

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

**EJEKSİYON FRAKSİYONU DÜŞÜK VE KORUNMUŞ KALP
YETERSİZLİĞİ VAKALARI İÇİN TEK SİNYAL KULLANARAK
MAKİNE ÖĞRENMESİ TABANLI YENİ BİR TANI ALGORİTMASI**

DOKTORA TEZİ

Pınar ÖZEN

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektronik Mühendisliği Bilim Dalı

KASIM 2022

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

**EJEKSİYON FRAKSİYONU DÜŞÜK VE KORUNMUŞ KALP
YETERSİZLİĞİ VAKALARI İÇİN TEK SİNYAL KULLANARAK
MAKİNE ÖĞRENMESİ TABANLI YENİ BİR TANI ALGORİTMASI**

DOKTORA TEZİ

Pınar ÖZEN

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektronik Mühendisliği Bilim Dalı

Tez Danışmanı: Prof. Dr. Mehmet Recep BOZKURT

KASIM 2022

Pınar ÖZEN tarafından hazırlanan “EJEKSİYON FRAKSİYONU DÜŞÜK VE KORUNMUŞ KALP YETERSİZLİĞİ VAKALARI İÇİN TEK SİNYAL KULLANARAK MAKİNE ÖĞRENMESİ TABANLI YENİ BİR TANI ALGORİTMASI” adlı tez çalışması 30.11.2022 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı **Elektronik Mühendisliği** Bilim Dalı’nda Doktora tezi olarak kabul edilmiştir.





ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “EJEKSİYON FRAKSİYONU DÜŞÜK VE KORUNMUŞ KALP YETERSİZLİĞİ VAKALARI İÇİN TEK SİNYAL KULLANARAK MAKİNE ÖĞRENMESİ TABANLI YENİ BİR TANI ALGORİTMASI” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, etik kurul onay belgesi aldığımı, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim. (30 / 11 / 2022).

Pınar ÖZEN





Aileme...



TEŞEKKÜR

Tez çalışmamın hazırlanmasında, gerekli ortamı sağlayan ve çalışmanın her safhasında desteğini esirgemeyen danışman hocam Prof. Dr. Mehmet Recep BOZKURT'a, önerileriyle tezin yönlendirilmesinde yardımcı olan Tez İzleme Komitesi Üyelerine, tıbbi konulardaki ve veri toplama aşamasındaki yardımlarından dolayı Doç. Dr. Cahit BİLGİN'e, ve yine veri toplama aşamasındaki yardımlarından dolayı Sakarya Üniversitesi Eğitim ve Araştırma Hastanesi kardiyoloji poliklinik ve yatan hasta servisi çalışanlarına en içten teşekkürlerimi sunarım.

Ayrıca, yalnız bu çalışmada değil, her zaman her türlü destekleriyle yanımda olan ve manevi katkılarını esirgemeyen aileme, eşime ve kızıma sabır ve desteklerinden dolayı minnet ve şükranlarımı sunarım.

Pınar ÖZEN

İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vii
KISALTMALAR	ix
SİMGELER	xiii
TABLO LİSTESİ	xv
ŞEKİL LİSTESİ	xvi
ÖZET	xviii
SUMMARY	xx
1. GİRİŞ	1
2. EJEKSİYON FRAKSİYONU DÜŞÜK VE KORUNMUŞ KALP YETERSİZLİĞİ	7
2.1. Giriş	7
2.2. Kalp Yetersizliği Belirtileri	8
2.3. Tanı	9
2.4. Tedavi	10
3. ELEKTROKARDİYOGRAM VE FOTOPLETİSMOGRAFİ SİNYALLERİ	13
3.1. Elektrokardiyogram	13
3.1.2. Kalpteki elektrik sinyali	14
3.1.3. EKG temelleri: dalgalar, aralıklar ve segmentler	15
3.1.4. EKG ile teşhis edilebilen tıbbi sorunlar	18
3.1.5. EKG için dijital filtreleme	19
3.2. Fotopletismografi Sinyali ve Ondan Türetilen Kalp Hızı Değişkenliği	21
3.2.1. Fotopletismografi sinyali	22
3.2.2. Kalp hızı değişkenliği	24
3.2.3. PPG için dijital filtreleme	25
3.2.4. Kalp hızı değişkenliğinin PPG'den türetilmesi	27
4. KULLANILAN VERİ SETİ, ÖZELLİK ÇIKARMA VE ÖZELLİK SEÇME	31
4.1. Kullanılan Veri Seti	31
4.1.1. Gönüllülerden veri toplanması	31
4.1.2. EKG ile yapılan çalışmanın veri seti	31
4.1.3. PPG ve KHD ile yapılan çalışmanın veri seti	32
4.1.4. KHD ile yapılan çalışmanın veri seti	32
4.2. Özellik Çıkarma ve Özellik Seçme	32
4.2.1. Özellik Çıkarma	32
4.2.2. Özellik Seçme	36
5. SINIFLANDIRMADA KULLANILAN ALGORİTMALAR	45
5.1. Giriş	45
5.2. k - En Yakın Komşu (k-NN) Algoritması	45

5.3. Destek Vektör Makinaları	48
5.4. Karar Ağaçları	49
5.5. Torbalı Ağaçlar Topluluk Sınıflandırıcı	50
5.6. Performans Kriterleri	52
5.6.1. k - kat çapraz doğrulama	52
5.6.2. Doğruluk, duyarlılık, özgüllük, F-ölçümü, Kappa değeri	53
6. SONUÇLAR VE ÖNERİLER.....	55
6.1. Sonuçlar.....	55
6.1.1. EKG ile yapılan çalışma sonuçları	55
6.1.2. KHD ile yapılan çalışma sonuçları.....	61
6.1.3. PPG ve KHD ile yapılan çalışma sonuçları	62
6.2. Öneriler.....	65
KAYNAKLAR.....	68
ÖZGEÇMİŞ	79



KISALTMALAR

ABD	: Amerika Birleşik Devletleri
AC	: Alternatif Akım
AF	: Atriyal Fibrilasyon
ANOVA	: Varyans Analizi (Analysis of Variance)
AR	: Otoregresif
ASM	: Öznitelik Seçim Ölçüsü (Attribute Selection Measure)
AUC	: ROC Eğrisi Altındaki Alan (Area Under Curve)
AV	: Atriyovenriküler
BNP	: B-tipi Natriüretik Peptid
COPD	: Kronik Obstruktif Akciğer Hastalığı (Cronic Obstructive Pulmonary Disease)
DC	: Doğru Akım
DEF-KY	: Düşük Ejeksiyon Fraksiyonlu Kalp Yetersizliği
DI	: Derivasyon I
DII	: Derivasyon II
DIII	: Derivasyon III
DVM	: Destek Vektör Makineleri
ECG	: Elektrokardiyogram (Electrocardiogram)
EF	: Ejeksiyon Fraksiyonu
EKG	: Elektrokardiyogram
FD	: Fotodiyot
FDATool	: Filtre Tasarım ve Analiz Aracı (Filter Design and Analysis Tool)
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
GI	: Gini İndeksi
HF	: Kalp Yetersizliği (Heart Failure)
HFpEF	: Korunmuş Ejeksiyon Fraksiyonlu Kalp Yetersizliği (Heart Failure with preserved Ejection Fraction)
HFrEF	: Düşük Ejeksiyon Fraksiyonlu Kalp Yetersizliği (Heart Failure with reduced Ejection Fraction)
HRV	: Kalp Hızı Değişkenliği (Heart Rate Variability)

IG	: Bilgi Kazancı (Information Gain)
KA	: Karar Ağaçları
KAH	: Koroner Arter Hastalığı
KEF-KY	: Korunmuş Ejeksiyon Fraksiyonlu Kalp Yetersizliği
KHD	: Kalp Hızı Değişkenliği
KKY	: Konjestif Kalp Yetersizliği
k-NN	: k- En Yakın Komşu
KVH	: Kardiyovasküler Hastalık
KY	: Kalp Yetersizliği
LA	: Sol Atriyum
LED	: Işık Yayan Diyot (Light-Emitting Diode)
LVEF	: Sol Ventrikül EjeksiyonFraksiyonu (Left Ventricular Ejection Fraction)
ML	: Makine Öğrenmesi (Machine Learning)
MÖ	: Makine Öğrenmesi
MUGA	: Radyonüklid Ventrikülografi (Multiple – Gated Acquisition)
NT-proBNP	: N-terminal proBNP
NYHA	: New York Kalp Derneği (New York Heart Association)
Ort	: Ortalama
ÖS	: Özellik Sayısı
PPG	: Fotopletismografi (Photoplethysmography)
RA	: Sağ Atriyum
ROC	: Alıcı İşletim Karakteristiği (Receiver Operating Characteristic)
SA	: Sinoatriyal
SPECT	: Tek Foton Emisyonlu Bilgisayarlı Tomografi (Single Photon Emission Computerized Tomography)
SS	: Standart Sapma
STa	: Atriyal ST Segmenti
SV	: Sol Ventrikül
SVEF	: Sol Ventrikül Ejeksiyon Fraksiyonu
SVM	: Destek Vektör Makinaları (Support Vector Machines)
Ta	: Atriyal T Dalgası
TN	: Gerçek Negatif (True Negative)
TP	: Gerçek Pozitif (True Positive)
Ü.S.	: Üçlü Sınıflandırma
V.K.İ.	: Vücut Kitle İndeksi

