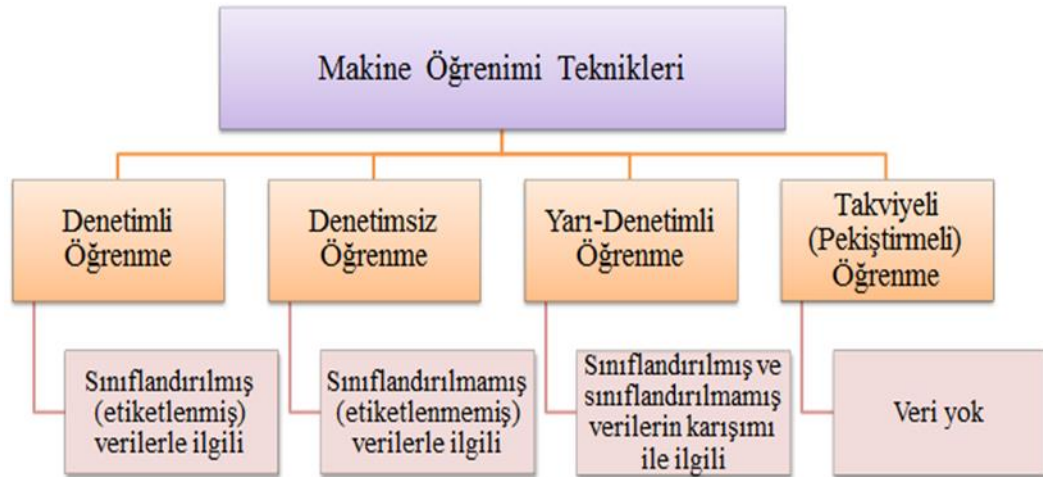
Şekil 3.11. Yapay zeka, MÖ, YSA, DÖ'nin Venn şeması ile gösterimi

Çok çeşitli verileri ve problem türlerini kapsayacak şekilde MÖ teknikleri önerilmiş olup aşağıdaki şekilde sınıflandırılabilir (Tablo 3.1).

- **Denetimli Öğrenme:** YSA'nın öğrenmesini sağlamak üzere hazırlanmış etiketli eğitim verilerinden bir işlev veya eşleme çıkarma tekniğidir. Bu veriler, verileri

içeren girdi vektörü X ve her eğitim örneği için etiketleri içeren çıktı vektörü Y'den meydana gelir. Y'de yer alan etiketler bir alanında uzman olan bir denetmen tarafından sağlanır. Bazen etiketleme için makineler de kullanılabilir. Uzman görüşleri makinelerden daha maliyetlidir, ancak makineler tarafından etiketlenen verilerde daha yüksek hata oranlarına rastlandığından uzman görüşünün üstünlüğü vurgulanmaktadır. Dolayısıyla bir uzman tarafından manuel olarak etiketlenen veriler, denetimli öğrenme için değerli ve güvenilir bir kaynaktır.

- **Denetimsiz Öğrenme:** Yalnızca girdi verisinin (etiketlenmemiş veriler) olduğu ve karşılık gelen çıktı değişkenlerinin bulunmadığı öğrenme tekniğidir. Denetimli öğrenmenin aksine öğrenme sürecinde denetçi ve kesin sonuç çıktısı yoktur. YSA'nın amacı, verilerde çalışılan alanı keşfetmek için verilerin temel yapısı/dağılımı bir model oluşturmaktır. Denetimsiz öğrenme, eğitim setinin herhangi bir etiket içermemesi bakımından farklılık gösterir. Kullanılan bu yöntem ile model, girdi veri örneklerinin temeldeki dağılımını tahmin etmek amaçlanır.
- **Yarı Denetimli Öğrenme:** Denetimli ve denetimsiz öğrenme arasında yer alan öğrenme tekniğidir. Bu öğrenme yöntemi, büyük miktarda girdi verisi mevcut olduğunda ve verilerin sadece bir kısmı etiketlenebildiğinde kullanışlıdır. Girdi verileri, sınıflandırılmış ve sınıflandırılmamış verilerin bir karışımıdır. Etiketli ve etiketlenmemiş verilerin bu kombinasyonu, verilerin sınıflandırılmasında uygun bir model oluşturmaya yarar (Langley and Carbonell 1984).
- **Pekiştirmeli (Takviyeli) Öğrenme:** Eylemler aracılığıyla gerçekleştirilen bir ödül sistemi ile çalışan davranışsal öğrenme modelidir. Aşamalara dayalı olarak karar vermeyi optimize eden algoritma, verilerin analizinden geri bildirim alarak kullanıcıyı en iyi sonuca yönlendirir. Pekiştirmeli öğrenmede, durum-eylem kavramları ile ilişkilendirme yapılarak deneme yanılma yoluyla öğrenme sağlanır. Uygulanan yöntemin sonucunda ödül işlevi olarak çevreden gelen nesnel geri bildirimlerden elde edilen gözlemlerin kullanılması amaçlanır.

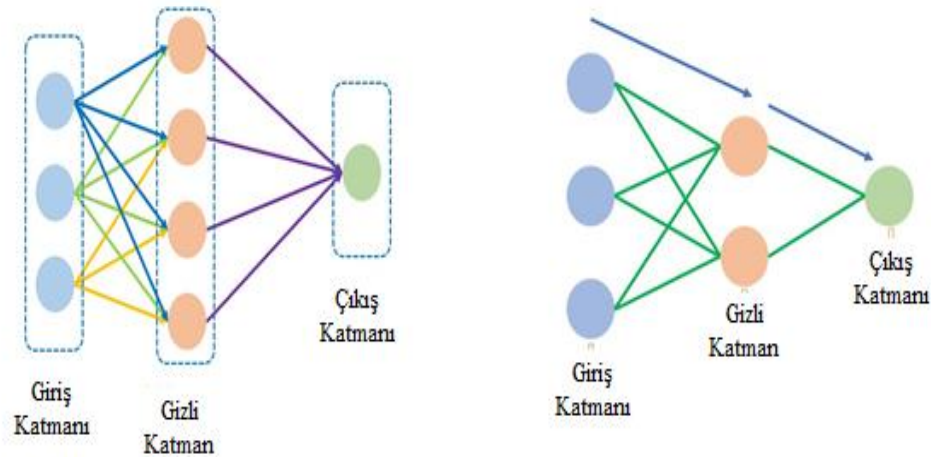


Şekil 3.12. Makine Öğrenimi Teknikleri ve İlgili Veriler

3.4.2 Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), biyolojik sinir sistemlerinin çalışma biçimini gözlemleyerek bilgiyi işlemede ilham alınan bir hesaplama sistemidir. DÖ'nin temelini oluşturan YSA, insan beynindeki gibi nöronların haberleşmesini sağlayabilmek için üç katmandan oluşur. Bunlar girdi katmanı, gizli katman ve çıktı katmanıdır. Girdi katmanında ham veri değişikliğe uğramadan gizli katmana iletilmektedir. Gizli katman öğrenmenin gerçekleştirildiği katmandır ve modelin eğitilmesi burada gerçekleşir. Çıktı katmanı ise, gizli katmanda işlenmiş verinin bilgi çıktısını oluşturan katmandır. DÖ modelinin, büyük veri setini işleyebilmesi ve kantitatif değerlendirme yapabilmesi için eğitime uygun YSA seçilmelidir (Zhou, Wang et al. 2019).

YSA modelleri, sıkıca birbirine bağlı olan ve bilgileri işleyerek istenen çıktıları üretmek için verilen girdiler üzerinde çalışan bir dizi temel işlem birimi olarak anlaşılabilir. Sinir ağları, bilginin ağda yayılma şekline göre ileri beslemeli ve geri beslemeli ağlar olarak iki genel kategoriye ayrılır (Şekil 3.13). İleri beslemeli bir ağdaki bilgi akışı yalnızca tek yönde gerçekleşir. Geri beslemeli ağlar ise yönlendirilmiş döngüler oluşturan bağlantılara sahiptir. Rastgele boyutlarda diziler üzerinde işlem yapmalarına ve oluşturmalarına izin verir. Geri besleme ağları, ezberleme yeteneği sergiler ve bilgileri ve sıralama ilişkilerini dahili belleklerinde saklayabilir.



Şekil 3.13. (a) İleri beslemeli sinir ağı. (b) Geri beslemeli sinir ağı. (Rosdeepy 2020)

3.4.3 Derin Öğrenme

Derin öğrenme, verilerden yinelemeli bir şekilde (iterasyonlar yoluyla) öğrenmek için ardışık katmanlarda sinir ağlarını birleştiren özel bir MÖ yöntemidir. DÖ insan beyninin nasıl çalıştığını taklit etmek için tasarlanmıştır, böylece bilgisayarlar kötü tanımlanmış soyutlamalar ve problemlere çözüm bulmak amacıyla eğitilebilir. DÖ genellikle görüntü tanıma, konuşma ve bilgisayarla görme uygulamalarında kullanılır. Buna ek olarak DÖ etiketlenmemiş ve yapılandırılmamış verilerden öğrenir. Bu yöntem geleneksel bir sinir ağına çok benzese de, çok daha fazla gizli katmana sahiptir. Problem ne kadar karmaşıksa modelde o kadar gizli katmanlar vardır.

Özellikle DÖ algoritmaları kullanılarak görüntü analizinin yapılabilir olması büyük verilerin bu yaklaşım ile pratik olarak çözümlenmesini sağlar. DÖ algoritmalarının ana yapısını oluşturan Derin Beslemeli Sinir Ağları (D-FFCN), Evrimsel Sinir Ağları (ESA), Derin İnanç Ağları (DBN), Otomatik Kodlayıcı, Uzun-Kısa Öğrenme gibi mimariler uygulanarak çeşitli DÖ modelleri geliştirilebilir. Bu doğrultuda asıl amaçlanan hedef çalışmaya özgü yeni bir DÖ modeli tasarlayarak büyük veri setlerindeki bilgi aktarımını geleceğe taşımaktır.

3.5 Görüntü İşleme Yöntemleri

Kardiyak SPECT tarama ile KAH varlığının ve lokalizasyonunun klinik değerlendirmedeki başarısını arttırmak üzere DÖ ile teşhis çalışmaları son zamanlarda önem kazanmıştır (Slomka, Hung et al. 2016). Bu alanda yapılan çalışmalar genellikle büyük veri setleri üzerinde ve eğitim öncesinde görüntü işleme teknikleri uygulanarak öznelik çıkarımı ve sınıflandırma üzerine yoğunlaşmıştır (Yoneyama, Nakajima et al. 2019). Çalışma kapsamında geliştirilen DÖ modeli yardımıyla elde edilen kardiyak SPECT görüntülerinin ön işleme, filtreleme, artefakt giderme ve segmentasyon işlemleri gerçekleştirilir. Böylece hastalığa ait farklı özelliklerin çıkarılıp görüntülerin sınıflandırılması sağlanmaya çalışılır.

SPECT sistemi tarafından rekonstrükte edilen görüntüler üzerinden doğru KAH tanısı koyabilmek için aşağıdaki işlem adımları uygulanmıştır.

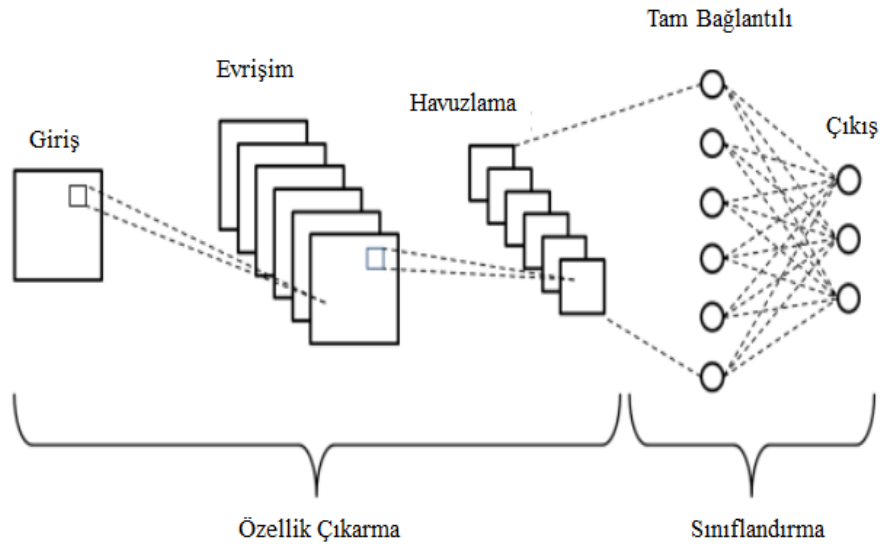
- **Önişleme:** MÖ projelerinde, genellikle veriler bir ön işleme adımından geçirilir. Özellikle SPECT taramalarında, hasta vücudu, donanım bileşenleri, yazılımsal sorunlar veya dış etmenlerden kaynaklı olarak görüntüde oluşabilecek gürültü öğeleri hatalı ve eksik bilgi verebileceğinden, çeşitli filtreler kullanılarak görüntüye ön işleme uygulanır ve böylece görüntü üzerindeki gürültü miktarı azaltılarak önemli bilgiler korunmuş olur.
- **Segmentasyon (Bölütleme):** Görüntüyü segmentlere ayırma işlemidir. Piksellerin özelliklerine göre nesnelere ve sınırları segmente ederek görüntüyü daha anlamlı ve daha kolay analiz etmeye olanak sağlar. SPECT görüntüsünde segmentasyon işlemi alanında uzman kişiler yardımı ile gerçekleştirilir. DÖ modeline segmentasyonu öğretmek için bir uzman tarafından etiketlenmiş görüntü veri seti referans alınır (Tan 2016).
- **Özellik (Öznelik) Çıkarımı:** Özellik çıkarımının temel amacı, orijinal verilerden anlamlı bilgileri elde etmek ve bu bilgiyi daha düşük bir boyutsal alanda olmasını sağlamaktır. Bu sistemin amacı, girdi verilerindeki anlamsız verilerin işlenmemesi ve sistemin işleyeceği veri setini azaltmaktır. Özellik çıkarmadan önce görüntü üzerinde ikileme, eşikleme, yeniden boyutlandırma, normalleştirme gibi çeşitli görüntü ön işleme teknikleri uygulanır. Daha sonrasında görüntülerin sınıflandırılma ve tanınmasında faydalı olacak özellikler için çıkarma teknikleri uygulanır.
- **Sınıflandırma:** Belirli kurallara göre bir görüntü içindeki piksel veya vektör gruplarını kategorize etme ve etiketleme işlemidir (Shinozuka and Mansouri 2009). Sınıflandırmanın amacı, bir sınıfı belirli bir veri noktasına otomatik şekilde ve bazı veri noktası özelliklerine göre doğru şekilde atayabilmektir.

3.6 Evrişimli Sinir Ağı Katmanları ve Mimarileri

3.6.1 Evrişimli Sinir Ağı Katmanları

Evrişimli Sinir Ağı yapısı ilk olarak 1988'de Fukushima tarafından önerilmiştir (Fukushima 1988). 1990'lı yıllarda LeCun ve ark., ESA'lara gradyan tabanlı bir öğrenme algoritması uygulayarak elle yazılmış rakam sınıflandırma problemi için başarılı sonuçlar elde etmişlerdir (LeCun, Bottou et al. 1998). İleriki çalışmalarda araştırmacılar ESA'yı geliştirme üzerine çalışmışlardır. ESA'ların, insanın görsel işleme sistemine daha çok benzemesi, 2D ve 3D görüntülerin işlenmesi için yüksek düzeyde optimize edilmesi gibi DSA'ya (Deep Neural Networks; Derin Sinir Ağları) göre avantajları vardır. Bu avantajlara ek olarak ESA, 2D özelliklerin soyutlamalarının öğrenilmesi ve çıkarılmasında da etkilidir. ESA'lar gradyan tabanlı öğrenme algoritması ile eğitilir ve azalan gradyan probleminden daha az etkilenir. Gradyan tabanlı algoritmanın bir hata kriterini doğrudan en aza indirmek için tüm ağı eğittiği göz önüne alındığında, ESA'lar yüksek düzeyde optimize edilmiş ağırlıklar üretebilir.

ESA, bir tür eğitilebilir ileri beslemeli sinir ağıdır. Görüntü nesnelерinin özellik-öznitelik çıkarımında, segmentasyonunda ve sınıflandırmasında ESA başarılı sonuçlar verir. ESA giriş katmanı, evrişim katmanı, havuz katmanı, tamamen bağlı katman ve çıktı katmanı olmak üzere beş farklı katmandan oluşur. Bu katmanlar işlevleri açısından özellik çıkarma ve sınıflandırma olarak iki kısma ayrılır. Özellik çıkarma, girdi katmanı, evrişim katmanı ve havuz katmanından oluşurken, sınıflandırma tamamen bağlı katmandan ve çıktı katmanından oluşur (Şekil 3.14) (Phung and Rhee 2019).



Şekil 3.14. ESA Mimarisinin şematik diyagramı (Phung and Rhee 2019)

- **Giriş Katmanı:** Bilgisayar sistemi ile görüntü veri setini sayısal veri setine dönüştürerek bir görüntü matrisi oluşturur. Ön işleme süreci, genellikle bir vektör olarak görüntüdür ve eğitimde evrişimli sinir ağının hızını artırmak için onu

normalleştirerek veriyi evrişim katmanına iletir.

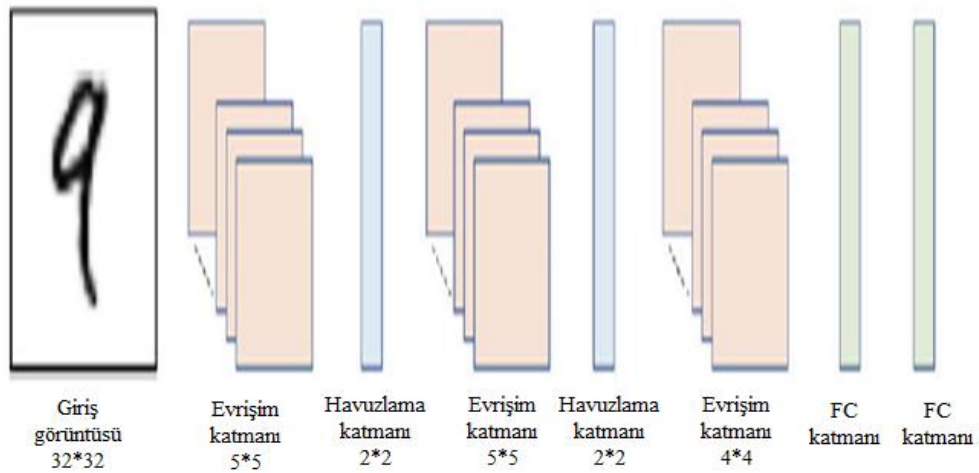
- **Evrişim Katmanı:** Önceki katmanlardan gelen özellik haritaları öğrenilebilir çekirdeklerle birleştirilir. Çekirdeklerin çıktısı, çıktı özellik haritalarını oluşturmak için sigmoid, hiperbolik tanjant, Softmax, ReLu ve özdeşlik işlevleri gibi doğrusal veya doğrusal olmayan bir etkinleştirme işlevinden geçer. Çıkış özellik haritalarının her biri, birden fazla giriş özelliği haritası ile birleştirilebilir. Ancak, ilgili çıktı haritalarını oluşturmak için girdi haritaları farklı çekirdeklerle birleştirilecektir. Çıktı haritaları doğrusal veya doğrusal olmayan bir etkinleştirme işlevinden geçer (sigmoid, hiperbolik tanjant, Softmax, düzeltilmiş doğrusal veya özdeşlik işlevleri gibi) (Alom, Taha et al. 2019).
- **Havuzlama Katmanı:** Bir alt örnekleme süreci olarak havuzlama katmanı, algılama alanındaki özellikleri taramak ve bölgedeki en temsili özellikleri çıkarmak için kullanılır. Bu da çıktı özelliği ölçeğini etkili bir şekilde azaltabilir, böylece modelin gerektirdiği parametre sayısını azaltır. İşlem türüne göre, genellikle ortalama havuzlama ve maksimum havuzlama olarak ikiye ayrılır. Scherer vd. iki birleştirme yöntemini karşılaştırmış ve maksimum havuzlamanın daha hızlı yakınsama oranına ve daha iyi genelleme yeteneğine sahip olduğunu bulmuştur (Scherer, Müller et al. 2010).
- **Tam Bağlantılı (Fully Connected; FC) Katman:** ESA tarafından öğrenilen özellikleri özetlemekten sorumlu katmandır ve çıkış değerlerini çıkış katmanına iletir. Evrişim aşamalarının son çıktısı bir boyutlu diziye düzleştirilir ve tamamen bağlı bir katmana bağlanır (Si, Xiong et al. 2020) Tam bağlantılı katmanlar, evrişim/havuzlama işleminin sonuçlarını alır ve bunları geleneksel bir sinir ağı gibi görüntüyü bir etikete (yani sınıf) sınıflandırmak için kullanır.
- **Çıkış Katmanı:** Görüntünün sınıflandırılmasını gerçekleştirir. Her bir çıktı nöronu etiketlerin her birine karar verir ve en büyük çıktı değeri sınıflandırma kararına karşılık gelir.
- **Aşırı Uydurma ve Bırakma Katmanı:** ESA modeli tasarlarken mimariye ek olarak aşırı uydurmaktan kaçınmak için aşırı uyum ve bırakma katmanı eklenebilir. *Aşırı (fazla) uyum katmanı*, eğitim verilerini ezberlemek ve görüntü özelliklerini öğrenmemek anlamına gelir. Eğitim veri kümesine daha iyi şekilde uyan (eğitim sırasında çok düşük hata) ancak daha önce görmediği diğer veri örneklerine genelleme yapamayan bir süper ağ oluşturulduğunda ortaya çıkar. Aşırı uyumda ağın eğitim veri setinde çok iyi performans gösterdiği fakat test veri setinde kötü performans gösterdiği gözlemlenir. *Bırakma katmanı* ise aşırı uydurmaya önlemek için kullanılır. Katmanlarda bulunan her yapay nöron, bir ağırlıkla çarpıldığında başka bir özelliğe dönüşen belirli bir özelliği temsil eder. Düğümlerden bazıları rastgele kapatıldığında geriye kalan düğümleri yalnızca bir veya iki özelliğe güvenmeden kalıpları öğrenmeye zorlanır, çünkü herhangi bir özellik herhangi bir noktada rastgele çıkarılabilir. Bu, ağırlıkların tüm özellikler arasında yayılmasıyla sonuçlanır ve daha eğitilmiş nöronlara yol açar. Bırakma katmanı böylece yapay nöronlar arasında birbirine bağlı öğrenmeyi azaltmaya yardımcı olur.

3.6.2 Evrişimli Sinir Ağı Mimarileri

Evrişimli Sinir Ağları ile veri analizi yapıldığında YSA'lara göre daha az parametreye ihtiyaç duyulmaktadır. YSA'da bir katmandaki her nöron bir sonraki katmandaki tüm


nöronlara bağlanarak, ESA'da ise bir katmandaki nöron kendine yakın olan nöronlara bağlanarak analiz yapılabilmektedir. Uygulamadaki birçok problemi çözüme kavuşturabilecek DÖ modelini tasarlamak zor bir iştir. Verilerin büyüklüğü ve dinamik yapısı göz önüne alınarak akıllı bir sistemin geliştirilmesinde uygun ESA mimarilerin seçimi önemlidir. Yapılan çalışmaya uygun seçilen mimarilerin analiz yeteneklerini daha iyi değerlendirmek ve hayata geçirebilmek için aşağıda bazı mimarilerin yapısı hakkında bilgi verilmiştir.

- **LeNet Mimarisi:** 1988 yılında Yann LeCun tarafından tanıtılan ve 1998 yılına kadar sürekli iyileştirme yapılan ilk ESA mimarisidir (LeCun, Bottou et al. 1998). MNIST el yazısıyla yazılmış rakam tanıyıcı modellerine başarıyla uygulanmış bir mimaridir. Beş ağırlık katmanından oluşur ve dolayısıyla LeNet-5, üç evrişimli katman ve iki tam bağlantılı katmana sahiptir (Şekil 3.15; (Khan, Rahmani et al. 2018)). LeNet, evrişim katmanlarına ve ardından alt örnekleme katmanına giden bir girdi görüntüsü (gri tonlamalı görüntü) ile elde edilir. Daha sonra, başka evrişim katmanları dizisi ve ardından bir havuzlama katmanı vardır. Son olarak, çıktı katmanını içeren 3 tam bağlantılı katmanı mevcuttur. Mimarinin temel amacı postanelerde elle yazılmış rakam kalıplarını ve posta kodu tanımayı sağlamaktır.




Şekil 3.15. LeNet-5 Mimarisi (Khan, Rahmani et al. 2018)

- **AlexNet:** Krizhevsky ve ark. (Krizhevsky, Gonzalez, 2007) 2012 yılında, ILSVRC (Russakovsky et al., 2015) nesne algılama ve büyük ölçekte görüntü sınıflandırması için bulmuş oldukları AlexNet algoritmalarını değerlendirmiştir. 60 milyon parametre ve 650.000 nörona sahip olan AlexNet, beş evrişimli katman ve üç tam bağlantılı katmandan oluşmaktadır (Şekil 3.16). İlk iki evrişimli katmanı normalleştirme ve maksimum havuz katmanı izler, üçüncü ve dördüncü katman doğrudan bağlanmakta ve beşinci evrişimli katmanı maksimum havuz katmanını izlemektedir. Veri çıktısı, bir dizi tam bağlantılı iki katmana gider ve burada ikinci tam bağlantılı katman bir softmax sınıflandırıcıya beslenir. AlexNet modelinin bir diğer özelliği de, ilk yedi katmanın her birine uygulanan ReLU kullanımını ve tanh ve Sigmoid aktivasyon fonksiyonlarına göre daha hızlı eğitilebileceği belirtilmiştir.



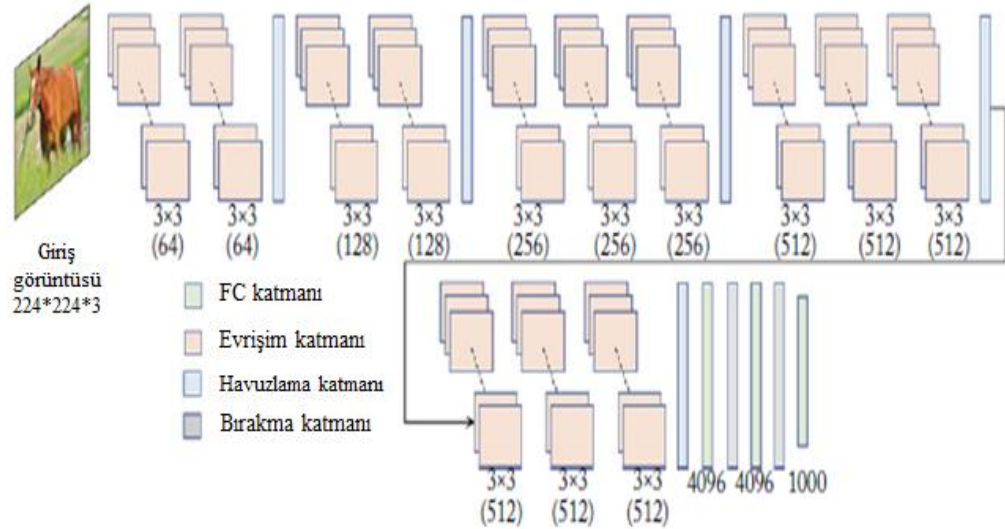
Şekil 3.16. AlexNet Mimarisi (Khan, Rahmani et al. 2018)

- Network in Network (NiN):** AlexNet'ten kısa bir süre sonra önerilmiştir. NiN (Lin et al., 2013) mimarisi, genellikle küçük ölçekli veri kümelerinde iyi performans gösterir. ESA tasarımına iki yeni fikir getirmiştir. İlk olarak, evrişimli katmanlar sonuçlarının arasına tamamen bağlı katmanların dahil edilmesinin ağ eğitiminde yardımcı olduğunu göstermektedir. Bu nedenle, örnek mimari, sırasıyla 5*5, 5*5 ve 3*3 boyutlarında filtrelerle birinci, dördüncü ve yedinci konumlarda (ağırlık katmanları arasında) üç evrişimli katmandan oluşur. Bu evrişimli katmanların her birini, bir çift tam bağlantılı katman (veya 1*1 filtre boyutlarına sahip evrişimli katman) ve bir maksimum havuz katmanı izler. İkincisi, bu mimari, düzenleyici olarak modelin sonunda küresel bir ortalama havuzlamayı kullanır. Bu havuzlama şeması, softmax kayıp katmanına iletilen tek bir sınıflandırma puanı elde etmek için her özellik haritasındaki tüm etkinleştirmeleri (ortalamasını alarak) birleştirir (Şekil 3.17).



Şekil 3.17. NiN Mimarisi (Khan, Rahmani et al. 2018)

- VGGNet:** 2014 yılında Oxford Üniversitesi'ndeki Visual Geometry Group tarafından geliştirilmiştir. VGGNet bileşenleri LeNet ve AlexNet'dekilerle tamamen aynıdır. Tek fark, VGGNet'in daha evrişimli, havuzlama ve yoğun katmanlara sahip olmasıdır. VGG16 olarak da bilinen VGGNet, 13 evrişimli katman ve 3 tam bağlı katman olarak toplamda 16 ağırlık katmanından oluşur (Şekil 3.18). Simonyan ve Zisserman, VGGNet mimarisi için çeşitli konfigürasyonlar oluşturmuşlardır (Simonyan and Zisserman 2014). Tüm konfigürasyonlar aynı genel tasarımı takip eder. D ve E konfigürasyonları en yaygın kullanılanlardır ve ağırlık katmanlarının sayısına göre VGG16 ve VGG19 olarak adlandırılır. Her blok, benzer hiperparametre konfigürasyonuna sahip bir dizi 3*3 evrişimli katman ve ardından 2*2 bir havuzlama katmanı içerir. VGG16, ~138 milyon parametre verir. VGGNet'in daha derin bir versiyonu olan VGG19, 144 milyondan fazla parametreye sahiptir. VGG16 daha yaygın olarak kullanılır çünkü neredeyse daha az parametre ile VGG19 kadar iyi performans gösterir.



Şekil 3.18. VGGNet-16 Mimarisi (D konfigürasyonu) (Khan, Rahmani et al. 2018).