YZ : Yapay Zeka





SİMGELER

x_{rms}	: Karekök Ortalama
$\bar{x}$	: Dağılımın ortalaması
n	: Örneğin gözlem sayısı
S_1	: Sinyalin birinci türevinin standart sapması
S_2	: Sinyalin ikinci türevinin standart sapması
$a_p(i)$	: Yule-Walker metodu p. dereceden modelin i. AR parametresi
ϵ_p	: Yule-Walker p. derece modelin beyaz gürültüye tahmini varyansı
$rc(i)$	: Yule-Walker metodu p. dereceden modelin i. yansıma katsayısı
$a_{p,i}$	: Burg metodu p. dereceden modelin i. AR parametresi
e_p	: Burg metodu p. derece modelin beyaz gürültüye tahmini varyansı
rc_i	: Burg metodu p. dereceden modelin i. Yansıma katsayısı
c	: Doğru tahmin edilen elemanların toplam sayısı
s	: Toplam eleman sayısı
p_i	: i. sınıf için tahmin edilen değerler (sütun toplamı)
t_i	: i. sınıf için gerçek değerler (satır toplamı)



TABLO LİSTESİ

Sayfa

Tablo 4.1. Demografik Bilgiler.	33
Tablo 4.2. KHD ile yapılan çalışmadaki gönüllülere ait demografik bilgiler.	34
Tablo 4.3. Çalışmada verilerden çıkarılan zaman domenindeki özellikler.	35
Tablo 4.4. Özellik olarak kullanılan Yule-Walker ve Burg metodu parametreleri. ..	37
Tablo 4.5. Kruskal Wallis testi sonucu EKG özelliklerine ait p değerleri.	38
Tablo 4.6. DEF-KY ve Sağlıklı sınıfları için ikili Mann Whitney U test sonuçları. ..	39
Tablo 4.7. DEF-KY ve KEF-KY sınıfları için ikili Mann Whitney U test sonuçları.	39
Tablo 4.8. KEF-KY ve Sağlıklı sınıfları için ikili Mann Whitney U test sonuçları. ..	40
Tablo 4.9. PPG ve KHD özelliklerinin DEF-KY ve KEF-KY ikili sınıflandırma çalışması için Mann Whitney U test sonuçları.	41
Tablo 4.10. (Devamı) PPG ve KHD özelliklerinin DEF-KY ve KEF-KY ikili sınıflandırma çalışması için Mann Whitney U test sonuçları.	42
Tablo 4.11. (Devamı) PPG ve KHD özelliklerinin DEF-KY ve KEF-KY ikili sınıflandırma çalışması için Mann Whitney U test sonuçları.	43
Tablo 4.12. Kruskal Wallis test sonucu PPG ve KHD özelliklerine ait p değerleri. ..	44
Tablo 4.13. PPG ve KHD özellikleri ile DEF-KY ve Sağlıklı ikili sınıfı için Mann Whitney U testi sonucunda elde edilen p değerleri.	44
Tablo 4.14. (Devamı) PPG ve KHD özellikleri ile DEF-KY ve Sağlıklı ikili sınıfı için Mann Whitney U testi sonucunda elde edilen p değerleri.	45
Tablo 4.15. PPG ve KHD özellikleri ile KEF-KY ve Sağlıklı ikili sınıfı için Mann Whitney U testi sonucunda elde edilen p değerleri.	45
Tablo 4.16. PPG ve KHD özellikleri ile DEF-KY ve KEF-KY ikili sınıfı için Mann Whitney U testi sonucunda elde edilen p değerleri.	46
Tablo 6.1. EKG ile yapılan çalışmanın performans parametreleri.	58
Tablo 6.2. EKG ile yapılan çalışma için sınıflandırıcı sonuçları.	59
Tablo 6.3. (Devamı) EKG ile yapılan çalışma için sınıflandırıcı sonuçları.	60
Tablo 6.4. KHD ile yapılan çalışma için sınıflandırma performans parametreleri. ..	63
Tablo 6.5. PPG ve KHD ile yapılan çalışma için sınıflandırma performans parametreleri.	65
Tablo 6.6. PPG ve KHD ile yapılan çalışmanın sınıflandırıcı sonuçları.	65
Tablo 6.7. PPG ve KHD özellikleri ile KY ve Sağlıklı ikili sınıflandırması için Mann Whitney U testi sonuçları.	66
Tablo 6.8. PPG ve KHD özellikleri ile ikili sınıflandırma sonuçları.	67



ŞEKİL LİSTESİ

Sayfa

Şekil 3.1. Einthoven üçgeni.	13
Şekil 3.2. Kalbin elektriksel bağlantıları (Goldberger ve Goldberger, 2018).....	14
Şekil 3.3. Depolarizasyon ve repolarizasyon (a) Dinlenme halindeki kalp kası hücresi polarizedir; yani, hücrenin dışı pozitif yüklü ve içi negatif yüklüdür. (b) Hücre uyarıldığında (S, stimüle) depolarize olmaya başlar (noktalı alan). (c) Tamamen depolarize olan hücrenin içi pozitif, dışı negatif yüklüdür. (d) Uyarılan hücre dinlenme durumuna döndüğünde repolarizasyon meydana gelir. Depolarizasyon ve repolarizasyon yönleri oklarla gösterilmiştir (Goldberger ve Goldberger, 2018).....	16
Şekil 3.4. EKG grafiğinin temel bileşenleri.	17
Şekil 3.5. EKG ile yapılan çalışmaya ait iş akış diyagramı.	20
Şekil 3.6. Filtrelenmeden önce ve filtrelendikten sonra EKG sinyali.	21
Şekil 3.7. Moving Average Filtre Etkisi (Uçar, 2017).....	21
Şekil 3.8. EKG'ye ait periodogram grafiği.	22
Şekil 3.9. Doku tarafından ışık Emilimi (Tamura ve ark., 2014).	24
Şekil 3.10. PPG ölçümü için modlar (Tamura ve ark., 2014).....	24
Şekil 3.11. Biopac MP36 cihazı.....	25
Şekil 3.12. PPG'ye ait periodogram grafiği.	25
Şekil 3.13. EKG ve PPG'den türetilen KHD.....	26
Şekil 3.14. PPG ve KHD ile yapılan çalışmanın iş akış diyagramı.	27
Şekil 3.15. Filtrelenmeden önce ve filtrelendikten sonra PPG sinyali.	28
Şekil 3.16. PPG ve PPG'den Türetilen KHD örneği.	29
Şekil 3.17. DEF-KY, KEF-KY ve Sağlıklı KHD Dizileri.	30
Şekil 3.18. KHD ile yapılan ikili sınıflandırma çalışmasına ait iş akış diyagramı.....	31
Şekil 3.19. DEF-KY ve KEF-KY ikili sınıflandırması için PPG'ye ait periodogram grafiği.	32
Şekil 5.1. (a) Basit bir k-NN, (b) Yeni etiketlenmemiş verinin k değerlerine göre komşuluk mesafeleri.	49
Şekil 5.2. DVM örneği (a) doğrusal, (b) doğrusal olmayan ayrılma.	50
Şekil 5.3. Karar Ağaçları Sınıflandırıcı.	51
Şekil 5.4. Topluluk Sınıflandırıcı.....	53
Şekil 5.5. 10 - kat çapraz doğrulama.	54
Şekil 5.6. Karışıklık matrisi.	55
Şekil 6.1. Özellik seçimi olmadan (ÖS=37), Kruskal Wallis testi sonrası (ÖS=19) ve Mann Whitney U testi sonrası sınıflandırıcı ROC eğrileri.....	61
Şekil 6.2. KHD ile yapılan çalışma için sınıflandırıcılara ait ROC eğrileri.	64



EJEKSİYON FRAKSİYONU DÜŞÜK VE KORUNMUŞ KALP YETERSİZLİĞİ VAKALARI İÇİN TEK SİNYAL KULLANARAK MAKİNE ÖĞRENMESİ TABANLI YENİ BİR TANI ALGORİTMASI

ÖZET

Kalp yetersizliği (KY) ile ilgili olarak, mortaliteyi azaltmak ve ömrü uzatmak tedavinin ana hedeflerinden biridir. Birçok klinik çalışma KY hastalarını Sol Ventriküler Ejeksiyon Fraksiyonuna (SVEF) göre tanımlar. SVEF'ye göre KY alt tiplerinden en sık görülen ikisi, düşük ejeksiyon fraksiyonlu KY (DEF-KY, $SVEF \leq \%40$) ve korunmuş ejeksiyon fraksiyonlu KY (KEF-KY, $SVEF \geq \%50$)'dir.

DEF-KY tanısı daha kolaydır. Ancak KEF-KY tanısı uzmanlar için bile daha karmaşık ve zordur. SVEF normal görüldüğünden (sağlıklı bireylerde de $SVEF \geq \%50$), bazı benzer semptomlar nedeniyle KEF-KY vakaları göğüs hastalıkları ile karıştırılabilir. SVEF'yi ölçmek için genellikle ekokardiyografi kullanılır. Bu, uzman gerektiren pahalı bir cihazdır ve cihaza ulaşmanın kısıtlı olduğu durumlar olabilir. Tedaviye ekokardiyografi yapılmadan başlanması gereken acil durumlar da olabilir. Bu tür durumların çözümü için ekonomik, pratik karar destek sistemlerine ihtiyaç duyulmaktadır.

Bu tez çalışmasında, DEF-KY, sağlıklı ve KEF-KY sınıflarının olduğu üçlü sınıflandırma yapan, yalnızca 3 kablolu elektrokardiyogram (EKG) özelliklerini kullanan bir tanı algoritması ve yalnızca fotopletismografi (PPG) ve PPG'den türetilen kalp hızı değişkenliği (KHD) özelliklerini kullanan bir algoritma olmak üzere iki farklı algoritma geliştirilmiştir. Ayrıca DEF-KY ve KEF-KY ikili sınıflandırması için de sadece KHD özelliklerini kullanan başka bir algoritma da geliştirilmiştir.

25 yaş ve üzeri 61 gönüllüden 10 saniye boyunca elektrokardiyogram (EKG) ve fotopletismografi (PPG) verileri eş zamanlı olarak alınmıştır. Hem EKG hem de PPG sinyallerini temizlemek için dijital filtreler kullanılmıştır. Temizlenmiş PPG'lerden KHD'ler türetilmiştir.

EKG ile yapılan üçlü sınıflandırma çalışması için dört farklı makine öğrenmesi (MÖ) algoritması kullanılmıştır. Veri setinin rasgele %80'i eğitim ve %20'si test veri seti olarak ayarlanmıştır. Bu sınıflandırmalar sonucunda elde edilen en yüksek doğruluk oranı, k-en yakın komşu (k-NN) algoritması için %100'dür. Yalnızca KHD özellikleri kullanılarak yapılan DEF-KY ve KEF-KY ikili sınıflandırması için üç farklı MÖ algoritması kullanılmıştır. Bu sınıflandırmalar sonucunda elde edilen en yüksek doğruluk oranı, Destek Vektör Makinaları (DVM) için %98.33'dir. PPG ve PPG'den türetilen KHD kullanılarak yapılan üçlü sınıflandırma için üç farklı MÖ algoritması kullanılmıştır. Yine 10 kat çapraz doğrulama ile değerlendirme yapılmıştır. Sınıflandırmalar sonucu elde edilen en yüksek doğruluk oranı, topluluk sınıflandırıcı için %87.78'dir.

Bu çalışmada elde edilen sonuçlara dayanarak, sadece 3 kablolu EKG ya da sadece PPG özelliklerinin DEF-KY ve KEF-KY tanısında kullanılabileceği ve önemli sonuçlar sağlayacağı belirlenmiştir. Bu çalışma ile, tek bir sinyalle DEF-KY ve KEF-

KY teşhis etme olasılığının yolu açılmıştır. Konuyla ilgili bundan sonraki araştırmalara öncülük edeceği düşünülmektedir.



A NEW MACHINE LEARNING-BASED DIAGNOSTIC ALGORITHM USING SINGLE SIGNAL FOR CASES OF HEART FAILURE WITH LOW AND PRESERVED EJECTION FRACTION

SUMMARY

Regarding heart failure (HF), reducing mortality and prolonging life is one of the main goals of treatment. HF is one of the most common causes of hospitalization and death for adults and is on the way to becoming a worldwide epidemic. There are many advances in the treatment of HF, but due to the heterogeneous pathophysiology, HF still contains many unexplained points. Many clinical studies define HF patients according to their Left Ventricular Ejection Fraction (LVEF). According to LVEF, the two subtypes of HF are HF with reduced ejection fraction (HFrEF, $LVEF \leq 40\%$) and HF with preserved ejection fraction (HFpEF, $LVEF \geq 50\%$).

HF is a common and costly disease. Timely diagnosis is important for effective treatment, but diagnosis of HF at an early stage can be difficult. Early diagnosis of HF is difficult because the symptoms are not specific.

The presence of atypical findings or comorbidities may complicate the diagnosis of HF. For example, in a patient diagnosed with chronic obstructive pulmonary disease (COPD), it may be unclear whether the progression of dyspnea is due to COPD or HF. Similarly, wheezing occurs when the fluid accumulated as a result of pulmonary congestion compresses the bronchioles from the outside. In the case of asthma and COPD, the symptomatology is the same, although the pressure originates inside the bronchioles. For this reason, even if the patient is treated for chest diseases, the diagnosis of HF may be overlooked. If the pulmonologist considers the possibility of HF and makes some blood tests used in the diagnosis of HF and the results are compatible with the findings of HF, the patient can be referred to a cardiologist and the case will not be missed.

The rate of HFpEF is increasing among all HF patients. When HF patients in epidemiological studies are examined, approximately 50-55% of all HF cases are HFpEF. HFpEF is often seen in the elderly women patient population with a diagnosis of HF. Diagnosing HFpEF is more difficult than diagnosing HFrEF. The diagnosis of HFpEF is more complex and difficult even for specialists. The diagnosis of HFpEF is a problem that is tried to be solved in medicine. Since LVEF appears normal ($LVEF \geq 50\%$ in healthy individuals), HFpEF cases can be confused with pulmonary diseases due to some similar symptoms.

LVEF is a measure of how much of the blood coming into the left ventricle is pumped around the body. In a normal healthy individual, the maximum LVEF is 70%.

In HFrEF, the left ventricle cannot contract adequately and pump enough blood to the body. Although left ventricular contraction and blood pumping appear normal in HFpEF, adequate filling cannot be achieved because left ventricular relaxation is insufficient. For this reason, the amount of blood required for the body cannot be supplied in sufficient quantity.

Echocardiography is often used to measure LVEF. This is an expensive device that requires specialists and there may be situations where access to the device is limited. There may also be emergencies where treatment should be initiated without echocardiography. Economic and practical measurement and decision support systems are needed to solve such situations.

Most guidelines advocate primary care physician evaluation to diagnose HF. Once a definitive diagnosis is reached, treatment can be started by a specialist or primary care physician. Primary care physicians have an important role in monitoring the general health status of patients. They are the most aware of comorbid conditions. Treatment of comorbidities may decrease HF symptoms. Patients be more easily detected by providing medical care, by doing more research based on their signs and symptoms, or by screening those at highest risk for HF. High-risk groups include those with COPD or type 2 diabetes, particularly those who are older. In these patients, symptoms may be interpreted as part of the aging process and may cause the diagnosis to be overlooked. Echocardiography is still not available to most primary care physicians. The studies carried out within the scope of this thesis are advantageous in terms of providing a portable, easily accessible and easily measurable measurement system for primary care specialists who do not have echocardiography for the screening of high-risk groups.

B-type natriuretic peptide (BNP) blood tests are also performed to diagnose HF. BNP is a substance released from the ventricles into the blood in response to changes in blood pressure according to the HF level. Blood BNP levels increase as HF symptoms worsen and decrease once the condition is controlled. Even in a person with HF whose condition is under control, the BNP level is always higher than in a normal healthy person.

In this thesis, two different algorithms were developed as a diagnostic algorithm using only 3-lead electrocardiogram (ECG) features and a diagnostic algorithm using only photoplethysmography (PPG) and PPG-derived heart rate variability (HRV) features, for triple classification of classes of HFrEF, healthy and HFpEF. In addition, an algorithm using only HRV features has been developed for the binary classification of HFrEF and HFpEF.

This thesis study aimed to determine with a single signal whether the people who admitted to the hospital with HF symptoms are a HFrEF case, healthy or a HFpEF case.

ECG and PPG data were taken simultaneously for 10 seconds from 61 volunteers aged 25 and over. To clean both ECG and PPG signals, Chebyshev Type II band-pass filter in the range of 0.25-100 Hz, notch filter in the range of 49-51 Hz for 50 Hz mains noise and moving average filter were used as digital filters. HRVs were derived from cleared PPGs.