- GoogleNet:** Szegedy ve ark. 2015 yılında ILSVRC'nin yarışmasını GoogleNet mimarisi ile kazanmışlardır (Szegedy, Liu et al. 2015). GoogleNet yedi milyon parametreye sahiptir ve dokuz başlangıç modülü, dört evrişimli katman, dört maksimum havuz katmanı, üç ortalama havuz katmanı, beş tam bağlı katman ve ana katman için üç softmax katmanı içerir. Ek olarak, tamamen bağlı katmanda bırakma düzenlemesini kullanır ve tüm evrişimli katmanlara ReLU etkinleştirmesini uygulamıştır. Bu ağ, toplam 22 katman ile çok daha derin ve daha geniştir, ancak AlexNet'e kıyasla çok daha az sayıda ağ parametresine sahiptir.
- ResNet:** He ve ark. 2015 yılında geliştirdikleri mimari ile görüntü sınıflandırmada ILSVRC yarışmasının kazananı olmuştur (He, Zhang et al. 2016). ResNet-34-50-101-152 gibi çeşitli sayıda katmanlara sahip ResNet (Residual Network) diğer mimarilere kıyasla daha fazla derin katman içeren bir yapıdadır. Daha derin katmana

sahip ağların eğitim süreci daha zor olduğu için ResNet mimarisinde artık ağ kullanılarak öğrenme süreci kolaylaştırılmak istenmiştir. ResNet, VGGNet mimarisi ile benzerlik göstermektedir ancak VGGNet'e göre daha derin katmanlara ve daha az karmaşıklığa sahiptir. Artık ağlara verilen bilgi bir sonraki ağa bağlanarak katmanlar arasında öğrenme işlemi gerçekleştirilmektedir.

3.6.3 Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları (AF), girdi olarak tek bir sayıyı alan ve üzerinde bazı matematiksel işlemler yapan doğrusal olmayan fonksiyonlardır. Bu tür birçok işlev mevcuttur ve yaygın olarak kullanılanlardan bazılarını aşağıda değinilmiştir (Şekil 3.19; (Aloysius and Geetha 2017)).

- **Sigmoid:** Çoğunlukla ileri beslemeli sinir ağlarında kullanılan doğrusal olmayan bir AF'dir. Sigmoid işlevi, denklem 3.1'de belirtilen formülle hesaplanarak genellikle DÖ mimarilerinin çıktı katmanlarında görünür ve olasılığa dayalı çıktıyı tahmin etmek için kullanılır (Gomar, Mirhassani et al. 2016, Rasamoelina, Adjailia et al. 2020). Sigmoid fonksiyonlarının avantajları, anlaşılması kolay ve daha çok sığ ağlarda uygulanmaktadır.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.1)$$


- **Tanh (Hiperbolik Tanjant):** DÖ uygulamalarında kullanılan ve bazı varyantlara sahip bir aktivasyon fonksiyonudur. Tanh işlevi olarak bilinen hiperbolik tanjant işlevi, aralığı -1 ile 1 arasında olan daha yumuşak bir sıfır merkezli işlevdir. Çok katmanlı sinir ağları için daha iyi eğitim performansı sağlaması açısından sigmoid işlevine kıyasla daha sık tercih edilen tanh işlevi denklem 3.2'deki gibi hesaplanır (Gomar, Mirhassani et al. 2016, Rasamoelina, Adjailia et al. 2020). Fonksiyonun sağladığı temel avantaj, geri yayılma sürecine yaklaşıp sıfır merkezli çıktı üretmesidir.

$$\tanh \tanh (x) = 2f(2x) - 1 = \frac{2}{1 + e^{-2x}} - 1 \quad (3.2)$$

- **Softmax:** Sinirsel hesaplamada kullanılan başka bir aktivasyon işlevi türüdür. Gerçek sayılardan oluşan bir vektörden olasılık dağılımını hesaplamak için kullanılır. Softmax işlevi, olasılıkların toplamı 1'e eşit olacak şekilde 0 ile 1 arasında değer aralığı olan bir çıktı üretir (Nwankpa, Ijomah et al. 2018, Yamashita, Nishio et al. 2018). Softmax işlevi, her bir sınıfın olasılıklarını döndürdüğü, hedef sınıfın en yüksek olasılığa sahip olduğu çok sınıflı modellerde kullanılır. Sigmoid ve Softmax AF arasındaki temel fark, Sigmoid iki değişkenli sınıflandırmada kullanılırken, Softmax çok değişkenli sınıflandırmada kullanılır.
- **ReLU (Rectified Linear Unit):** Nair ve Hinton tarafından 2010 yılında önerilmiştir (Nair and Hinton 2010). ReLU, başarılı, daha hızlı öğrenen ve yaygın olarak kullanılan bir aktivasyon işlevidir. Sigmoid ve tanh aktivasyon fonksiyonlarına kıyasla DÖ'de daha iyi performans ve genelleştirme olanağı sunar. Ayrıca, sıfırdan küçük değerlerin sifira ayarlandığı her giriş elemanı için bir eşik işlemi

gerçekleştirir. Denklem 3.3’de ifade edilen bu fonksiyon, sıfırdan küçük girişlerin değerlerini düzeltir, böylece onları sıfıra zorlar ve daha önceki aktivasyon fonksiyonu türlerinde gözlemlenen kaybolan gradyan problemini ortadan kaldırır. ReLU işlevi, nesne sınıflandırmasında ve konuşma tanıma uygulamalarında bulunan tipik örneklerle ağıın çıktı katmanlarında kullanılan başka bir AF ile derin sinir ağlarının gizli birimlerinde kullanılmaktadır.

$$\text{rect}(x) = \max(0, x), \quad f(x) = \begin{cases} 0 & \text{ise } x < 0 \\ x & \text{ise } x \geq 0 \end{cases} \quad (3.3)$$



Şekil 3.19. Çeşitli aktivasyon fonksiyonlar: (a) ReLU), (b) sigmoid, (c) hiperbolik tanjant (tanh) (Yamashita, Nishio et al. 2018).

3.7 Transfer Öğrenme

Derin Öğrenme, genellikle milyonlarca görüntü içeren veri kümelerinden yüksek doğruluk elde etmek için büyük miktarda veri gerektirir. Ancak birçok durumda bu kadar büyük veri kümelerine sahip olmak zordur. DÖ modellerini eğitmek de hesaplama ve zaman açısından kolay değildir. Transfer öğrenme, bir problemde öğrenilen özelliklerin başka bir sınıflandırma problemine uygulanmasını içerir. Bu nedenle transfer öğrenme, ImageNet veya COCO gibi milyonlarca görüntünün veri kümeleri üzerinde eğitilmiş modeller ile elde edilmiş ağırlıkların yeni model için kullanılmasına ve böylece yapılması gereken öğrenme miktarının azaltılmasına izin verir. ESA'nın daha sığ katmanları, çizgiler, eğriler ve kenarlar gibi daha düşük sıradaki özellikleri öğrendiğinden transfer öğrenme, modellerin fazla uydurmadan kaçınarak daha küçük veri kümelerinden öğrenmesini kolaylaştırır. Shin vd., BDT problemlerinde transfer öğrenmenin performansını değerlendirerek (Shin, Roth et al. 2016) ImageNet ile tıbbi veri kümeleri arasındaki eşitsizliğe rağmen ImageNet veri kümesi üzerinde ön eğitim yaparak daha iyileştirilmiş bir performans elde etmiştir (Bir & Balas, 2020). Transfer öğrenme yöntemi sayesinde etiketli ile etiketsiz veriler arasındaki benzerlik bulunabilir ve ardından bilgi muhakemesi yoluyla tasarlanan modele etiketli verilerin özellikleri aktarılabilir (Kang, Song et al. 2019). Görüntü analizlerinin derin öğrenme uygulamaları kullanılarak pratikleştirilmesi ve iyileştirilmesi için inşa edilen ESA eğitiminden sonra mevcutta olan ESA mimarileri ile de eğitim süreci tamamlanarak

transfer öğrenme sağlanmaktadır.

DÖ modelini oluşturmak için büyük veriye, büyük işlem gücüne ve fazla zamana ihtiyaç vardır. ImageNet, MS COCO, Open Images, MNIST, CIFAR, Kaggle gibi açık kaynak veri kümeleri, insanların çevrimiçi olarak paylaştığı ve birçok bilgisayar araştırmacısının algoritmalarını eğitmek ve durumu elde etmek için kıyaslama olarak kullandıkları veri kümeleridir (Ranzato, 2013).

- **ImageNet:** Görsel nesne tanıma yazılımı araştırmasında kullanılmak üzere tasarlanmış büyük bir görsel veri tabanıdır (Deng, Dong et al. 2009). Yaklaşık 22.000 kategoriye ait 15 milyondan fazla etiketli yüksek çözünürlüklü görüntüden oluşan bir veri kümesidir. Yıllık düzenlenen ILSVRC (ImageNet Large Scale Visual Recognition Challenge; ImageNet Büyük Ölçekli Görsel Tanıma Yarışması) yarışmasında 1000 kategorinin her birinde 1000 görüntüye sahip ImageNet alt kümesi kullanılır (Mele and Altarelli 1993, Russakovsky, Deng et al. 2015). Görüntüler, Amazon'un Mechanical Turk kitle kaynak kullanım aracı ile internetten toplanmıştır ve insanlar tarafından etiketlenmiştir.
- **MS COCO:** Microsoft Common Objects in Context'in kısaltmasıdır (<http://cocodataset.org/>). Nesne algılama, örnek bölütleme gibi gelecekteki araştırmaları etkinleştirmeyi amaçlayan açık kaynaklı bir veri tabanıdır. MS COCO, 328.000 resim içerir. Bunların 200.000'den fazlası etiketlidir ve dört yaşında bir çocuk tarafından kolayca tanınabilecek 1,5 milyon nesne örneği ve 80 nesne kategorisi içerir.
- **Kaggle:** Dünyanın her yerinden insanların katılabileceği ve değerlendirmeler için algoritmalar gönderebileceği MÖ ve DÖ yarışmalar yapan web sitesidir (<http://www.kaggle.com/>). Destekledikleri sınıfları ve kullanım durumlarını daha iyi anlamak için bu veri kümelerini keşfetmede ve birçok açık kaynak veri kümesini aramada tavsiye edilir.

3.8 Başarım Performans Ölçütleri

Performans ölçütleri, modelin veya sistemin verimliliğinin değerlendirilmesinde kullanılan metriklerdir. Öğrenme algoritmalarının başarı performansı genellikle bir test verisi üzerinden analiz edilerek değerlendirilir. Yaygın olarak kullanılan performans ölçütlerinden bazıları aşağıda sıralanmıştır (Maeda-Gutiérrez, Galvan-Tejada et al. 2020).

- **Doğruluk:** Sınıflandırma performansını değerlendirmek için en çok kullanılan ölçüdür. Eldeki modelin kaç kez doğru tahmin yaptığını ölçerek doğru şekilde sınıflandırılan örneklerin yüzdesini hesaplamaya yardımcı olur. Yani model 100 giriş örneği ile test edildiğinde ve 90 kez doğru tahmin yapmışsa, bu modelin %90 doğru olduğu anlamına gelir (Maeda-Gutiérrez, Galvan-Tejada et al. 2020). Doğruluk, aşağıdaki Denklem 3.4 ile hesaplanır:

$$\text{Doğruluk} = \frac{\text{Doğru tahminler}}{\text{Toplam örnek sayısı}} = \frac{TP + TN}{TP + TF + FP + FN} \quad (3.4)$$

Burada,

- *Gerçek pozitif (TP: True Positive)*: Model, pozitif vakaların doğru tahminini (hastalık vardı ve hasta olarak tahmin edildi) yapmıştır.
- *Gerçek negatif (TN: True Negative)*: Model, negatif vakaların doğru tahminini (hastalık yoktu ve normal olarak tahmin edildi) yapmıştır.
- *Yanlış pozitif (FP: False Positive)*: Model, pozitif vakaların yanlış tahminini (hastalık vardı ve normal olarak tahmin edildi) yapmıştır.
- *Yanlış negatif (FN: False Negative)*: Model, negatif vakaların yanlış tahminini (hastalık yoktu ve hasta olarak tahmin edildi) yapmıştır.
- **Duyarlılık**: Pozitif vaka örneklerinin model tarafından doğru olarak sınıflandırılmasına karşılık gelir ve kaç vaka örneğinin doğru olarak etiklendiğini ifade eder (Adil 2021). Duyarlılık, aşağıdaki Denklem 3.5 ile hesaplanır:

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.5)$$

- **Özgüllük**: Gerçek negatif olarak etiketlenen vaka örneklerinin doğru şekilde sınıflandırılmasına karşılık gelir (Altuntaş, Cömert et al. 2019). Özgüllük, aşağıdaki Denklem 3.6 ile hesaplanır:

$$Özgüllük = \frac{TN}{TN + FP} \quad (3.6)$$

- **Kesinlik (Hassasiyet)**: Kesinlik, algoritmanın tahmin gücünü değerlendirir. Pozitif vaka örneklerinin kaçının gerçekten pozitif olduğunu tahmin edebilen kesin ifadedir (Adil 2021). Kesinlik, aşağıdaki Denklem 3.7 ile hesaplanır:

$$Kesinlik = \frac{TP}{TP + FP} \quad (3.7)$$

- **F-Skoru**: F-skoru, Denklem (3.8)'de gösterildiği gibi harmonik ortalama kesinlik ve duyarlılık olarak belirlenir (Adil 2021). Bu metriğin yüksek değere sahip olması, modelin pozitif sınıfta daha iyi performans sergilediğini gösterir. F-skoru, aşağıdaki denklemle hesaplanır:

$$F - Skoru = 2 * \frac{Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \quad (3.8)$$

- **Karmaşıklık Matrisi**: Referans alınan sınıflandırma ile modelin tahmini sınıflandırmasındaki performansını bir matris üzerinde özetleyen metriktir. Kalp SPECT MPI görüntü veri setinin anormal ve normal olarak sınıflandırılması için 2*2'lik karmaşıklık matrisi tasarlanmalıdır. Karmaşıklık matrisindeki modelin tahmini sınıflandırması sütunlara, referans alınan değerlerin sınıflandırması satırlara karşılık gelir ve örnek veri setlerinin sayıları TP (True Pozitif/Gerçek Pozitif), FP (False Positive/Yanlış Negatif), FN (False Negative/Yanlış Negatif), TN (True Negative/Gerçek Negatif) olarak Şekil 3.20'deki gibi ifade edilir (Altuntaş, Cömert et al. 2019).

| | | Tahmin edilen | |
|-----------------------|----------------|------------------------|------------------------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | TP (Gerçek Pozitif) | FN (Yanlış Negatif) |
| | Normal | FP (Yanlış Pozitif) | TN (Gerçek Negatif) |

Şekil 3.20. Karmaşıklık Matrisi

3.9 Kalp Spect Verilerinin Toplanması ve ESA ile İskemi Değerlendirmesi

KAH'ın varlığını, durumunu ve lokalizasyonunu non-invaziv yöntemlerle doğru, hızlı ve erken teşhis etmek hasta açısından önem arz eder (Arasaratnam and Ruddy 2015). Derin öğrenme ile veri artırma ve açık kaynak bulma imkanı elde edilir ve tıbbi problemlerde daha doğru teşhis sağlayabilir. Bu çalışma kapsamında nükleer tıpta kullanılan SPECT görüntüleri kullanılarak bir derin öğrenme yöntemi olan ESA modeli eğitilmiştir ve bunun için programlama ortamı olarak Python dili kullanılmıştır. Transfer öğrenme yöntemi önceden eğitilmiş bir mimari ile ESA modeline bilgi aktarımı yaparak modelin eğitiminde kolaylık sağlar. Bu çalışmada transfer öğrenme modeli için öncelikle retrospektif olarak elde edilen kalp SPECT görüntü veri setinin ön işleme (görüntüde kırpma) FIJI programı kullanılarak yapılmıştır. Çalışmanın sonraki aşamalarında önceden eğitilmiş TÖ mimarileri (DenseNet121, InceptionResNetV2, InceptionV3, MobileNet, MobileNetV2, ResNet50, VGG16, VGG19, Xception) ile özellik çıkarma ve sınıflandırma işlemi yapılmıştır (Berkaya, Sivriköz et al. 2020). Son olarak DÖ modelinin başarı oranını değerlendirmek üzere karmaşıklık matrisi, duyarlılık, özgüllük, doğruluk, F-Skoru, ROC eğrisi ve AUC parametresi gibi performans ölçütleri kullanılmıştır. (Altuntaş, Cömert et al. 2019).