21 features have been extracted from both ECG, PPG, and HRVs at time domain. To these features, 16 more features have been added, consisting of Burg method and Yule-Walker method output parameters. Thus, 37 features have been obtained from each signal. Afterwards, the features have been analyzed statistically. The distributions of the ECG, PPG and HRV are not normal. For this reason, statistical analyzes are made with non-parametric tests. The Mann Whitney U test is a nonparametric test that performed to establish whether the two groups belong to the same population. Kruskal Wallis test, also, is a non-parametric test method used in cases where the data are not normally distributed and there are three or more classes. Therefore, these two tests

were preferred. The number of features decreased after the Kruskal Wallis test and further decreased with the experiments performed after the Mann Whitney U test.

For the triple classification study using ECG, after the Kruskal Wallis test, the number of features decreased from 37 to 19. The features are ranked from most relevant to least relevant according to their Eta correlation coefficients. With the experiments performed after the Mann Whitney U test, the final result was reached in the relationship of higher accuracy / fewer feature. The highest accuracy classification has been made with 4 ECG features which were at the top of rankings. Four different machine learning (ML) algorithms, namely k-NN, Support Vector Machines (SVM), Decision Trees and Bag Trees Ensemble Classifier, were used. 80% of the dataset is randomly set as training and 20% as test dataset. The accuracy rates obtained as a result of these classifications are: 100% for k-NN, 97.22% for SVM, 91.66% for Decision Trees and 97.22% for ensemble classifier.

For HFrEF and HFpEF binary classification using only HRV features, after the Mann Whitney U test, the number of features decreased from 37 to 21. The features are ranked from most relevant to least relevant according to their Eta correlation coefficients. A different number of highest ranking features were taken as input and classification studies were carried out. As a result, the best results were obtained from the classification using the features in the top three of the rankings. Three different ML algorithms, namely SVM, k-NN and Decision Trees, were used. Evaluation was made with 10-fold cross validation. The accuracy rates obtained as a result of these classifications are: 98.33% for SVM, 96.67% for k-NN and 95.83% for Decision Trees.

For triple classification using PPG and PPG-derived HRV, The dataset included a total of 74 features, 37 of which were PPG features and 37 were HRV features. After the Kruskal Wallis test, the number of features decreased from 74 to 58. With the experiments performed after the Mann Whitney U test, the final result was reached in the relationship of higher accuracy / fewer feature. The classification with highest accuracy has been made using 8 features, five of which were PPG features and three of which were HRV features. Three different ML algorithms, namely k-NN, SVM and ensemble classifier, were used. Again, evaluation was made with 10-fold cross-validation. The accuracy rates obtained as a result of the classifications are: 82.22% for k-NN, 82.78% for SVM and 87.78% for ensemble classifier.

Based on the results obtained in this study, it was determined that only 3-lead ECG or only PPG features can be used in the diagnosis of HFrEF and HFpEF and will provide important results. This study paved the way for the possibility of diagnosing HFrEF and HFpEF with a single signal. This is the point where the thesis study contributes to the literature. It is thought that it will lead the future researches on the subject.



1. GİRİŞ

En önemli yaşamsal organlarımızdan biri kalptir. Vücudumuzdaki hücre, doku ve organlar için gerekli olan besin ve oksijeni sağlayan kanı vücuda pompalar. Kalpteki herhangi bir hastalık (anormallik) kişinin tüm yaşamını, yaşam kalitesini etkiler.

Kalp yetersizliği (KY), normal dolum basınçlarına rağmen (veya sadece artmış dolum basınçlarına rağmen), kalbin dokuların metabolik ihtiyaçlarını karşılayacak ölçüde oksijen sunamamasına yol açan, kardiyak yapısal veya işlevsel bozukluk şeklinde tanımlanabilir (Dickstein ve ark., 2008). Yeterli oksijen sağlanamaması sebebiyle kişide çabuk yorulma, nefes darlığı, nabız düzensizliği (aritm) gibi belirtilere sebep olur ve günlük yaşamı olumsuz etkiler.

Ejeksiyon fraksiyonu (EF) kalbin her atışıyla birlikte bir ventrikülden vücuda pompalanan kan miktarıdır (Ponikowski ve ark., 2016). Normal bir insanda EF % 50-70 aralığındadır. Yani kalbe gelen kanın % 50'si ila %70'i vücuda pompalanır. Sol ventrikül ejeksiyon fraksiyonu (SVEF), sistemik dolaşıma pompalama verimliliğinin bir ölçüsüdür, sağ ventrikül ejeksiyon fraksiyonu ise, pulmoner dolaşıma pompalama verimliliğinin bir ölçüsüdür (Ponikowski ve ark., 2016). SVEF, yalnızca hastalık belirtisi olarak değil, klinik çalışmaların çoğunda hastaların SVEF'ye göre belirlenmesinden dolayı da önemlidir. SVEF genellikle ekokardiyografi ile ölçülür ve kişinin kalp fonksiyonunun genel bir ölçüsü olarak kullanılır. EF ölçümü için ekokardiyografi "altın standart" yöntem denilebilir. Bunun dışında Tek Foton Emisyonlu Bilgisayarlı Tomografi (SPECT) ve radyonüklid ventrikülografi (MUGA) de kullanılır. Bu cihazlar pahalıdır, bazı yöntemler invazivdir ve hepsi bir uzman gerektirir. Bu cihazlara erişimin kısıtlı olduğu durumlar da olabilir.

Kalp yetersizliğinin SVEF'ye göre belirlenen ve en yaygın görülen iki alt tipi düşük ejeksiyon fraksiyonlu KY (DEF-KY) ve korunmuş ejeksiyon fraksiyonlu KY (KEF-KY)'dir. Amerikan Kalp Derneği, KY vakaları için SVEF $\leq$ %40 ise DEF-KY, SVEF $\geq$ %50 ise KEF-KY olarak tanımlamaktadır (Heidenreich ve ark., 2022).

Sistolik KY veya DEF-KY olan hastalarla yapılan temel klinik çalışmalara genellikle EF $<$ %40 olan hastalar dahil edilmiştir ve günümüzde etkinliği kanıtlanmış tedavilerin

sadece bu grup hastalarda etkin olduğu gösterilmiştir. Diğer taraftan, EF >%40-45 olan ve başka kardiyak bozukluğu olmayan KY hastaları ile de çalışmalar yapılmıştır. Bu hastaların bazılarında EF tamamen normal değerlerde (genellikle > %50) olmakla beraber, sistolik işlevlerde de büyük bir azalma görülmemektedir. Bu nedenle, bu hastaları tanımlamak için KEF-KY terimi geliştirilmiştir (Borlaug ve Paulus, 2011; Paulus ve ark., 2007).

KEF-KY hastalarında altta yatan patofizyolojik bozukluğun SV diyastolik işlev bozukluğu olduğu düşünülmektedir ve bu yüzden bu tip KY'nin tanısında SV diyastolik işlev bozukluğunun teşhisi esastır. Hiçbir ekokardiyografik parametre tek başına SV diyastolik işlev bozukluğu tanısını koymada yeterli ölçüde kesin ve tekrarlanabilir değildir. Bu yüzden, tam ilişkili iki boyutlu ve Doppler verilerini içeren kapsamlı bir ekokardiyografik inceleme önerilmektedir (Nagueh ve ark., 1997, 2009; Paulus ve ark., 2007). Doppler Ultrason cihazları pahalıdır, ekokardiyografik inceleme zahmetlidir ve uzman hekim gerektirir. KEF-KY, tek bir hastalık varlığından ziyade yapısal veya fonksiyonel kardiyak bozukluklardan kaynaklanabilen karmaşık bir sendrom olduğundan, KY uzmanları için bile doğru teşhisi zor olabilir (Ponikowski ve ark., 2016).

Teşhisi zor olan, pahalı cihazlar ve uzmanlar gerektiren KEF-KY ve DEF-KY için daha ekonomik, ölçümü daha kolay ve hasta konforu için de avantajlı bir yönteme ihtiyaç vardır. Bu sebeple, bu çalışmada 3 kablolu elektrokardiyogram (EKG) ve fotopletismografi (PPG) verileri kullanılarak DEF-KY, KEF-KY ve sağlıklı olmak üzere üç sınıf için üçlü sınıflandırma çalışmaları yapılmıştır. Çalışmanın amacı, KY belirtileri ve şüphesiyle hastaneye başvuran hastanın DEF-KY mi, KEF-KY mi yoksa sağlıklı mı olduğu ön bilgisini saniyeler içerisinde doktora veren ve hastaya pahalı ve zahmetli testlerin gereksiz yere yapılmasını önleyen, hem zaman hem de hasta konforu açısından faydalı, yalnızca tek sinyal (EKG ya da PPG) kullanarak makine öğrenmesi (MÖ) tabanlı tıbbi karar destek sistemi geliştirmektir.

Literatürde çeşitli kalp yetersizliği sınıflandırmaları için yapay zeka (YZ) ve MÖ yöntemlerini kullanan çalışmalar mevcuttur (Choi ve ark., 2020; Ho ve ark., 2013; Kolukisa ve ark., 2019; Kota ve ark., 2021; J. Kwon ve ark., 2021; Lim, 2021; Muthunayagam ve Ganesan, 2022; Selvaraj ve ark., 2020). Bu çalışmalar genellikle DEF-KY'ye odaklanmıştır, bazıları sadece KEF-KY'yi incelemiştir. Sınıflandırmalar iki sınıf için yapılmıştır. Sınıflandırma için kullanılan özellikler yaş, boy ve kilo gibi

demografik bilgiler veya ekokardiyografi, manyetik rezonans görüntüleme veya invaziv yöntemlerden elde edilenler gibi daha zahmetli özelliklerdir. Son yıllarda, EKG kullanarak çeşitli kalp hastalıklarını tespit etmek için YZ algoritmaları geliştirildi. Bu çalışmalarda aort darlığı, anemi, atriyal fibrilasyon, kardiyak kontraktıl disfonksiyon, konjestif kalp yetersizliği, aritmi tahmini ve miyokard enfarktüsü gibi durumlar için EKG kullanılarak YZ yöntemleri ile algoritmalar geliştirilmiştir (Abdalla ve ark., 2020; Attia, Kapa, ve ark., 2019; Attia, Noseworthy, ve ark., 2019; J. Kwon ve ark., 2021; J. M. Kwon ve ark., 2020; Lin ve ark., 2020; Sbrollini ve ark., 2019; Zhang ve Xia, 2020). Bu çalışmalarda genellikle 12 derivasyonlu EKG verileri kullanılmıştır. YZ'nin EKG'ye uygulanmasıyla, QRS'deki ince değişikliklerin miyokardiyal fibroz, konjestif kalp yetersizliği, diürez tedavisinin etkinliği vb. gibi kalp fonksiyonları ile ilişkili olabileceği ve daha hızlı ve daha az maliyetli değerlendirme yapılabileceği gösterildi (García-Escobar ve ark., 2022). YZ ve MÖ algoritmaları kullanılarak kalp yetersizliğine bağlı ölüm ve hastaneye yeniden yatışı tahmin etmek için çalışmalar yapıldı (Plati ve ark., 2022). Bu çalışmaların bazılarında ekokardiyografik veriler (Jin ve ark., 2022), veya klinik fenotipleme, laboratuvar, EKG ve ekokardiyografi gibi birçok parametre aynı anda kullanılmıştır (Herman ve ark., 2022). Konjestif kalp yetersizliği (KKY), DEF-KY ve KEF-KY'yi kapsar. KKY'nin varlığı veya yokluğu şeklinde ikili sınıflandırma yapılmıştır (Masetic ve Subasi, 2016). Hasumi ve ark. (2020) yapılan çalışmada, veri setindeki hasta sınıfı DEF-KY, KEF-KY ve Koroner Arter Hastalığı'nı (KAH) içerir. Ancak sınıflandırma KY varlığı veya yokluğu şeklinde yapılmış ve hasta sınıfı da New York Heart Association (NYHA) fonksiyonel sınıflamasına göre sınıflandırılmıştır. García-Escobar ve ark. (2022), Hasumi ve ark. (2020), Herman ve ark. (2022), Jin ve ark. (2022), Masetic ve Subasi (2016), Plati ve ark. (2022) çalışmalarının odak noktası DEF-KY ve KEF-KY tanısı değildir.

12 derivasyonlu EKG verileri kullanılarak geliştirilen YZ tabanlı bir sistem ile DEF-KY ve KEF-KY için 10 yıllık bir HF risk tahmini yapılmıştır (Karabayır ve ark., 2022). Burada DEF-KY için $LVEF < 50\%$ ve KEF-KY için $LVEF \geq 50\%$ kabul edilmiştir. Yani, sınırda ejeksiyon fraksiyonlu KY (SEF-KY) ($41\% \leq LVEF \leq 49\%$) de DEF-KY'ye dahil edilmiştir. Bu sistemin DEF-KY ve KEF-KY arasında ayırım yapmaya yardımcı olabileceğine dair hiçbir kanıt yoktur.

Bu çalışmada sadece 3 kablolu EKG verilerinden elde edilen özellikler kullanılarak sınıflandırma çalışmaları yapılmıştır. Oldukça kayda değer başarılı sonuçlar elde edilmiştir. Ayrıca PPG ve PPG'den türetilen kalp hızı değişkenliği (KHD) özellikleri ile de sınıflandırma çalışmaları yapılmıştır.

Fotopletismografi (PPG), kalp debisi ve oksijen saturasyonu gibi fizyolojik parametreleri ölçmek için yaygın olarak kullanılan bir klinik yöntemdir. Küçük boyutu ve maliyet etkinliği nedeniyle kardiyovasküler sağlık çalışmaları için iyi bir seçenektir. Ayrıca çalışmalar, PPG'nin kalibrasyondan bağımsız olarak elde edilebileceğini kanıtlamaktadır (Harini ve ark., 2014).

PPG, kardiyovasküler ve kalp hastalığı ile ilgili çalışmalarda kullanılmıştır. Bunların çoğunda makine öğrenmesi algoritmaları kullanılmıştır. Rubins ve ark. (2008) tarafından yapılan çalışmada, sağlıklı ve kardiyovasküler hastalığı (KVH) olan gönüllü grupları, eşzamanlı parmak ve kulak PPG ölçümlerini kullanan yeni bir algoritma ile değerlendirilmiştir. Makine öğrenmesi ve yapay zeka yöntemleri kullanılarak PPG ile non-invaziv kan basıncı tahmini çalışması yapılmıştır (El-Hajj ve Kyriacou, 2020). Farklı aritmi tiplerini teşhis etmek için fotopletismografi sinyalleri kullanılarak derin öğrenme modellerinin performans değerlendirmesi yapılmıştır (Kulkarni ve Dushyanth, 2021). Kalp yetersizliği hastalarında uykuda solunum bozukluğunu taramak için PPG kullanılmıştır (Sharma ve ark., 2015).

İnvaziv yöntemlere alternatif olarak da PPG ile çalışmalar yapılmıştır. PPG, sağ kalp yetersizliği ve stabil diyastolik hastalarda L-arginin ve sitrülün amino asitlerinin endotel fonksiyonu üzerindeki etkisini yorumlamak için kullanılmıştır (Orea-Tejeda ve ark., 2010). PPG'nin Valsalva manevrası sırasında sol ventrikül dolum basıncını gösterdiği bulunmuştur (Silber ve ark., 2012). Valsalva manevrasında kullanılan PPG'nin, kalp yetersizliği hastalarında pulmoner kapiller kama basıncını tahmin edebildiği gösterilmiştir (Gilotra ve ark., 2017). Hastanede yatan kalp yetersizliği hastalarının risk altında olup olmadığını belirlemek için Valsalva manevrası sırasında ölçülen PPG'nin yararlılığı araştırılmıştır (Gilotra ve ark., 2020). Kalp yetersizliği hastalarında mekanik değişimin PPG analizi ile doğru bir şekilde tanımlanabileceği gösterilmiştir (Besleaga ve ark., 2019).

PPG'nin ölçülmesi kolay olduğu için akıllı telefonlar, giyilebilir teknolojiler ve elektronik cihazlar konusunda birçok çalışma bulunmaktadır. Akıllı telefonlar

kullanılarak atriyal fibrilasyon tespiti için PPG kullanan yeni bir algoritma geliştirilmiştir (Schack ve ark., 2017). PPG, akıllı telefonlardan ve giyilebilir cihazlardan kolayca ölçüldüğünden, diyabet tespiti PPG kullanılarak incelenmiştir (Avram ve ark., 2019). Sol ventrikül diyastol sonu basıncının 20 mm Hg'den büyük olduğunu saptamak için PPG kullanılarak yüksek özgüllüğe ve iyi duyarlılığa sahip bir cihaz geliştirilmiştir (Galiatsatos ve ark., 2017). PPG teknolojisine sahip Corsano 287 bilekliğin kalp atış hızı ve RR aralıklarını yüksek doğrulukla belirleyebildiği gösterilmiştir (Blok ve ark., 2021).

KKY olanlar ile sağlıklı bireyleri ayırt etmek için prototip bir PPG cihazı geliştirilmiştir (Baldoumas ve ark., 2019). Sağlıklı kişiler ve KKY hastalarını ayırt etmek için eş zamanlı olarak alınan EKG ve PPG kullanılmıştır (Baldoumas ve ark., 2020).