4. BULGULAR

Bu çalışmada nükleer tıp görüntüleme yöntemlerinden biri olan SPECT ile elde edilmiş kardiyak görüntüler üzerinden evrişimli sinir ağları yardımıyla KAH sınıflandırılması hedeflenmiştir. Kardiyoloji uzmanları tarafından değerlendirilen SPECT_MPI görüntüleri ile tasarlanan ve Red Green Blue (RGB) renk skalasından oluşan RGB_SPECT_MPI_CNN veri seti ESA (CNN) modellerinin öngörülerini ile karşılaştırılmıştır. Geliştirilen RGB_SPECT_MPI_CNN derin öğrenme modelinin eğitimi ve testi için Akdeniz Üniversitesi Hastanesi arşivinden SPECT MPI görüntüleri retrospektif olarak taranmıştır. İlk aşamada FIJI programı kullanılarak görüntüler üzerinde ön işleme adımı (kırpma) uygulanmıştır. Bir sonraki adımda ise modelin eğitim süreci tamamlandıktan sonra önceden eğitilmiş olan farklı transfer öğrenme modelleri ile eğitim yapılarak sınıflandırma işlemi gerçekleştirilmiştir. Böylece çalışmada kullanılan InceptionV3, Xception, MobileNet, VGG16, VGG19, ResNet50, DenseNet121, MobileNetV2 ve InceptionResNetV2 transfer öğrenme modelleri arasında performans metrikleri karşılaştırılmıştır.

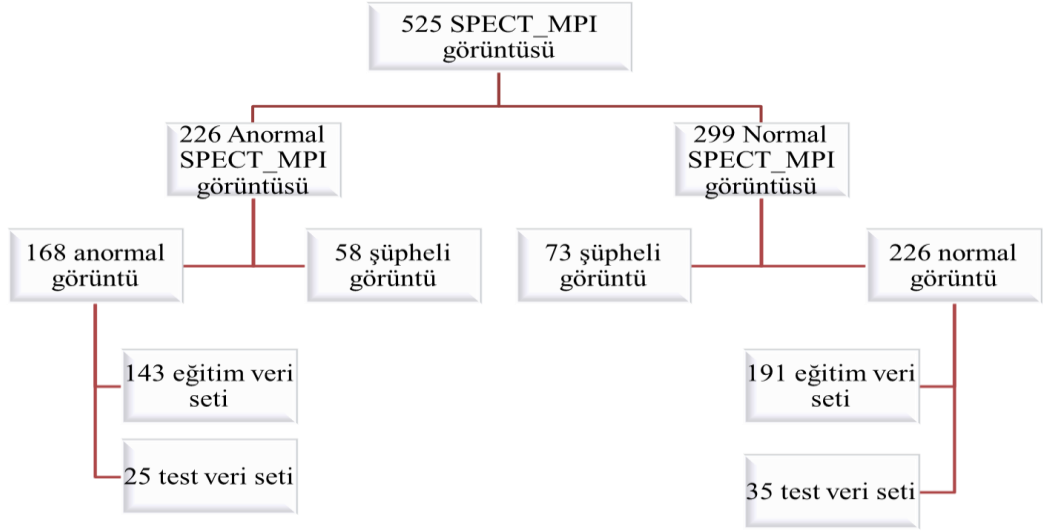
4.1 Klinik SPECT_MPI Veri Setinin Oluşturulması

Bu çalışmada Akdeniz Üniversitesi Nükleer Tıp Anabilim Dalı'nda Mart 2021-Aralık-2021 tarihleri arasında SPECT MPI çekim protokolü ile elde edilen 525 hastanın RGB_SPECT_MPI görüntüleri kullanılmıştır. Çalışmada yer alan retrospektif görüntüler için öncelikle etik kurul onayı alınmıştır. Hastaların istirahat ve stres çekimi sonrası alınan SPECT_MPI görüntüleri kardiyoloji veya nükleer tıp uzmanları tarafından değerlendirilerek her bir hastaya KAH tanısı konulmuştur.

Hasta verilerinin yer aldığı DICOM formatındaki “.dcm” uzantılı görüntüler Python programlama dilinin Jupyter arayüzünde oluşturulan bir kod yardımıyla hasta ID'leri değiştirilmeden JPG formatına dönüştürülerek “.jpg” uzantısı ile kaydedilmiştir. Ayrıca nükleer tıp uzmanlarının SPECT MPI hasta görüntüleri üzerinden yaptıkları KAH teşhisi hakkındaki değerlendirmelerin bulunduğu “.TXT” uzantılı rapor dosyaları da bu kod ile taranarak ilgili klasörlerden pratik olarak ayıklanmıştır.

Uzmanların hasta raporunda belirttikleri görüşlerine dayanarak hastalar öncelikle anormal ve normal olarak iki sınıfa ayrılmıştır. Uzman görüşlerinde net bir bilgiye ulaşılamamış şüpheli 131 hasta görüntüsü oluşturulan veri setine dahil edilmemiştir. Arşivden belirtilen aralıklar için filtrelenen 525 hastadan geriye kalan 394 hastanın 168'i anormal, 226'sı ise normal olarak etiketlenmiştir.

RGB_SPECT_MPI görüntülerinde yer alan ancak herhangi bir kardiyak bilgi içermeyen sayılar, çizgiler, yazılar ve grafikler FIJI programı kullanılarak her bir görüntü temizleme işlemine tabii tutulmuştur. Bu işlemde geçirilen görüntüler tasarlanan RGB_SPECT_MPI_CNN modeli için veri seti olarak kullanılmak üzere hazır hale getirilmiştir. Toplamda iki sınıf (anormal (0), normal (1)) olan RGB_SPECT_MPI görüntüleri, geliştirilen ESA modelinde kullanıma sunulması için her sınıfta da eğitim ve test olmak üzere ikiye bölünmüştür. Etiketlenen görüntüler anormal (0); eğitim:143, test:25, normal (1); eğitim:191, test:35 olarak Şekil 4.1'deki gibi iki gruba ayrılmıştır.



Şekil 4.1. RGB_SPECT_MPI_CNN modeli için oluşturulan veri kümesinin şeması


4.2 İskemi Tanısı İçin Önerilen Transfer Öğrenme Modelinin Tasarım Aşamaları

Bu tez çalışmasında ESA mimarileri kullanılarak RGB_SPECT_MPI görüntüleri üzerinden koroner arter hastalığında iskemi/canlı doku analizinin derin öğrenme metoduyla gerçekleştirilmesi önerilmiştir. Nükleer tıp hekimlerin iskemi/canlı doku değerlendirmeleri referans alınarak geliştirilen derin öğrenme modeli SPECT görüntülerinin anormal/normal sınıflandırmasını yapmıştır. ImageNet veri kümesi ile önceden eğitilmiş farklı transfer öğrenme modellerinin kullanımı önerilen bu yöntem ile iskemi teşhisinin uzman görüşlerine yakın biçimde öngörülmesi amaçlanmıştır.

Derin öğrenme modellerinin eğitiminde yer alacak görüntülerin bazı özelliklerinin modelin başarımı üzerinde önemli etkisi olabilmektedir. Bu bakış açısıyla ilerleyerek görüntü işleme yöntemlerinden ön işleme ve sınıflandırma adımlarından yararlanılmıştır. Medikal görüntülerle hastalık teşhisinde RGB veya GRAY formatı fark etmeksizin uzmanın bilgi birikimi önem arz eder. Bu deneyimi ESA modellerine orijinal görüntüler üzerinden entegre etmek güçtür. Uygulamada tasarladığımız RGB_SPECT_MPI_CNN modelinde kullanılan veri seti ön hazırlık aşamasından geçirilmiştir.

Akdeniz Üniversitesi Hastanesi PACS sisteminden çekilen görüntülerle oluşturulan SPECT MPI veri seti tek tek hasta ID numaralarını içerecek şekilde adlandırılmıştır. 525 hastaya ait DICOM formatındaki SPECT görüntüleri ile TXT formatındaki hasta raporlarını içeren klasörler filtrelenerek kaydedilmiştir. Bu süreçten sonra DÖ modelinin eğitim ve test aşamalarında kullanılacak SPECT görüntüleri “.jpg” ve hasta sonuç raporu ise “.txt” dosyasına dönüştürülmüştür.

SPECT_MPI görüntülerinin içerdiği bazı metin bilgileri ve sembolleri DÖ modellerinin başarımını etkileyebileceğinden KAH tanısına katkısı olmayan kısımlar FIJI programı ile kırılarak yeni bir görüntü seti elde edilmiştir (Şekil 4.2). Net bir bilgiye ulaşamayan 131 hastaya ait görüntü veri kümesinden çıkarılarak toplamda 394 hastaya ait görüntü kümesi ile TÖ modellerinin eğitim ve test işlemleri yapılmıştır.



Şekil 4.2. Bir hastaya ait (a) Orijinal anormal, (b) Kırpılmış anormal SPECT MPI görüntüleri, (c) Orijinal normal, (d) Kırpılmış normal SPECT MPI görüntüleri

Görüntü işleme tekniklerinden olan görüntü sınıflandırma aşamasını günümüzde önemli bir konu haline gelen çeşitli transfer öğrenme mimarilerine uygulayarak bu çalışma yapılmıştır. Python programlama dilinin uygulanabildiği Google Colaboratory arayüzünde kullanıma sunulan GPU bağlantısı seçilerek farklı transfer öğrenme mimarileri uygun şekilde eğitim ve test veri setleri olarak sınıflandırılmıştır. ESA mimarilerinin başarımlarını artıracak niteliğe sahip olan Tensorflow 2.6.4 ve Keras 2.6.0 kütüphanelerinden yararlanılarak KAH’da iskemi/canlı doku değerlendirmesi yapılmıştır. Bu tez çalışmasında Bölüm 3.6’da yer alan bilgiler ışığında geliştirilen transfer öğrenme modeli ile SPECT_MPI görüntüleri üzerinden KAH tanısı bilgisini gözlemci olmadan verebilecek bir ESA modeli önerilmiştir.

4.3 Koroner Arter Hastalığında SPECT_MPI_CNN_TL Modelin İskemi Değerlendirmesi Sonuçları

Transfer öğrenme mimarileri kullanılarak KAH’da iskemi değerlendirmesinin araştırıldığı çalışmada derin öğrenme modellerinin eğitim ve test işlemlerinde kullanılan hiperparametreler Çizelge 4.1.’de belirtilmiştir.

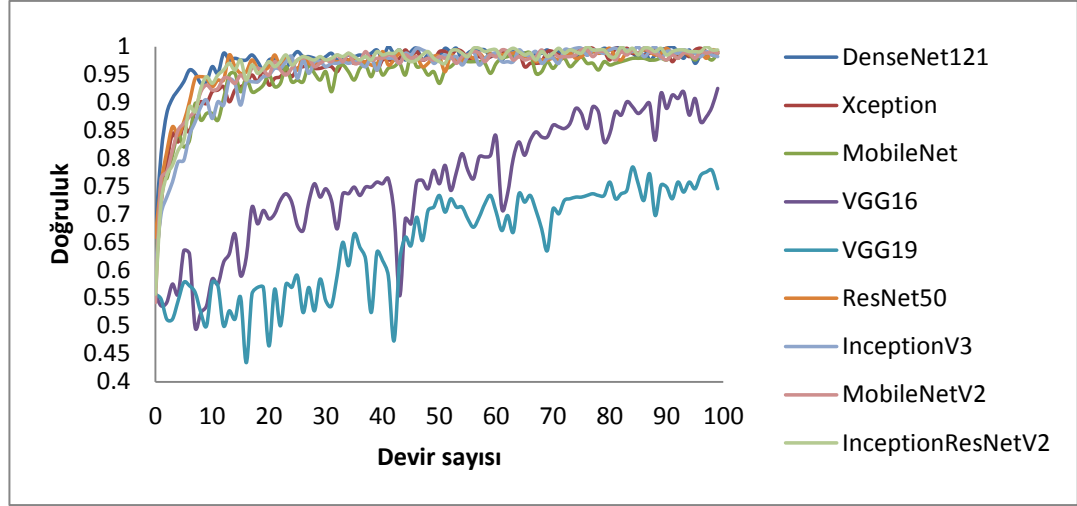
Yapay zeka ile görüntü sınıflandırma çalışmalarında yer alan “ImageNet” veri kümesi ile önceden eğitilmiş toplam 9 mimari (DenseNet121, Xception, MobileNet, VGG16, VGG19, ResNet50, InceptionV3, MobileNetV2, InceptionResNetV2) sırasıyla eğitim ve test süreçlerinden geçirilerek sınıflandırma sağlanmıştır. Çoklu sınıflandırmayı sağlayan “softmax” sayesinde görüntülerde normal ve anormal olarak ikili

sınıflandırma işlemi yapılmıştır. Benzer şekilde derin öğrenmede sıklıkla tercih edilen ve başarı performansını artıran “Adam” optimizasyon algoritması seçilmiştir. Modelin içeriğinde bulunan veri artırma komutları (data augmentation) ile de büyük bir veri kümesi elde edilmiştir. Son olarak eğitim süreci için 100 devir sayısına (epoch) karşılık 32 yığın boyutu (batch size) belirlenerek hızlı ve doğru karar veren bir transfer öğrenme modeli üzerine çalışma yapılmıştır. Eğitimi yapılan SPECT_MPI görüntülerin farklı transfer öğrenme mimarileri ile sınıflandırılmasındaki başarı kriterlerinden olan devir sayısına karşılık doğruluk grafiği Şekil 4.3.’te ve devir sayısına karşılık kayıp grafiği Şekil 4.4.’te gösterilmiştir.