KKY, DEF-KY ve KEF-KY vakalarını içerir. Literatürde KKY ile ilgili çalışmalar genellikle KY olup olmadığı ile ilgilidir. EKG'nin kullanıldığı bazı çalışmalar sadece DEF-KY veya sadece KEF-KY ile ilgilidir. EKG veya PPG kullanılarak, sadece tek bir sinyal ile, bu iki KY alt tipini aynı anda değerlendiren bir çalışma yoktur. Bu yönüyle bu tez çalışması literatürdeki çalışmalardan öne çıkmaktadır. Bu çalışmada DEF-KY, sağlıklı ve KEF-KY olmak üzere üç sınıfla üçlü sınıflandırma yapılmıştır. Yani KY belirtileri gösteren bireyin sadece KKY olup olmadığı hakkında bilgi verilmez, aynı zamanda vakanın DEF-KY, KEF-KY veya sağlıklı olup olmadığı, yani KY var ise hangi tip KY olduğu hakkında da bilgi verilir.

KY hastaları göğüs ağrısı, nefes darlığı, yorgunluk gibi semptomlar gösterdiğinden özellikle KEF-KY hastaları ($SVEF \geq 50$ sağlıklı bireyler gibi) Göğüs Hastalıkları bölümüne gönderilebilir. Göğüs hastalıkları uzmanı dikkatli olursa B tipi natriüretik peptit (BNP) ve N-terminal proBNP (NT-proBNP) kan testlerini yaptırır ve bu hastalara KEF-KY tanısı konur. Ancak sadece göğüs hastalıkları bakımından değerlendirilirse ve sonuçlar normal çıkarsa hiçbir işlem yapılmaz ve KEF-KY tanısı gözden kaçmış olur. BNP ve NT-proBNP kan testleri invaziv ve zahmetli yöntemlerdir. Ayrıca ekokardiyografi pahalı bir cihazdır, uzman gerektirir ve cihaza erişimin kısıtlı olduğu durumlar olabilir. Bu nedenle alternatif ekonomik ve pratik bir tanı yöntemi araştırılmıştır.

Literatürde KY için KHD kullanan çalışmalar mevcuttur (Guzzetti ve ark., 2001; İşler ve Kuntalp, 2007; Musialik-Lydka ve ark., 2003). Ancak bu çalışmalarda KHD'ler EKG'den türetilmiştir. KHD çoğunlukla EKG'den türetilse de, PPG'den türetilen KHD'leri kullanan çalışmalar da vardır (Bozkurt ve ark., 2019; Bozkurt ve ark., 2020; Uçar ve ark., 2018). Bu çalışmalar da KY tanısı ile ilgili değildir. Bu nedenle, bu çalışmada PPG'den türetilen KHD'lerin kullanılabileceği düşünülmüştür.

Literatürde, EKG veya PPG sinyallerinin kullanıldığı çalışmalarda genellikle bu sinyallerin yanı sıra yaş, boy, kilo gibi demografik bilgiler, ekokardiyografik veriler, hastalık geçmişi, hastanın kullandığı ilaçlar gibi çok sayıda özellikler de kullanılmıştır. EKG veya PPG ile, yani tek bir sinyal ile bu tanı algoritmasının geliştirilmiş olması, bu tez çalışmasının literatüre katkılarının biridir. Ayrıca, KEF-KY ve DEF-KY ile ilgili çalışmalarda PPG'nin kullanıldığı bir çalışma mevcut değildir. Düşük maliyetli bir cihazla kolayca elde edilebilen ve hasta konforu için de avantajlı olan PPG sinyalinin bu alanda kullanılması da bu tez çalışmasının literatüre katkılarındandır.

EKG ve PPG verileri 25 yaş ve üzeri gönüllülerden 10 s süreyle eş zamanlı olarak alınmıştır. Her iki sinyal için de dijital filtreler ile filtreleme işlemi yapılmıştır. Filtreleme adımından sonra PPG'lerden KHD'ler türetilmiştir. Daha sonra EKG, PPG ve KHD'lerin her birinden 37'ser özellik çıkarılmıştır.

Tanı algoritması için demografik bilgilere veya ekokardiyografi ve diğer detaylı tetkiklere gerek olmadan sadece EKG'den, sadece PPG'den ya da sadece KHD'den elde edilen özelliklerin kullanılabilir olup olmadığını araştırmak için, özellikler ile sınıflar arasındaki ilişki istatistiksel yöntemlerle incelenmiştir.

İstatistiksel olarak en ayırt edici olan özellikler belirlenmiş, özellik sayısı azaltılarak MÖ algoritmaları ile sınıflandırma çalışmaları yapılmıştır. Oldukça yüksek doğrulukla sınıflandırmalar gerçekleştirilmiştir.

2. EJEKSİYON FRAKSİYONU DÜŞÜK VE KORUNMUŞ KALP YETERSİZLİĞİ

2.1. Giriş

Kalp yetersizliği tek bir hastalık varlığından ziyade, yüksek juguler ven basıncı, pulmoner raller ve periferik ödem gibi bulguların eşlik edebileceği başlıca semptomlardan (örn. nefes darlığı, ayak bileği şişmesi ve yorgunluk) oluşan klinik bir sendromdur. İstirahatte ve/veya egzersiz sırasında yüksek kalp içi basınçlara ve/veya yetersiz kalp debisine neden olan, kalbin yapısal ve/veya fonksiyonel anormalliğinden kaynaklanır (McDonagh ve ark., 2021). Bu anormallik sebebiyle KY, kalbin dokular için gerekli olan kanı ve dolayısı ile oksijeni yeterli miktarda gönderememesine yol açan bir klinik tablodur. 'Konjestif KY (KKY)' bazen kullanılan ve aşırı yük hacmi kanıtıyla birlikte akut veya kronik KY'yi tanımlayabilen bir terimdir (Ponikowski ve ark., 2016).

Yetişkin bireyler için en sık görülen hastaneye yatış ve ölüm nedenlerinden biri KY'dir ve giderek dünya genelinde bir epidemi olma yolundadır. Avrupa'da ve ABD'de KY vakalarının %85'i 65 yaş ve üzerindedir. Ülkemizde KY için yaş ortalaması Avrupa'daki ortalamanın altındadır. Toplumumuzdaki yaşlı nüfus arttıkça KY vaka sayılarının daha da artacağı düşünülmektedir. Sık hastaneye yatma, yaşam boyu tedavi, karmaşık ve pahalı cihaz gereksinimleri nedeniyle KY, ekonomik olarak yüksek maliyetlere sebep olmaktadır. Avrupa'daki sağlık harcamalarının toplamının %1-3'ü KY vakalarına harcanmaktadır (Çavuşoğlu ve ark., 2015).

KY yaygınlığı tanım aralığına bağlıdır, mesela gelişmiş ülkelerde yetişkin nüfusun yaklaşık %1 – 2'sidir ve 70 yaş ve üzeri kişilerde %10'un üzerindedir (Ponikowski ve ark., 2016).

KY'yi tanımlamak için kullanılan ana terminoloji SVEF ölçümüne dayanmaktadır. SVEF'ye göre KY'nin iki alt tipi Düşük EF'li KY (DEF-KY, $SVEF \leq \%40$) ve Korunmuş EF'li KY (KEF-KY, $SVEF \geq \%50$)'dir (Bozkurt ve ark., 2021). Altta yatan farklı etiolojiler, demografik özellikler, komorbiditeler ve tedavilere verilen yanıtlar nedeniyle KY hastalarının SVEF'ye göre ayırt edilmesi önemlidir (Butler ve ark.,

2014). İki KY tipinde bazı farklı patofizyolojik mekanizmalar, tedavi farklılıkları, doğal geçmişler ve sonuçlar bildirilmiştir (Adebayo ve ark., 2017).

Toplam KY vakalarının yaklaşık %50'si KEF-KY'dir. KEF-KY tanısı, DEF-KY tanısından daha zordur. KEF-KY'li hastalarda genellikle sol ventrikül (SV) genişlememiştir, bunun yerine artan dolum basınçlarının bir göstergesi olarak sıklıkla SV duvar kalınlığında bir artış ve/veya sol atriyal (SA) boyutunda artış vardır. Çoğunda, diyastolik disfonksiyon olarak da sınıflandırılan ve genellikle bu hastalarda KY'nin olası nedeni olarak kabul edilen (dolayısıyla 'diyastolik KY' terimi) bozulmuş SV dolum veya emme kapasitesinin ek 'kanıtları' vardır. Bununla birlikte, DEF-KY'li hastaların çoğunda (önceden "sistolik KY" olarak anılırdı) diyastolik disfonksiyon da vardır ve KEF-KY'li hastalarda sistolik fonksiyonda hafif anormallikler gösterilmiştir. Bu nedenle korunmuş veya azalmış 'sistolik fonksiyon' yerine korunmuş veya azalmış SVEF'nin belirtilmesi tercih edilir (Ponikowski ve ark., 2016).

KEF-KY'li hastalar, DEF-KY hastalarına göre daha yaşlı, sıklıkla kadın cinsiyette ve genellikle daha obez hastalardır. Bu grup hastada koroner kalp hastalığına daha az, hipertansiyon ve atriyal fibrilasyona (AF) ise daha sık rastlanmaktadır. KEF-KY hastalarının hastalık seyri DEF-KY hastalarına göre daha iyidir (Rich ve ark., 2018).