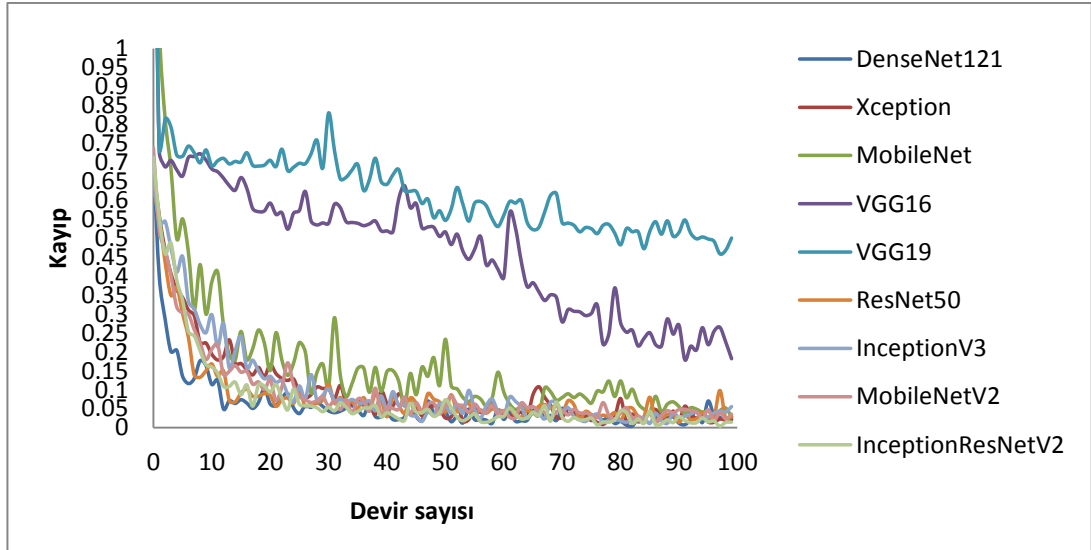
Çizelge 4.1. Transfer öğrenme modellerinde kullanılan hiperparametreler ve değerleri

| Hiperparametreler | Değerler |
|--------------------------|----------|
| Optimizasyon Algoritması | Adam |
| Aktivasyon Fonksiyonu | Softmax |
| Öğrenme Hızı | 0.001 |
| Devir Sayısı | 100 |
| Yığın Boyutu | 32 |

Bu çalışma sonucunda 9 farklı transfer öğrenme mimarisi kullanılarak elde edilen performans metriklerinin (karmaşıklık matrisleri, doğruluk, kayıp, kesinlik, duyarlılık, F1-skoru, ROC eğrisi/AUC değeri) analizleri yapılarak koroner arter hastalığında iskemi/canlı doku değerlendirmesi incelenmiştir. Eğitim veri setinin karmaşıklık matrisi ile doğruluk değerine bakılırsa en yüksekten en düşüğe doğru sınıflandırmayı sağlayan transfer öğrenme mimarileri başarı performansı sırasıyla InceptionV3 (0.982), Xception (0.964), InceptionResNetV2 (0.955), VGG16 (0.947), MobileNet (0.94), DenseNet121 (0.901), ResNet50 (0.898), MobileNetV2 (0.75) ve VGG19 (0.733); test veri setinde ise InceptionV3 (1.0), Xception (1.0), InceptionResNetV2 (1.0), MobileNet (1.0), DenseNet121 (1.0), ResNet50 (1.0), VGG16 (0.983), VGG19 (0.85) ve MobileNetV2 (0.772) olarak hesaplanmıştır. Google Colaboratory’de eğitim ve test adımları yürütülen TÖ mimarileri yaklaşık olarak 15 dk içerisinde sonuç vermiştir. Modellerin eğitim aşamasının tahmin edilenden daha kısa sürede tamamlanmasında Tensorflow: 2.6.4 ve Keras: 2.6.0 kütüphanelerinin kullanılması etkili olabilir.



Şekil 4.3. Transfer öğrenme modellerinin doğruluk grafiği

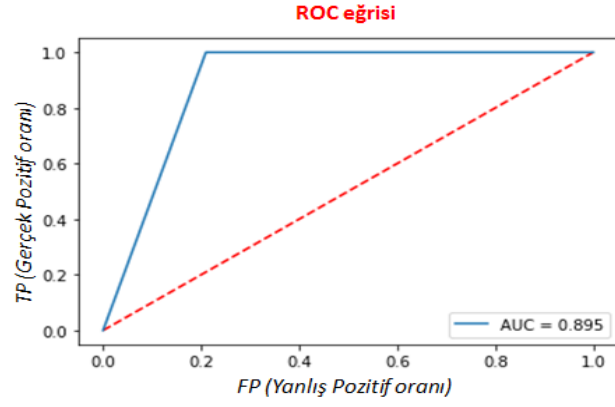


Şekil 4.4. Transfer öğrenme modellerinin kayıp grafiği

Normal ve Anormal olarak sınıflandırılan veri setleri için 2*2 boyutlarında karmaşıklık matrisleri tasarlanmıştır. Geliştirilen model için karmaşıklık matrisleri, ROC eğrisi, AUC değerleri ve doğruluk/kayıp grafikleri oluşturulmuştur. Transfer öğrenme mimarilerinin her biri için ayrı ayrı elde edilen performans ölçütleri incelenerek modeller arasında değerlendirmeler yapılmıştır. Çalışmada yer alan TÖ mimarilerinin bir arada karşılaştırılmasına imkan sunan eğitim ve test veri setlerin karmaşıklık matrisleri ile ROC eğrisi/AUC değeri Şekil 4.5.; DenseNet121, Şekil 4.6.; Xception, Şekil 4.7.; MobileNet, Şekil 4.8.; VGG16, Şekil 4.9.; VGG19, Şekil 4.10.; ResNet50, Şekil 4.11.; InceptionV3, Şekil 4.12.; MobileNetV2, Şekil 4.13.; InceptionResNetV2'de gösterildiği gibidir.

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 113 | 30 |
| | Normal | 0 | 191 |

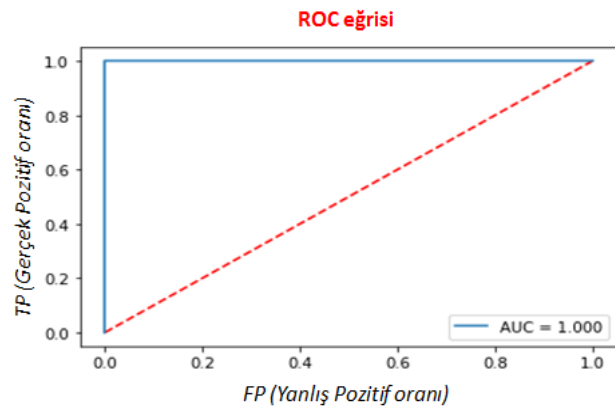
(a)



(c)

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 25 | 0 |
| | Normal | 0 | 35 |

(b)

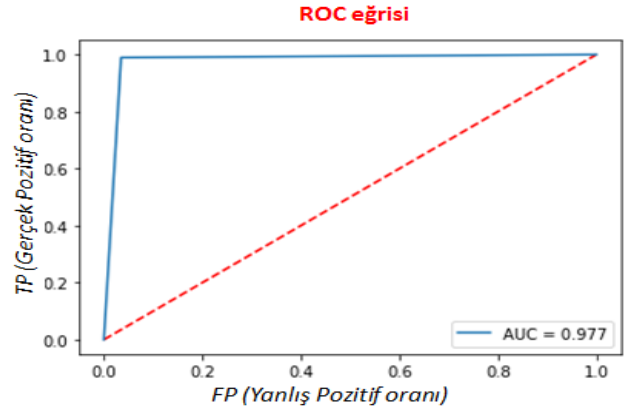


(d)

Şekil 4.5. DenseNet121 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 138 | 5 |
| | Normal | 2 | 189 |

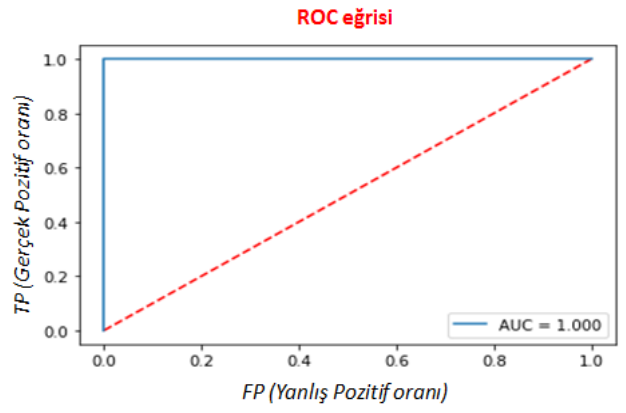
(a)



(c)

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 25 | 0 |
| | Normal | 0 | 35 |

(b)




(d)

Şekil 4.6. Xception modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 133 | 10 |
| | Normal | 13 | 178 |

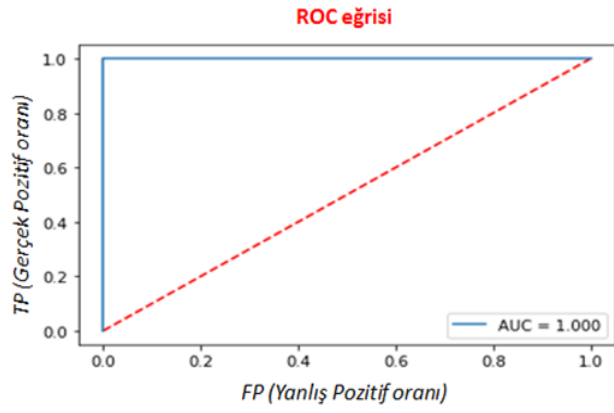
(a)



(c)

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 25 | 0 |
| | Normal | 0 | 35 |

(b)




(d)

Şekil 4.7. MobileNet modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 123 | 20 |
| | Normal | 30 | 161 |


(a)



(c)

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 24 | 1 |
| | Normal | 0 | 35 |

(b)




(d)

Şekil 4.8. VGG16 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 104 | 39 |
| | Normal | 34 | 157 |


(a)



(c)

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 22 | 3 |
| | Normal | 6 | 29 |

(b)




(d)

Şekil 4.9. VGG19 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 139 | 4 |
| | Normal | 26 | 165 |


(a)



(c)

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 25 | 0 |
| | Normal | 0 | 35 |

(b)

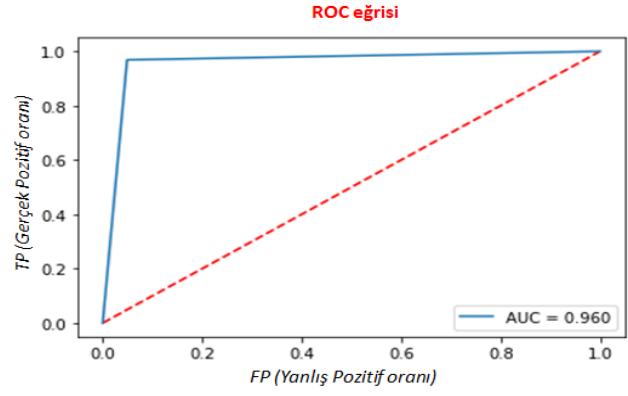


(d)

Şekil 4.10. ResNet50 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 136 | 7 |
| | Normal | 6 | 185 |


(a)



(c)

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 25 | 0 |
| | Normal | 0 | 35 |

(b)




(d)

Şekil 4.11. InceptionV3 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri

| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 66 | 77 |
| | Normal | 1 | 190 |


(a)



(c)

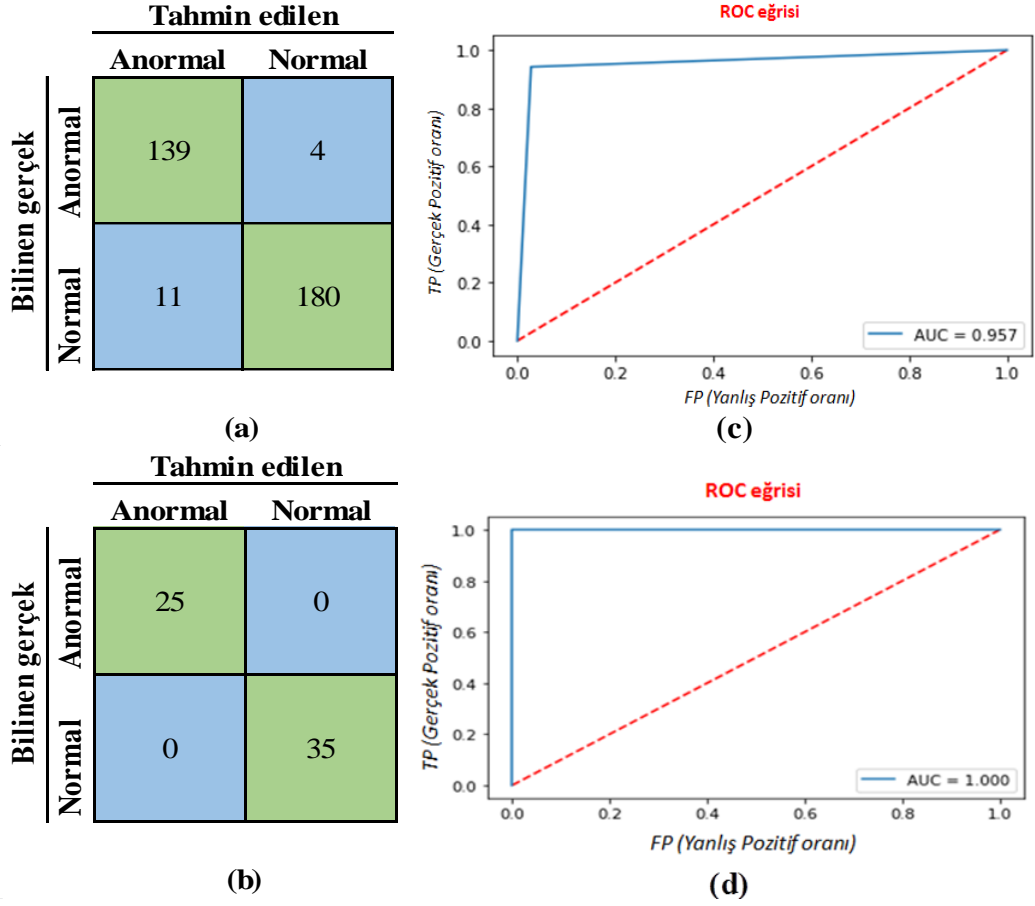
| | | Tahmin edilen | |
|----------------|---------|---------------|--------|
| | | Anormal | Normal |
| Bilinen gerçek | Anormal | 10 | 15 |
| | Normal | 0 | 35 |

(b)



(d)

Şekil 4.12. MobileNetV2 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri



Şekil 4.13. InceptionResNetV2 modeline ait (a) eğitim ve (b) test veri setlerinin karmaşıklık matrisleri ile (c) eğitim ve (d) test veri setlerinin ROC eğrisi/AUC değeri

Her bir model için ayrı ayrı yukarıda oluşturulan karmaşıklık matrisleri üzerinden model performansları arasında karşılaştırmayı sağlayan Denklem 3.4. ile doğruluk, Denklem 3.5 ile duyarlılık, Denklem 3.7. ile kesinlik ve Denklem 3.8. ile F1-Skoru değerleri hesaplanarak elde edilen sonuçlar Çizelge 4.2’de belirtildiği gibi aktarılmıştır.

Çizelge 4.2. Transfer öğrenme modellerine ait eğitim ve test veri kümesinin başarı performansı

| MODELLER | Doğruluk | | Kesinlik | | Duyarlılık | | F1-Skoru | | AUC | |
|--------------------------|----------|-------|----------|------|------------|------|----------|------|--------|-------|
| | Eğitim | Test | Eğitim | Test | Eğitim | Test | Eğitim | Test | Eğitim | Test |
| <i>DenseNet121</i> | 0.901 | 1.0 | 0.92 | 1.0 | 0.91 | 1.0 | 0.91 | 1.0 | 0.895 | 1.0 |
| <i>Xception</i> | 0.964 | 1.0 | 0.98 | 1.0 | 0.98 | 1.0 | 0.98 | 1.0 | 0.977 | 1.0 |
| <i>MobileNet</i> | 0.94 | 1.0 | 0.93 | 1.0 | 0.93 | 1.0 | 0.93 | 1.0 | 0.931 | 1.0 |
| <i>VGG16</i> | 0.947 | 0.983 | 0.85 | 0.98 | 0.85 | 0.98 | 0.85 | 0.98 | 0.852 | 0.98 |
| <i>VGG19</i> | 0.733 | 0.85 | 0.78 | 0.86 | 0.78 | 0.85 | 0.78 | 0.85 | 0.775 | 0.854 |
| <i>ResNet50</i> | 0.898 | 1.0 | 0.92 | 1.0 | 0.91 | 1.0 | 0.91 | 1.0 | 0.918 | 1.0 |
| <i>InceptionV3</i> | 0.982 | 1.0 | 0.96 | 1.0 | 0.96 | 1.0 | 0.96 | 1.0 | 0.96 | 1.0 |
| <i>MobileNetV2</i> | 0.75 | 0.772 | 0.82 | 0.83 | 0.75 | 0.77 | 0.72 | 0.74 | 0.7 | 0.728 |
| <i>InceptionResNetV2</i> | 0.955 | 1.0 | 0.96 | 1.0 | 0.96 | 1.0 | 0.96 | 1.0 | 0.957 | 1.0 |

Eğitim ve test veri seti birlikte değerlendirildiğinde en yüksek başarı sıralaması InceptionV3, Xception ve InceptionResNetV2 mimarileri, en düşük başarı sıralaması ise MobileNetV2, VGG19 ve VGG16 mimarileri olarak gözlenmiştir. SPECT_MPI görüntülerin sınıflandırmasını kararlı, doğru ve hızlı bir şekilde yapabilen en uygun transfer öğrenme mimarisi InceptionV3'tür. Şekil 4.4'te yer alan doğruluk ve Şekil 4.5'te yer alan kayıp grafikleri ele alındığında VGG19 ve VGG16 mimarilerin eğitim veri setini öğrenme sürecinde diğer mimarilere göre daha başarısız olduğu saptanmıştır. Karmaşıklık matrisi ve doğruluk değerleri ile doğruluk/kayıp grafikleri incelendiğinde MobileNetV2 mimarisinin kararsız olduğu sonucuna varılmıştır.