2.2. Kalp Yetersizliği Belirtileri

Sağlık hizmeti sağlayıcılarının KY'nin bulgularını ve semptomlarını iyi anlaması önemlidir, böylece ilk başvuruda tanının gözden kaçırılmaması ve kötüleşen durumun erken saptanması ve derhal tedavi edilmesi sağlanır. Ayrıca, KY'nin yaygın bulgu ve semptomları, KY'yi rutin olarak tedavi eden kardiyologlar tarafından iyi bilinebilir, ancak durumun kötüleşmesiyle ilişkili olağandışı bulgu ve semptomlar başvuru sırasında fark edilmeyebilir.

KY doğrudan ve dolaylı olarak sağlık sistemi için yüksek maliyetlere neden olmakta ve önemli bir yük teşkil etmektedir. Bu nedenle sağlık hizmeti sağlayıcıları ve hastalar için KY'nin yaygın ve olağandışı bulgu ve semptomlarının miktarını belirtmek, tanı testleri ve tedavi kararlarını optimize etmek ve genel durumun uygun bir şekilde izlenmesini kolaylaştırmak için önemlidir.

Hastalar ve hemřireler KY'nin belirti ve semptomlarını tanıdıklarında ve KY'nin yönetimini anladıklarında, bedensel değışiklikler, duyular ve davranışlar arasındaki bağlantılar daha anlamlı hale gelebilir.

KY belirtileri:

- 1- Nefes darlığı
- 2- Çarpıntı
- 3- Çabuk yorulma
- 4- Ayak veya bacakta ödem
- 5- Karın şişliği ve ağrı
- 6- Hızlı kilo alma
- 7- Öksürük
- 8- Baş dönmesi, sersemlik, dikkat kaybı, bayılma
- 9- Göğüs ağrısı
- 10- İştah kaybı ve / veya bulantı .

KY belirti ve bulguları ile ilgili bir çalışmada, hastalara bir kontrol listesi dağıtılmıştır. Bu kontrol listesi, hastaları yalnızca KY ile ilgili olduğunu düşündükleri değil, yaşadıkları tüm belirti ve semptomları bildirmeye sevk etmiştir. Bu çalışmada hastalar tarafından bildirilen ilk 5 semptom nefes darlığı, egzersiz yapma yeteneğinde azalma, ortopne, aşırı yorgunluk ve baş dönmesidir. En sık bildirilen 5 belirti ödem, ayak bileği veya bacak ödemi, çarpıntı, düzensiz nabız ve karın ödemidir. Neredeyse tüm hastalar dispne bildirmiştir. Derin yorgunluk, hastaneye kaldırılmanın belirgin bir göstergesidir (Albert ve ark., 2010).

2.3. Tanı

KY tanısı sadece hekimler tarafından konulabilir. Hastanın klinik hikayesi ve yakınmalarına göre yapılacak muayene sonucu KY olasılığı ortaya konacaktır. Tanıyı doğrulamak için çeşitli testler yapılır. Bu testlerden en sık kullanılanı ekokardiyogram (kalp ultrasonu) dır. Ekokardiyografik inceleme ile kalp duvarları, kalp kapakları ve kalp boşlukları hakkında bilgi edinilebilir ve pompalama gücü doğrudan ölçülebilir (*Türk Kardioloji Derneği*, 2022).

2.4. Tedavi

KY tedavisinde erken tanı ve tedavi çok önemlidir. Günümüzde pek çok KY hastası hekim-hasta işbirliği ile normal günlük yaşantılarını devam ettirebilmektedir. KY tanısı alındıktan sonra hastaya hekim tarafından bir takım ilaçlar başlanacak ve yaşam tarzını hastalığının gerektirdiği şekilde değiştirmesi önerilecektir (*Türk Kardioloji Derneği*, 2022).

2.4.1. Kalp yetersizliğinde ilaç tedavisi

KY hastaları çeşitli ilaçlar kullanmak zorundadırlar. İlaçlar çoğunlukla düşük dozda başlanır ve giderek dozları artırılır. KY ilaçlarının reçetede belirtildiği gibi kullanılması tedavinin iyi sonuç vermesi açısından önemlidir. KY tedavisinde genelde birden fazla ilaç reçetelenir. Bu ilaçlar sadece hastaların yakınmalarını azaltmak için değil, aynı zamanda altta yatan hastalığı tedavi etmek ve hastanın sağlığını uzun vadede iyi tutmak için verilir. İlaçlar için alım saati ve miktarı belirten bir çizelge oluşturmak ve saatinde kullanılan ilaçları işaretlemek, ilaç almanın unutulmasını veya atlanmasını en aza indirecek ve ilaçların sebep olabileceği yan etkilerin doktor tarafından tespit edilmesini kolaylaştıracaktır. KY ya da kalp ritm problemi için kalp pili veya şoklama cihazı gibi bir cihaz konulmuş olsa bile, ilaçların doktorun önerdiği şekilde kullanılması gereklidir. Cihazlar kullanılırken genellikle ilaç tedavisine de devam edilir (*Türk Kardioloji Derneği*, 2022).

2.4.2. Kalp yetersizliğinde yaşam tarzı değişiklikleri

KY kroniktir ve yaşam boyu tedavi gerekir. KY hastasının ilaçlarını düzgün kullanmakla birlikte, tedaviden olabildiğince fayda görebilmesi, klinik olarak kötüleşmelerin ve hastalığın ilerlenemesinin önlenmesi için yaşam biçiminde birtakım değişiklikler yapması gerekir.

Kısa sürede fazla kilo almak ya da vermek önemlidir. İdrar söktürücü ilacın kullanım şekli veya doz ayarı yanlış olabilir. Bu da aşırı su kaybı veya vücutta ödeme sebep olarak hızlı kilo vermeye ve almaya neden olabilir. KY hastalarının her gün aynı baskülle ve aynı saatte kilolarını ölçüp not almaları ve ani değişimleri doktorlarına bildirmeleri tavsiye edilir. Ödemden kaçınmak için sıvı alımı kontrollü olmalı ve tuz tüketimi kısıtlanmalıdır.

Beslenme rutinine potasyum açısından zengin meyve ve sebzeler dahil edilmelidir. Yüksek kolesterol KY'ye sebep olan koroner arter hastalığı ve kalp krizi ile bağlantılıdır. Bu nedenle yağ alımının azaltılması önerilir.

KY hastalarının üçte birinde diyabet görülebilir. Kan şekerinin yüksek olmasının, dolaylı veya direkt olarak kalp fonksiyonuna zararlı etkileri olmaktadır. Diyabet sebebiyle organ harabiyetini önlemek için diyabetik diyetle dikkat edilmesi önerilir.

Araştırmalar KY hastalarının hafif ve doktorun tavsiye ettiği şekilde yapacakları düzenli egzersizlerin yaşam kalitesine olumlu etkileri olduğunu göstermektedir (*Türk Kardiyoloji Derneği*, 2022).






3. ELEKTROKARDİYOGRAM VE FOTOPLETİSMOGRAFİ SİNYALLERİ

3.1. Elektrokardiyogram

Elektrokardiyogram (EKG), kalp hücreleri ("kardiyo") tarafından üretilen ve vücut yüzeyine ulaşan elektriksel aktivitenin ("elektro") kayıdır ("gram"). Bu elektriksel aktivite, vücuda kan pompalayan kalbin kas kasılmasını başlatır (Wagner, 2013). EKG, kalp atışının zaman-voltaj grafiğini sağlar (Goldberger ve Goldberger, 2018). İlk olarak 1889'da A. D. Waller evcil hayvan buldog cinsi köpeğini sinyal kaynağı olarak ve kılcal elektrometreyi kayıt cihazı olarak kullanarak gözlemiştir (Waller, 1889). 1903'te W. Einthoven, kayıt cihazı olarak tel galvanometreyi kullanarak ve çeşitli kardiyak anormallikleri olan insan deneklerini kullanarak çalışma yapmıştır (Salinet ve Luppi Silva, 2018). Einthoven, insan vücudunu bir iletken olarak gördü. Kalp, vücutta akım üreten kaynaklardan biri olduğu için; bu kaynağın davranışının, kalpten yayılan elektrik kuvvetlerinin yansıtıldığı insan vücudunun farklı noktalarındaki voltaj ölçümünden çıkarılabileceği sonucuna vardı (Toinga ve ark., 2018). Einthoven tarafından önerilen ölçümler şunlardı: bipolar Lead I veya Derivasyon I (DI) olarak adlandırılan iki kol arasındaki voltaj; sağ kol ve sol bacak arasındaki, bipolar Lead II veya Derivasyon II (DII) olarak adlandırılan voltaj; ve sol kol ile sol bacak arasındaki, bipolar Lead III veya Derivasyon III (DIII) olarak adlandırılan voltaj. Şekil 3.1'de gösterildiği gibi, üç ölçüm noktasının birleşimi, elektrokardiyografik kayıtların normalleştirilmesini mümkün kılan Einthoven Üçgeni olarak bilinen hayali üçgeni oluşturabilir (Amin ve ark., 2017; Mukala ve ark., 2010).