Çizelge 4.2.'ye bakılırsa eğitim veri setinde en yüksek *kesinlik* (0.98), *duyarlılık* (0.98), *F1-Skoru* (0.98) ve *AUC değeri* (0.977) Xception mimarisine, en düşük *kesinlik değeri* VGG19 (0.78) mimarisine ve *duyarlılık* (0.75), *F1-Skoru* (0.72) ile *AUC değeri* (0.7) MobileNetV2 mimarisine aittir. Benzer şekilde test veri setinde en yüksek *kesinlik* (1.0), *duyarlılık* (1.0), *F1-Skoru* (1.0) ile *AUC değeri* (1.0) Xception, InceptionV3, InceptionResNetV2, MobileNet, DenseNet121 ve ResNet50 mimarilerinde, en düşük *kesinlik* (0.83), *duyarlılık* (0.77), *F1-Skoru* (0.74) ve *AUC değeri* (0.728) MobileNetV2 mimarisinde hesaplanmıştır. Çizelge 4.2.'de değerlendirilen performans metriklerinde ise en iyi sonuçlar Xception mimarisi ile elde edilmiştir. Karmaşıklık matrisinden yola çıkarak elde edilen diğer performans metrikleri bir arada analiz edilerek koroner arter hastalığında iskemi/canlı doku sınıflandırmasının transfer öğrenme modeli ile yapılabileceği kanısına varılmıştır. Transfer öğrenme mimarilerin eğitim süreleri karşılaştırıldığında yaklaşık olarak benzer sürelerde (Ortalama 1.epoch: 27 sn, diğer epochların her biri ortalama 8 sn'de, toplam eğitim süresi ortalama: 243 sn) çalışmıştır. Mimarilerin eğitim ve test sürelerinin birbirine yaklaşık olmasının sebebi kullanılan tensorflow: 2.6.4 ve keras: 2.6.0 kütüphanelerinden kaynaklı olduğu düşünülmektedir. Güncel versiyonların tercih edilmesi daha doğru, kararlı ve hızlı analiz yeteneğine sahip bir derin öğrenme modeli tasarlamayı amaçlamaktadır.

5. TARTIŞMA

Tıbbi görüntüleme yöntemlerinin yaygınlaşması ve buna paralel olarak son yıllarda yapay zeka ve derin öğrenme tekniklerinin gelişmesi tanı bilimine yeni yaklaşımlar kazandırmıştır. Farklı bilimsel çalışmaların sağlık alanında hız kazanması hastalıkların tanı ve tedavisinde fayda sağlamış ve farklı alanlarda kullanılan derin öğrenme tekniklerinin sağlık alanına da uyarlanabileceği kanısına varılmıştır. Bu tez çalışmasında nükleer tıp görüntüleme yöntemlerinden biri olan SPECT görüntüleme sisteminden elde edilen kalp görüntüleri üzerinden iskemi/canlı doku tanısını sağlayabilecek bir derin öğrenme modeli tasarlanması hedeflenmiştir. Çalışma kapsamında Akdeniz Üniversitesi Hastanesi Nükleer Tıp Anabilim Dalı'nda SPECT MPI çekim protokolü uygulanarak elde edilen 525 hastaya ait görüntü veri seti kullanılmıştır. Her bir hastanın dinlenme ve stres çekim protokolünden elde edilen görüntü dizileri veri seti içinde birlikte yer almaktadır. Bu görüntü veri setlerinde kalp ve kalpteki damarların istirahat/stres durumundaki davranışları nükleer tıp uzmanları tarafından tek bir çerçevede yorumlanarak KAH teşhisi yapılmıştır. Bu görüşlerin referans alındığı bu tez çalışmasında KAH teşhisinde gerekli olan bilgiyi veren iskemi/canlı doku sınıflandırması derin öğrenme yöntemi için ve görüntü etiketi olarak kullanılmıştır.

Literatürde yapılan çalışmalar incelendiğinde derin öğrenme modellerini kullanarak KAH tanısının analizinin yapıldığı çalışmalarda son zamanlarda artış gözlenmektedir. Bu çalışmalarda, SPECT görüntüleme tekniklerinden elde edilen veri setleri ve hasta kriterleri değerlendirilerek yapay sinir ağları, makine öğrenmesi ve derin öğrenme metotları ile KAH tanısı gerçekleştirilmeye çalışılmıştır. MÖ tekniklerinin kullanıldığı çalışmalarda hasta özellikleri, kantitatif perfüzyon ve klinik veriler gibi değişkenlik gösteren parametreler baz alınarak uzman destekli sınıflandırma yapılmıştır. YSA ve DÖ tekniklerinin kullanıldığı çalışmalarda farklı görüntü işleme tekniklerini de (ön işleme, bölütleme ve sınıflandırma) kapsayan birçok araştırmaya yer verilmiştir.

Bu tez çalışmasında non-invaziv görüntüleme tekniklerinden elde edilen verilerin depolanmasını ve bilgi birikimlerinin aktarılmasında katkıda bulunabilecek transfer öğrenme metodu önerilmiştir. Tıbbi görüntüleme alanında, yüksek doğrulukta otomatik analiz yapmayı başarabilecek derin öğrenme modelini görüntüleme cihazlarına entegre ederek birçok hastalığın erken tanı ve tedavisine katkı sağlayabilecek bir çalışma yapılması amaçlanmıştır. Diğer çalışmalardan farklı olarak SPECT MPI görüntülerinden elde edilen dinlenme/stres görüntüleri ile kısa eksen (SA), yatay uzun eksen (HLA) ve dikey uzun eksen (VLA) görüntülerinin hepsi bir çerçevede bulunan (her bir hastaya ait 66 görüntü dizisi tek görüntü karesinde) veri seti derin öğrenme modeline doğrudan verilmiştir. Uzman doktorların iskemi/ canlı doku tanısında kullandığı SPECT görüntülerindeki kalp dışı bilgiler ön işlemeden geçirilerek görüntüden ayıklanmıştır. Çeşitli transfer öğrenme mimarilerinde eğitim gerçekleştirilerek az veri seti ile KAH tanısında yüksek doğruluk değeri elde edilmeye çalışılmıştır. Ayrıca hasta kriterleri, SPECT çekiminden elde edilen kutup haritaları, fonksiyonel ve klinik veriler gibi farklı parametrelere ihtiyaç duyulmadan çalışma yapılmıştır. Böylece stres/dinlenme çekim protokolü uygulanan hasta görüntüleri sadece bir ön işleme tabii tutulduktan sonra derin öğrenme modeline aktarılıp Anormal ve Normal olarak görüntüde sınıflandırma işleminin yapılabilmesi düşünülmüştür.

El Rafaie vd. (2012) yapmış oldukları çalışmada araştırmacılara açık olan UCI

KKD havuzundaki SPECT kalp hastalıkları veri kümesine veri madenciliğinin alt dalı olan kaba kümeler algoritması yaklaşımını uygulayarak uzman destekli otomatik sınıflandırma işlemi incelenmiştir. Veri kümesinin sahip olduğu 22 özellik ve bir karar sınıfı kullanılarak eğitim veri kümesine genetik algoritma yaklaşımı ile indirgeme işlemi sağlanmıştır. Bu aşamadan sonra uzman yardımı ile eğitilen veri kümesinin karar kuralları belirlenerek anormal ve normal şeklinde sınıflandırma yapılmıştır. Kalbin iskemi/canlı doku sınıflandırmasındaki başarısını değerlendiren %85 özgüllük, %95 duyarlılık, %93 ($\pm 3,8$) genel sınıflandırma doğruluğu sonuçları elde edilmiştir.

Bu tez çalışmasında kullanılan ham SPECT MPI görüntü veri seti üzerinden KAH tanısının konulması için görüntüde önışleme ve sınıflandırma işlemleri yapılmıştır. Önışleme adımı için yararlanılan FIJI programı aynı anda tüm görüntü veri setlerinin (anormal ve normal olarak iki sınıfa ayrılan) önışlemeden geçirilmesini sağlayarak hastalığın tanısında bilgi vermeyen kısımları kolayca çıkarabilmiştir. Sınıflandırma adımında önışlemeden geçirilen veri setleri ESA ve önceden eğitilmiş 9 farklı transfer öğrenme mimarisi kullanılarak anormal ve normal olmak üzere sınıflandırma işlemi gerçekleştirilmiştir. Çalışma sonucunda eğitim veri setinde InceptionV3 mimarisinde en yüksek doğruluk (%98.2), Xception mimarisi ile de en yüksek kesinlik (%98), duyarlılık (%98), F1-Skoru (%98) ve AUC (0.977) değerlerine ulaşılmıştır. Test veri setinde ise DenseNet121, Xception, MobileNet, ResNet50, InceptionV3 ve InceptionResNetV2 mimarileri hesaplanan tüm performans metriklerinde %100 başarı göstermiştir. Transfer öğrenme metodu kullanılarak yapılan sınıflandırmada yüksek performans elde edilmesinin sebepleri arasında mimarilerin temel yapısının ESA'ya dayanması ve SPECT MPI görüntü veri setinin direkt olarak tek bir çerçevede (her bir hastaya ait toplam 66 görüntü dizisi) eğitilmesi olduğu düşünülmektedir.

Arsanjani vd. (2013) yapmış oldukları çalışmada destek vektör makinesi algoritması ile KAH tanısının konulmasına yardımcı olan kantitatif perfüzyon özellikleri (stres toplam perfüzyon açığı, iskemik değişiklikler ve stres sonrası ejeksiyon fraksiyon değişiklikleri) ve fonksiyonel değişiklikleri analiz etmeye çalışmışlardır. Çalışma sonucunda SVM'nin duyarlılığı %84, özgüllüğü %88, doğruluğu %86 olarak hesaplanmıştır. Arsanjani vd. (2013) yapmış oldukları bir diğer çalışmada ise ensemble MÖ (LogitBoost) algoritması ile kantitatif perfüzyon ve klinik değişkenleri kullanarak KAH tanısının otomatik analizi üzerine çalışmışlardır. WEKA yazılımı kullanılarak karar kütükleri oluşturulmuş ve sınıflandırma işlemi yapılmıştır. Çalışma sonucunda 30 yıllık tecrübeye sahip uzmanın KAH tanısındaki başarısı ile LogitBoost yaklaşımının başarısı arasında benzer bir doğruluk değeri çıkmıştır. On yıllık tecrübeye sahip uzmanın KAH tanısındaki başarısına göre daha yüksek doğruluk değeri hesaplanmıştır.

Bu tez çalışmasında kantitatif perfüzyon ve klinik değişkenler baz alınmadığından görüntü veri setleri üzerinde farklı yazılımsal çalışmalara ihtiyaç duyulmamıştır. Böylece görüntü veri setlerinde bilgi kaybı veya veri seti azaltma gibi durumlara yer verilmemiştir. MÖ yerine DÖ yöntemi kullanılarak da yüksek doğrulukta sınıflandırma işleminin sağlanmasına katkıda bulunan transfer öğrenme mimarileri uygulanabildiği için sınıflandırmada daha iyi sonuçlar elde edildiği düşünülmektedir. Sınıflandırma işlemini gerçekleştiren transfer öğrenme mimarilerinden en düşük doğruluk, kesinlik, duyarlılık, F1- skoru, AUC değerlerini MobileNetV2, VGG19 ve VGG16 modelleri vermiştir. Diğer mimariler tüm performans metriklerinde ortalama

%90-%100 arasında yüksek başarı göstermiştir. Böylece bu tez çalışmasında SPECT_MPI görüntülerin sınıflandırılmasında transfer öğrenme modellerinin uygunluğu araştırılarak yüksek doğrulukta otomatik analiz yapılabilmektedir.

Nakajima vd. (2017) yapmış oldukları çalışmada SPECT MPI görüntüleri üzerinden KAH tanısını sağlamada kullanılan istatistiksel kantitasyonun tanısallık doğruluğu ile geliştirdikleri YSA'nın karşılaştırmasını çalışmışlardır. İsveç veri tabanı ile eğitilen YSA, Japon veri tabanı ile de eğitilerek veri seti artırılmıştır. Çalışma sonucunda YSA'nın eğitim setinde stres bozukluğu için hassasiyet %86, özgüllük %77, doğruluk %82, dinlenme bozukluğu için hassasiyet %83, özgüllük %74, doğruluk %78 ve iskemi için hassasiyet %82, özgüllük %77, doğruluk %80 olarak sınıflandırmadaki başarısı incelenmiştir.

Bu tez çalışmasında eğitim ve test olmak üzere klinik SPECT MPI veri seti kullanılmıştır. YSA yerine DÖ yaklaşımının uygulanması ağın sadece eğitilmesini değil, test edilmesini de sağlamıştır. Eğitim ve test veri setlerinin sınıflandırılmasında kullanılan MobileNetV2 mimarisi eğitim veri seti için ortalama doğruluk %75, kesinlik %82, duyarlılık %75, F1-skoru %72 ve test veri seti için ortalama doğruluk %77.2, kesinlik %83, duyarlılık %77, F1-skoru %74, AUC 0.728 olarak elde edilmiştir. VGG19 mimarisi eğitim veri seti için doğruluk %73.3, kesinlik %78, duyarlılık %78, F1-skoru %78, AUC 0.775 ve test veri seti için ortalama doğruluk %85, kesinlik %86, duyarlılık %85, F1-skoru %85, AUC 0.854 olarak hesaplanmıştır. Sadece eğitim veri setleri ile eğitilen YSA ağın, DÖ yöntemi ile eğitim ve test veri setinin sınıflandırmadaki başarısı çoğu transfer öğrenme mimarisine göre düşük çıkmıştır. En düşük başarıya sahip olan MobileNetV2 ve VGG19 mimarisi incelendiğinde YSA ağının sonuçlarına yakın değer göstererek transfer öğrenme modellerinin sınıflandırma işleminde tercih edilmesi gerektiği kanısına varılmaktadır. Ayrıca YSA ağının test aşaması nükleer tıp uzmanlar tarafından değerlendirildiği için DÖ modelin tercih edilmesinin zaman açısından avantaj sağlayabileceği düşünülmektedir. Son olarak eğitim ve test veri setinin direkt olarak DÖ modeli üzerinden yapılması hem eğitim hem de test veri setinin sınıflandırılmadaki performans metriklerinin karşılaştırılmasına imkân verdiği düşünülmektedir.

Betancur vd. (2018) yapmış olduğu çalışmada SPECT MPI görüntülerini, Quantitative Perfusion SPECT (QPS)/Quantitative Gated SPECT (QGS) yazılımı ile miyokardiyal konturları belirlemiş ve MÖ yöntemiyle majör advers kardiyak olayların (MACE) otomatik analizini incelemiştir. Çalışmada açık kaynaklı WEKA programı kullanılarak görüntüleme verisi değişkeni, stres testi değişkeni ve klinik değişkenler eğitim veri setinin sınıflandırılmasında kriter olarak seçilmiştir. LogitBoost algoritması ile MACE tahmininin değerlendirilmesinde MÖ-birleştirilmiş (0.81), MÖ-görüntüleme (0.78), MD teşhisi ve stres TPD (0.73) ile iskemik TPD (0.72) olmak üzere 4 farklı ROC-AUC analizinin sonuçları karşılaştırılmıştır. Betancur vd. (2018) yapmış oldukları diğer çalışmada ESA yaklaşımı kullanılarak SPECT MPI görüntüleri üzerinden obstrüktif koroner arter hastalığı tahmini çalışılmıştır. Çalışmada DÖ yöntemi ile öncelikle kutup haritalarından özellik çıkarımı, sonra da damar başına/hasta başına KAH tanısı için sınıflandırma yapılmıştır. Çalışma sonucunda modelin sınıflandırmadaki başarısı ROC-AUC (hasta başına: 0.80 (DÖ), 0.78 (TPD); damar başına: 0.76 (DÖ), 0.73 (TPD)) ve duyarlılık (hasta başına: %79.8 (TPD), %82.3 (DÖ); damar başına %64.4 (TPD); %69.8 (DÖ)) sonuçları elde edilmiştir.

Bu tez çalışmasında SPECT_MPI görüntüleri üzerinden iskemi sınıflandırması transfer öğrenme mimarileri ile sağlandığı için değerlendirmeler SA, HLA ve VLA düzlemlerine ait görüntüler bir arada olacak şekilde gerçekleştirilmiştir. Bu düzlemlerin KAH teşhisine katkısı olabileceği ve düzlemlerin hem bir arada hem de ayrı ayrı ele alınarak farklı kesitsel görüntüler üzerinde çalışma yapılabileceği düşünülmektedir.

Spier vd. (2019) yapmış oldukları çalışmada SPECT MPI görüntülerinden elde edilen kutupsal harita verileri stres ve dinlenme şeklinde ikiye ayrılıp sınıflandırma ve lokalizasyon bilgisi için grafik-evrişimli sinir ağları (GCNN) kullanılarak KAH tanısı çalışılmıştır. Chebyshev filtrelerine bağlı geliştirilen GCNN modeli %89.3, uzman gözlemci %91.2'ye göre daha düşük algılama performansı göstermiştir. Lokalizasyon bilgisi için kutupsal haritaların 17 bölümlü ince segmentasyonu ve 3 bölümlü kaba segmentasyonu yapılarak geliştirilen GCNN modeli %83.1, uzman gözlemci %78.8'e göre daha yüksek başarıyla analiz edilmiştir.

Bu tez çalışmasında kutupsal haritalara ihtiyaç duymadan dinlenme/stres görüntü veri setleri transfer öğrenme modellerinde bir kere eğitilerek sınıflandırılmıştır. GCNN'ye göre önceden eğitilmiş transfer öğrenme mimarileri ile görüntü işleme tekniklerinin uygulanmasının KAH tanısında hızlı değerlendirme ve pratiklik kazandırabileceği düşünülmektedir.

Wang vd. (2020) yapmış oldukları çalışmada SPECT MPI görüntülerinden sol ventrikül (LV) segmentasyonu ve kantifikasyonunu ESA yapısına sahip 3D-V-Net modeli ile gerçekleştirmeye çalışmışlardır. Çalışma sonucunda hacim tabanlı 3D-VNet modelinin LV segmentasyonu ile klinik LV segmentasyonu karşılaştırıldığında (korelasyon katsayısı 0.910 ± 0.061 ve ortalama bağıl hatası $\%1.09 \pm 3.66$) birbirine yakın sonuçlar verdiği görülmüştür. Bu tez çalışmasında KAH tanısı için SPECT MPI görüntülerine segmentasyon adımı yapılmayarak DÖ modelinde eğitilen veri setlerinin sınıflandırmasının yüksek performansta yapılabileceği görülmüştür.

Trung vd. (2020) yapmış oldukları çalışmada SPECT MPI görüntülerinden elde edilen kutup haritası ve kesit görüntüleri kullanarak VGG modeline dayalı DÖ ile KAH tanısında yardımcı olan bilgileri sınıflandırmaya çalışmışlardır. Çalışma sonucunda ortalama hassasiyet, dilim MPI görüntülerinde $\%86.14 \pm \%2.14$, kutup haritası görüntülerinde $\%82.57 \pm \%2.33$ elde edilmiştir. Berkaya vd. (2020) yapmış oldukları çalışmada SPECT MPI görüntü veri seti üzerinden perfüzyon anomalilerini tespit etmek için DÖ tabanlı ve bilgi tabanlı model geliştirmeye çalışmışlardır. Önceden eğitilmiş transfer öğrenme mimarileri kullanılarak DÖ tabanlı ağ eğitilmiş ve DVM sınıflandırması yapılmıştır. Uzman görüşlerine çeşitli görüntü işleme yöntemleri uygulanarak da bilgi tabanlı model sınıflandırması sağlanmıştır. Çalışma sonucunda geliştirilen modellerin sınıflandırmadaki performansları DÖ tabanlı; maksimum doğruluk $\%94$, duyarlılık $\%88$, özgüllük $\%100$ ve bilgi tabanlı; maksimum doğruluk $\%93$, duyarlılık $\%100$, özgüllük $\%86$ olarak elde edilmiştir. Chen vd. (2021) yapmış oldukları çalışmada CZT SPECT MPI görüntü veri setini kullanarak DÖ yöntemi ile KAH tanısını gerçekleştirmeye çalışmışlardır. Çalışma sonucunda DÖ modelin tahmin doğruluğu $\%87.64$, duyarlılığı $\%81.58$ ve özgüllüğü $\%92.16$ olarak elde edilmiştir.

Liu vd. (2021) yapmış oldukları çalışmada sadece stres çekimine ait SPECT MPI görüntülerini kullanarak ResNet-34 mimarisi ile miyokardiyal perfüzyon

kusurlarının tespiti çalışılmıştır. Kantitatif perfüzyon kusur boyutu (DS; defect size) referans alınarak geliştirilen modelin performansı değerlendirilmiştir. DÖ yönteminin AUC değeri (0.872 ± 0.002), DS yönteminden elde edilen AUC değerine göre (0.838 ± 0.003) önemli ölçüde daha yüksek sonuç vermiştir. DÖ yöntemi, kantitatif DS yöntemine göre karşılaştırıldığında daha küçük standart sapma, yüksek tanısal doğruluk (DÖ Doğruluk: $\%82.7 \pm \%2.5$, DS Doğruluk: $\%78.5 \pm \%3.6$) ve özgülük (DÖ Özgülük: $\%84.9 \pm \%3.7$, DS Özgülük: $\%77.5 \pm \%6.5$), tutarlı AUC değerleri (AUC DÖ: 0.865 ± 0.010 , AUC DS: 0.838 ± 0.019) elde edilmiştir. Ancak DS yöntemine göre daha düşük duyarlılık (DÖ Duyarlılık: $\%74.4 \pm \%4.2$, DS Duyarlılık: $\%79.8 \pm \%5.8$) değerine sahiptir. Papandrianos vd. (2021) yapmış oldukları çalışmada stres ve dinlenme çekimi uygulanan hastalara ait SPECT MPI görüntüleri üzerinden ESA mimarileri ile sınıflandırma işlemi çalışılmıştır. VGG16, DenseNet, MobileNet ve InceptionV3 mimarileri kullanarak normal/anormal şeklinde ikili sınıflandırmayı sağlayan modellerin başarı performansları değerlendirilmiştir. Bunun sonucunda en iyi sınıflandırma doğruluğu $\%94$, duyarlılığı $\%78$, özgülüğü $\%94$ ve AUC değeri 0.93 olan ESA mimarisi gözlemlenmiştir.

Bu tez çalışmasında yukarıda bahsedilen DÖ modellerinin tasarımından farklı olarak eğitilen ve test edilen SPECT MPI veri setleri sadece ön işlemden geçirilerek transfer öğrenme modelleri ile sınıflandırılmıştır. Ayrıca segmentasyon, kantitatif perfüzyon kusur boyutu, kutupsal haritalar ve kısa eksen (SA), yatay uzun eksen (HLA), dikey uzun eksen (VLA) dilimleri gibi ayrı ayrı parametreler baz alınmadan ön işlemden geçirilen veri seti direkt olarak modellere verilmiştir. Birçok transfer öğrenme modelinin sınıflandırmadaki başarısının değerlendirilmesi de sağlanarak SPECT MPI görüntülerine en uygun olabilecek modeller belirlenebilmiştir. Bu çalışmada SA, HLA ve VLA dilimleri ile kutupsal haritalar (17 bölümlü ince segmentasyonu ve 3 bölümlü kaba segmentasyonu) ön işlemden kolaylıkla geçirildikten sonra transfer öğrenme mimarileri kullanılarak kesitsel ve lokal değerlendirmelerin hesaplanabileceği düşünülmektedir. Bu çalışmaya yakın olan Papandrianos (2021) vd. yapmış oldukları çalışmaya göre daha kararlı, doğru ve hızlı bir sistem oluşturulduğu kanısına varılabilir.

6. SONUÇLAR

Bu çalışmada görüntü analizleri ile yapay zeka bir arada kullanılarak SPECT görüntüleri ve koroner arter hastalığının teşhisi özelinde tıp ve mühendislik alanında uygulanabilirliğin olabileceği yeni bir yaklaşım geliştirilmeye çalışılmıştır. SPECT MPI görüntü veri setinden KAH teşhisini belirleyebilecek veriler derin öğrenme yöntemiyle analiz edilerek sınıflandırma işlemi yapılmıştır. Koroner arter hastalığında erken teşhis ve doğru tanıyı değerlendirmek için farklı derin öğrenme mimarilerinin verdiği analizlere dayanarak mimariler arasında karşılaştırma imkanı sunulmuştur. Çalışmada kullanılan SPECT MPI veri seti Akdeniz Üniversitesi Tıp Fakültesi Hastanesi Nükleer Tıp Anabilim Dalı'nda PACS sisteminde kayıtlı tutulan retrospektif hasta görüntülerinden elde edilmiştir. DICOM formatındaki görüntü veri seti bir Python kodu ile JPEG formatına dönüştürülerek ön işleme ve sınıflandırma tekniklerinin kullanımına hazır hale getirilmiştir. JPEG formatındaki görüntü serisinde kalbin fonksiyonel yapısı dışında bulunan gözle görülebilir kısımlar FIJI programı kullanılarak ön işleme tabii tutulmuştur. Elde edilen yeni görüntü veri seti anormal ve normal şeklinde sınıflandırma işlemini yapacak bir DÖ modeline aktarılmıştır. ESA mimarilerinden yola çıkılarak transfer öğrenme metodu sayesinde her bir hastaya ait stres ve istirahat görüntüleri ile SA, VLA ve HLA kesitlerinin bir arada bulunduğu görüntü serisi sınıflandırılmıştır.

Bu çalışmada önceden eğitilmiş çeşitli ESA mimarilerinden (DenseNet121, InceptionResNetV2, InceptionV3, MobileNet, MobileNetV2, ResNet50, VGG16, VGG19, Xception) faydalanılarak transfer öğrenme yöntemi ile doğruluk, kesinlik, duyarlılık, F1-skoru ve AUC analizleri yapılarak başarımları değerlendirilmiştir. Önerilen çalışmada ESA mimarilerinin test veri seti için performans metrikleri incelendiğinde en yüksek doğruluk (%100) InceptionResNetV2, DenseNet121, InceptionV3, Xception, MobileNetResNet50 modellerinde, geriye kalan modellerde test doğruluk değeri sırasıyla VGG16 (%98.3), VGG19 (%85) ve MobileNetV2 (%77.2) olarak hesaplanmıştır. Eğitim veri seti performans metriklerinde ise en yüksek doğruluk %98.2 ile InceptionV3 modeli, en yüksek kesinlik %98, duyarlılık %98, F1-skoru %98 ve AUC 0.977 ile Xception modeli vermiştir. Eğitim veri seti için en düşük performans metriğine sahip olan modeller incelendiğinde VGG19 mimarisinde doğruluk %73.3, kesinlik %78, MobileNetV2 mimarisinde ise duyarlılık %75, F1-skoru %72 ve AUC 0.70 olarak gözlenmiştir. Test veri seti performans metriklerinde ise en düşük doğruluk %77.2, kesinlik %83, duyarlılık %77, F1-skoru %74 ve AUC 0.728 ile MobileNetV2 mimarisinde hesaplanmıştır. ESA mimarilerinin transfer öğrenmedeki eğitim ve test süreleri incelendiğinde birbirine yakın değerdedir. Google Colaboratory arayüzünde transfer öğrenme metodu ile sınıflandırma işlemini sağlayarak KAH tanısının değerlendirilmesine yardımcı olan Tensorflow: 2.6.4, Keras: 2.6.0 kütüphanelerinin kullanılması ESA mimarilerinin eğitim ve test süresini hızlandırdığı düşünülmektedir. Python yazılımı ve bağlı kütüphaneleri günümüzde hızlı bir şekilde gelişim göstererek ilerlemesine dayanarak tasarlanan modelin SPECT MPI görüntü veri üzerinde seti transfer öğrenme tekniğini kullanarak sınıflandırılarak KAH tanısını başarıyla gerçekleştirdiği görülmüştür. Çeşitli ESA mimarileri ile transfer öğrenmeden elde edilen nicel sonuçlar yüksek başarı göstermiştir. Ayrıca çalışmada seçilen hiperparametre değerlerinden biri olan devir sayısının (100 epoch) literatürdeki çalışmalardan (400 epoch) daha makul bir değerde olması sebebiyle geliştirilen modele ait performans metrikleri kararlı, tutarlı ve güvenilir özelliğe sahiptir.

İleride araştırma yapılabilecek ve literatüre katkı sağlayabileceği düşünülen çalışmalarda SPECT MPI görüntü dizininde bulunan SA, VLA ve HLA düzlemleri görüntü üzerinde ayrı ayrı segmente edilerek transfer öğrenme ile sınıflandırma işlemi değerlendirilebilir. Böylece düzlem bazında KAH tanısı analizi sağlanabilir. Bunun yanı sıra görüntü dizinlerinde otomatik segmentasyon işlemi yapılarak her bir hastaya ait görüntü dizini otomatik olarak görüntü kümesine dönüştürülüp stres ve dinlenme olarak ayrı ayrı transfer öğrenme yöntemi ile sınıflandırılarak KAH teşhisine katkısı değerlendirilebilir. SPECT görüntülerine göre daha yüksek kantitatif özelliğe sahip PET görüntüleri de önerilen model üzerinde çalıştırılarak nükleer görüntüleme yöntemleri arasında karşılaştırma imkanı sunabilir. KAH tanısını koymada farklı bir teknik olan SPECT MPI görüntüsünden elde edilen kutup haritalarından veri seti oluşturularak 3 segmentli ya da 17 segmentli kısma ayrılan bölümler sayesinde konum odaklı nicel inceleme yapılabilir. Kardiyak hastalıkların erken tanı ve tedavisinde kalp ve kalp damarların hem anatomik hem de fonksiyonel görüntüleme tekniklerinin verdiği farklı özellikteki kantitatif bilgilerin analizi geliştirilen transfer öğrenme modeli ile doğru bilgi artırımı sağlanarak yeni çalışmalara yer verilebilir. Akdeniz Üniversitesi Nükleer Anabilim Dalı'ndan retrospektif olarak elde edilen veri sayısı artırılarak modelin performansını değerlendirmedeki başarı oranı daha da iyileştirilebilir. Böylece doğru ve hızlı tanı sistemi olarak kullanılacak TÖ modeli tasarlanabilir.

7. KAYNAKLAR

- Adil, M. A. (2021). "Facial Emotion Detection Using Convolutional Neural Networks."
- Alkan, O. and A. Keleş (2019). Parkinson Hastalığının Teşhisinde Derin Öğrenme Yöntemi İle Spect Görüntü Analizi. Ulusal Tez Merkezi, Ağrı İbrahim Çeçen Üniversitesi.
- Alom, M. Z., et al. (2019). "A state-of-the-art survey on deep learning theory and architectures." Electronics **8**(3): 292.
- Aloysius, N. and M. Geetha (2017). A review on deep convolutional neural networks. 2017 international conference on communication and signal processing (ICCSP), IEEE.
- Altuntaş, Y., et al. (2019). "Identification of haploid and diploid maize seeds using convolutional neural networks and a transfer learning approach." Computers and Electronics in Agriculture **163**: 104874.
- Amiel, M., et al. (2012). Coronary artery diseases: diagnostic and therapeutic imaging approaches, Springer Science & Business Media.
- Anonim 1: (2022). "SPECT MPI." Retrieved [Son Erişim Tarihi: 31.12.2022], from <https://www.kaggle.com/datasets/selcankaplan/spect-mpi>.
- Anonim 2: (2022). "Heart Chambers and Circulation through the Heart." Retrieved [Son erişim tarihi: 31.12.2022], from <https://courses.lumenlearning.com/suny-contemporaryhealthissues/chapter/chambers-and-circulation-through-the-heart/>.
- Anonim 3: (2022). "Heart PET Scans: Who Needs Them and Why?". Retrieved [Son erişim tarihi: 31.12.2022], from <https://www.cardio.com/blog/heart-pet-scans-who-needs-them-and-why>.
- Anonim 4: (2022). "SPECT." Retrieved [Son erişim tarihi: 31.12.2022], from <https://www.siemens-healthineers.com/tr/molecular-imaging/spect-and-spect-ct>
- Anonim 5: (2022). "What is SPECT imaging and how does it work?". Retrieved [Son erişim tarihi: 31.12.2022], from <https://www.digirad.com/what-is-spect-imaging-and-how-does-it-work/>.
- Arasaratnam, P. and T. D. Ruddy (2015). Noninvasive imaging for the assessment of coronary artery disease. Coronary Artery Disease-Assessment, Surgery, Prevention, IntechOpen.
- Arsanjani, R., et al. (2013). "Improved accuracy of myocardial perfusion SPECT for the detection of coronary artery disease using a support vector machine algorithm." Journal of Nuclear Medicine **54**(4): 549-555.
- Arsanjani, R., et al. (2013). "Improved accuracy of myocardial perfusion SPECT for detection of coronary artery disease by machine learning in a large population." Journal of Nuclear Cardiology **20**(4): 553-562.
- Badano, L. P., et al. (2020). "Artificial intelligence and cardiovascular imaging: A win-win combination." Anatolian journal of cardiology **24**(4): 214.
- Bailey, D. L. and J. Humm (2014). Nuclear medicine physics: a handbook for teachers and students, Iaea.

- Berkaya, S. K., et al. (2020). "Classification models for SPECT myocardial perfusion imaging." Computers in Biology and Medicine **123**: 103893.
- Betancur, J., et al. (2018). "Deep learning for prediction of obstructive disease from fast myocardial perfusion SPECT: a multicenter study." JACC: Cardiovascular Imaging **11**(11): 1654-1663.
- Betancur, J., et al. (2018). "Prognostic value of combined clinical and myocardial perfusion imaging data using machine learning." JACC: Cardiovascular Imaging **11**(7): 1000-1009.
- Boshchenko, A., et al. (2011). Transthoracic echocardiography in the assessment of coronary arteries. Coronary angiography: Advances in noninvasive imaging approach for evaluation of coronary artery disease, InTech.
- Cavedon, C. and S. Rudin (2015). Cardiovascular and neurovascular imaging: physics and technology, CRC Press.
- Chen, J.-J., et al. (2021). "Convolutional neural network in the evaluation of myocardial ischemia from czt spect myocardial perfusion imaging: Comparison to automated quantification." Applied Sciences **11**(2): 514.
- Cullom, S. J., et al. (1998). "Electrocardiographically gated myocardial perfusion SPECT: technical principles and quality control considerations." Journal of Nuclear Cardiology **5**(4): 418-425.
- Deng, J., et al. (2009). Imagenet: A large-scale hierarchical image database. 2009 IEEE conference on computer vision and pattern recognition, Ieee.
- Dietterich, T. G. (2000). Ensemble methods in machine learning. International workshop on multiple classifier systems, Springer.
- Dorbala, S., et al. (2018). "Single photon emission computed tomography (SPECT) myocardial perfusion imaging guidelines: instrumentation, acquisition, processing, and interpretation." Journal of Nuclear Cardiology **25**(5): 1784-1846.
- Dziuk, M. and G. Kamiński (2012). "Radioisotope studies in cardiology." Nuclear Medicine review. Central & Eastern Europe **15**(1): 2-2.
- El Rafaie, S., et al. (2012). On the use of SPECT imaging datasets for automated classification of ventricular heart disease. 2012 8th International Conference on Informatics and Systems (INFOS), IEEE.
- Fukushima, K. (1988). "Neocognitron: A hierarchical neural network capable of visual pattern recognition." Neural networks **1**(2): 119-130.
- Garner, S. R. (1995). Weka: The waikato environment for knowledge analysis. Proceedings of the New Zealand computer science research students conference.
- Gomar, S., et al. (2016). Precise digital implementations of hyperbolic tanh and sigmoid function. 2016 50th Asilomar Conference on Signals, Systems and Computers, IEEE.
- Gonzalez, F. A. and E. Romero (2009). "Biomedical image analysis and machine learning technologies: Applications and techniques: Applications and techniques."

- Hamdan, A., et al. (2011). "A prospective study for comparison of MR and CT imaging for detection of coronary artery stenosis." JACC: Cardiovascular Imaging **4**(1): 50-61.
- He, K., et al. (2016). Deep residual learning for image recognition. Proceedings of the IEEE conference on computer vision and pattern recognition.
- Kang, X., et al. (2019). "A deep similarity metric method based on incomplete data for traffic anomaly detection in IoT." Applied Sciences **9**(1): 135.
- Katz, A. M. (2010). Physiology of the Heart, Lippincott Williams & Wilkins.
- Khan, S., et al. (2018). "A guide to convolutional neural networks for computer vision." Synthesis lectures on computer vision **8**(1): 1-207.
- Knott, K. D., et al. (2020). "The prognostic significance of quantitative myocardial perfusion: an artificial intelligence-based approach using perfusion mapping." Circulation **141**(16): 1282-1291.
- Langley, P. and J. G. Carbonell (1984). "Approaches to machine learning." Journal of the American Society for Information Science **35**(5): 306-316.
- LeCun, Y., et al. (1998). "Gradient-based learning applied to document recognition." Proceedings of the IEEE **86**(11): 2278-2324.
- Liu, H., et al. (2021). "Diagnostic accuracy of stress-only myocardial perfusion SPECT improved by deep learning." European journal of nuclear medicine and molecular imaging **48**(9): 2793-2800.
- Ma, L., et al. (2019). "Thyroid diagnosis from SPECT images using convolutional neural network with optimization." Computational intelligence and neuroscience **2019**.
- Maddahi, J. and R. R. S. Packard (2013). "Flurpiridaz F-18 May Expand PET for Myocardial Perfusion Imaging." from <https://www.dicardiology.com/article/flurpiridaz-f-18-may-expand-pet-myocardial-perfusion-imaging>.
- Maeda-Gutiérrez, V., et al. (2020). "Comparison of convolutional neural network architectures for classification of tomato plant diseases." Applied Sciences **10**(4): 1245.
- Mele, B. and G. Altarelli (1993). "Lepton spectra as a measure of b quark polarization at LEP." Physics Letters B **299**(3-4): 345-350.
- Merhige, M. E., et al. (2007). "Impact of myocardial perfusion imaging with PET and ⁸²Rb on downstream invasive procedure utilization, costs, and outcomes in coronary disease management." Journal of Nuclear Medicine **48**(7): 1069-1076.
- Moghaddasi, H. and S. Nourian (2016). "Automatic assessment of mitral regurgitation severity based on extensive textural features on 2D echocardiography videos." Computers in Biology and Medicine **73**: 47-55.
- Mohammed, M., et al. (2016). Machine learning: algorithms and applications, Crc Press.

- Nair, V. and G. E. Hinton (2010). Rectified linear units improve restricted boltzmann machines. Icml.
- Nakajima, K., et al. (2017). "Diagnostic accuracy of an artificial neural network compared with statistical quantitation of myocardial perfusion images: a Japanese multicenter study." European journal of nuclear medicine and molecular imaging **44**(13): 2280-2289.
- Notghi, A. and C. S. Low (2011). "Myocardial perfusion scintigraphy: past, present and future." The British journal of radiology **84**(special_issue_3): S229-S236.
- Nwankpa, C., et al. (2018). "Activation functions: Comparison of trends in practice and research for deep learning." arXiv preprint arXiv:1811.03378.
- Pahuja, G., et al. (2020). "Early detection of Parkinson's disease by using SPECT imaging and biomarkers." Journal of Intelligent Systems **29**(1): 1329-1344.
- Papandrianos, N. and E. Papageorgiou (2021). "Automatic Diagnosis of Coronary Artery Disease in SPECT Myocardial Perfusion Imaging Employing Deep Learning." Applied Sciences **11**(14): 6362.
- Pearlman, J. D. (2022). "Coronary Artery Disease Imaging." from <https://emedicine.medscape.com/article/349040-overview>.
- Phung, V. H. and E. J. Rhee (2019). "A high-accuracy model average ensemble of convolutional neural networks for classification of cloud image patches on small datasets." Applied Sciences **9**(21): 4500.
- Ramon, A. J., et al. (2020). "Improving diagnostic accuracy in low-dose SPECT myocardial perfusion imaging with convolutional denoising networks." IEEE transactions on medical imaging **39**(9): 2893-2903.
- Rasamoelina, A. D., et al. (2020). A review of activation function for artificial neural network. 2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI), IEEE.
- Razzak, M. I., et al. (2018). "Deep learning for medical image processing: Overview, challenges and the future." Classification in BioApps: 323-350.
- Rosdeepy (2020). "What Is Artificial Neural Networks?". from <https://www.pyimagedata.com/what-is-artificial-neural-networks/>.
- Rosenthal, M., et al. (1995). "Quantitative SPECT imaging: a review and recommendations by the Focus Committee of the Society of Nuclear Medicine Computer and Instrumentation Council." Journal of Nuclear Medicine **36**(8): 1489-1513.
- Russakovsky, O., et al. (2015). "Imagenet large scale visual recognition challenge." International journal of computer vision **115**(3): 211-252.
- Scherer, D., et al. (2010). Evaluation of pooling operations in convolutional architectures for object recognition. International conference on artificial neural networks, Springer.
- Shah, S., et al. (2009). The heart: Anatomy, physiology and exercise physiology. Integrating cardiology for nuclear medicine physicians, Springer: 3-22.

- Shin, H.-C., et al. (2016). "Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning." IEEE transactions on medical imaging **35**(5): 1285-1298.
- Shinozuka, M. and B. Mansouri (2009). Synthetic aperture radar and remote sensing technologies for structural health monitoring of civil infrastructure systems. Structural health monitoring of civil infrastructure systems, Elsevier: 113-151.
- Si, L., et al. (2020). "A deep convolutional neural network model for intelligent discrimination between coal and rocks in coal mining face." mathematical Problems in Engineering **2020**.
- Simonyan, K. and A. Zisserman (2014). "Very deep convolutional networks for large-scale image recognition." arXiv preprint arXiv:1409.1556.
- Slart, R. H., et al. (2021). "Position paper of the EACVI and EANM on artificial intelligence applications in multimodality cardiovascular imaging using SPECT/CT, PET/CT, and cardiac CT." European journal of nuclear medicine and molecular imaging **48**(5): 1399-1413.
- Slomka, P., et al. (2016). "Novel SPECT technologies and approaches in cardiac imaging." Cardiovascular innovations and applications **2**(1): 31-46.
- Soo, G., et al. (2019). "SPECT-CT Scan." from <https://www.insideradiology.com.au/spect-ct-scan/>.
- Spier, N., et al. (2019). "Classification of polar maps from cardiac perfusion imaging with graph-convolutional neural networks." Scientific reports **9**(1): 1-8.
- Szegedy, C., et al. (2015). Going deeper with convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition.
- Tan, Y. (2016). GPU-based parallel implementation of swarm intelligence algorithms, Morgan Kaufmann.
- Trägårdh, E., et al. (2018). "Myocardial perfusion SPECT and SPECT/CT in interventional cardiology." Continuing Cardiology Education **4**(1): 45-50.
- Trung, N. T., et al. (2020). "A Deep learning Method for Diagnosing Coronary Artery Disease using SPECT Images of Heart." Journal of Science & Technology **144**: 022-027.
- Valotassiou, V., et al. (2011). "The clinical use of SPECT and PET molecular imaging in Alzheimer's disease." The Clinical Spectrum of Alzheimer's Disease—The Charge Toward Comprehensive Diagnostic and Therapeutic Strategies.
- van der Veldt, A. A., et al. (2013). "Positron emission tomography as a method for measuring drug delivery to tumors in vivo: the example of [11C] docetaxel." Frontiers in oncology **3**: 208.
- Wang, T., et al. (2020). "A learning-based automatic segmentation and quantification method on left ventricle in gated myocardial perfusion SPECT imaging: A feasibility study." J Nucl Cardiol **27**(3): 976-987.
- WHO (2021). "Cardiovascular diseases (CVDs)." from [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)).

- Wolterink, J. M., et al. (2016). "Automatic coronary artery calcium scoring in cardiac CT angiography using paired convolutional neural networks." Medical image analysis **34**: 123-136.
- Xu, B., et al. (2020). "Applications of artificial intelligence in multimodality cardiovascular imaging: A state-of-the-art review." Prog Cardiovasc Dis **63**(3): 367-376.
- Yamashita, R., et al. (2018). "Convolutional neural networks: an overview and application in radiology." Insights into imaging **9**(4): 611-629.
- Yoneyama, H., et al. (2019). "Ability of artificial intelligence to diagnose coronary artery stenosis using hybrid images of coronary computed tomography angiography and myocardial perfusion SPECT." Eur J Hybrid Imaging **3**(1): 4.
- Zhou, L. Q., et al. (2019). "Artificial intelligence in medical imaging of the liver." World J Gastroenterol **25**(6): 672-682.

ÖZGEÇMİŞ

BEDİA ŞAYIK

bedia.sayik.94@gmail.com



ÖĞRENİM BİLGİLERİ

| | |
|----------------------------|---|
| Yüksek Lisans 2019-2023 | Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı, Antalya |
| Lisans 2013-2018 | Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Kayseri |

MESLEKİ VE İDARİ GÖREVLER

| | |
|---|--|
| İş Güvenliği Uzmanı (C Sınıfı) 2021-Devam ediyor | Refleks Ortak Sağlık ve Güvenlik Birimi DNA Ortak Sağlık ve Güvenlik Birimi |
| Stajyer 06/2016-07/2016 | Novamed Gmbh, Antalya |
| Stajyer 06/2015-07/2015 | Antalya Eğitim ve Araştırma Hastanesi, Antalya |