Şekil 3.1. Einthoven üçgeni.


Bir EKG dalga formunu kaydetmek için vücuttaki iki nokta arasında bir diferansiyel kayıt yapılır. EKG'nin makine tarafından yorumlanması için EKG'ye bilgisayar uygulanması, bilgisayarların tıpta ilk kullanımlarından biridir. Bilgisayar tabanlı sistemlerde birincil ilgi alanı, insan okuyucunun yerini alması ve standart dalgaların ve aralıkların aydınlatılmasıydı (Berbari, 2014).

EKG, kritik bilgiler sağlayabileceğinden, klinik tanı ve yatan hastaların ve ayakta hastaların yönetiminin önemli bir bileşenidir. Günümüzde EKG'ler genellikle tek kullanımlık yapıştırma (yapışkan) gümüş-gümüş klorür elektrotları ile kaydedilir.

Standart 12 derivasyonlu EKG kaydı için, elektrotlar el bileklerine, ayak bileklerine ve göğüs duvarı (prekordiyum) üzerine yerleştirilir. Acil servisler, kardiyak ve yoğun bakım üniteleri ve ayakta izleme (örn., Holter) gibi ortamlarda, genellikle birkaç göğüs ve abdominal elektrot aracılığıyla yalnızca bir veya iki "ritim şeridi" derivasyonu kaydedilebilir (Ary L. Goldberger, Zachary D Goldberger, 2018). Bu tez çalışmasında kullanılan EKG verileri de üç kablolu EKG sinyalleridir. Sağ el bileği, sol ve sağ ayak bilekleri olmak üzere üç adet elektrot bağlantısı kullanılmıştır (Bipolar DII).

3.1.1. Kalpteki elektrik sinyali

En basit ifadeyle, kalp, elektrikle zamanlanmış bir pompa olarak düşünülebilir (Ary L. Goldberger, Zachary D Goldberger, 2018). Bu olağanüstü organın elektriksel “kabloları” Şekil 3.2'de özetlenmiştir.



Şekil 3.2. Kalbin elektriksel bağlantıları (Goldberger ve Goldberger, 2018).

Normalde kalp uyarısı (elektrik sinyali), sağ atriyumun (RA) üst tarafında bulunan sinoatriyal (SA) düğümdeki kalp pili hücreleri tarafından otomatik olarak üretilir. Uyarı daha sonra RA ve sol atriya (LA) yayılır. Daha sonra, atriyoventriküler (AV) düğümü ve His demetini geçer. Uyarı daha sonra His demetinin devamı olan sol ve sağ demet dalları yoluyla sol ve sağ ventriküllere geçer. Kalp uyarısı, Purkinje lifleri aracılığıyla sol ve sağ ventrikül kas hücrelerine hızla ve aynı anda yayılır. Sırasıyla atriyumların ve ventriküllerin elektriksel aktivasyonu, bu odaların sıralı kasılmasını sağlar.

Belirli kalp hücrelerinin minik saatler gibi kendiliğinden elektriksel darbeler üreterek kalp pili olarak işlev görme kapasitesi kardiyak otomatiklik olarak ifade edilebilir. Daha önce bahsedildiği gibi, SA düğümü, doğal otomatikliği nedeniyle normalde kalbin birincil (baskın) kalp pilidir (Goldberger ve Goldberger, 2018).


Otomatikliğe ek olarak, kalbin diğer önemli elektriksel özelliği iletkenliktir. Elektriksel uyarıların kalbin farklı bölümlerinden iletilme hızı değişir. İletim, Purkinje liflerinde en hızlı ve AV düğümünde en yavaştır. AV düğümündeki nispeten yavaş iletim hızı, kalp kasılması için sinyal gelmeden önce ventriküllerin kanla dolmasına izin verir. His - Purkinje sistemi aracılığıyla hızlı iletim, her iki ventrikülün senkronize kasılmasını sağlar.

EKG kaydı, yatay eksenindeki zamana karşı dikey eksenindeki voltajı çizer. Yatay eksen boyunca yapılan ölçümler, genel kalp atış hızını, düzenliliğini ve kalbin bir bölümünden diğerine hareket eden elektriksel aktivasyon sırasındaki zaman aralıklarını gösterir. Dikey eksen boyunca yapılan ölçümler, vücut yüzeyinde ölçülen voltajı gösterir. Bu voltaj, tüm kalp hücrelerinin elektriksel aktivasyonunun "toplamını" temsil eder. Bazı anormallikler, tek bir EKG kaydındaki ölçümlerle tespit edilebilir, ancak diğerleri yalnızca zaman içinde seri kayıtların gözlenmesiyle ortaya çıkar (Wagner, 2013).

3.1.2. EKG temelleri: dalgalar, aralıklar ve segmentler

Elektriksel aktivasyon (stimülasyon) terimi, elektrik sinyallerinin atriyumlar ve ventriküller boyunca yayılmasıdır denebilir. Kardiyak aktivasyon süreci için daha teknik terim depolarizasyondur. Depolarizasyondan sonra kalp kası hücrelerinin dinlenme durumuna geri dönmesine repolarizasyon denir.

Bu anahtar terimler, normal "dinlenme" miyokard hücrelerinin polarize olması gerçeğinden türetilmiştir; yani yüzeylerinde elektrik yükleri taşırlar. Şekil 3.3.a, normal bir atriyal veya ventriküler kalp kası hücresinin dinlenme polarize durumunu gösterir. Dinlenme hücresinin dışı pozitif ve içi negatiftir. (Aralarında yaklaşık -90 mV [milivolt] gradyan).



Şekil 3.3. Depolarizasyon ve repolarizasyon (a) Dinlenme halindeki kalp kası hücresi polarizedir; yani, hücrenin dışı pozitif yüklü ve içi negatif yüklüdür. (b) Hücre uyarıldığında (S, stimüle) depolarize olmaya başlar (noktalı alan). (c) Tamamen depolarize olan hücrenin içi pozitif, dışı negatif yüklüdür. (d) Uyarılan hücre dinlenme durumuna döndüğünde repolarizasyon meydana gelir. Depolarizasyon ve repolarizasyon yönleri oklarla gösterilmiştir (Goldberger ve Goldberger, 2018).

Bir kalp kası hücresi (veya hücre grubu) uyarıldığında depolarize olur. Sonuç olarak hücrenin dışı, yani uyarının meydana geldiği bölge negatif yüklenir ve hücrenin içi pozitif olur. Bu, uyarılan depolarize alan ile uyarılmayan polarize alan arasında hücrenin dış yüzeyinde elektrik voltajında bir fark yaratır (Şekil 3.3.b). Sonuç olarak, tüm hücre depolarize olana kadar uyarı ve depolarizasyon meydana geldikçe hücrenin uzunluğu boyunca yayılan küçük bir elektrik akımı oluşur (Şekil 3.3.c). Depolarizasyon yolu, Şekil 3.3.b'deki gibi bir ok ile gösterilebilir.

Elektrik akımı EKG tarafından, atriyumlar uyarıldığında ve depolarize olduğunda bir P dalgası ve ventriküller uyarıldığında ve depolarize olduğunda bir QRS kompleksi olarak kaydedilir. Tamamen uyarılmış ve depolarize hücre dinlenme durumuna geri dönmeye başladığında repolarizasyon başlar. Hücrenin dışındaki küçük bir alan tekrar pozitif hale gelir (Şekil 3.3.d) ve repolarizasyon, tüm hücre bir kez daha tamamen repolarize olana kadar hücrenin uzunluğu boyunca yayılır. Ventriküler repolarizasyon EKG tarafından ST segmenti, T dalgası ve U dalgası olarak kaydedilir.


Özetle, EKG ister normal ister anormal olsun, sadece iki temel olayı kaydeder: (1) depolarizasyon, bir uyarının (uyaranların) kalp kasından yayılması ve (2) repolarizasyon, uyarılan kalp kasının dinlenme durumuna dönmesi. Depolarizasyon ve repolarizasyonun temel hücresel süreçleri, vücut yüzeyinde standart EKG'de görülen dalga formlarını, segmentleri ve aralıkları oluşturur (Şekil 3.4).

EKG, sadece tek liflerin değil, çok sayıda atriyal ve ventriküler hücrenin elektriksel aktivitesini kaydeder. Uyaranların atriyumlar ve ventriküller boyunca sıralı ve organize bir şekilde yayılması, ardından dinlenme durumuna geri dönmeleri, EKG'de kaydedilen elektrik akımlarını üretir. Ayrıca, kardiyak elektriksel aktivitenin her aşaması belirli bir dalga veya sapma üretir. QRS dalga biçimlerine kompleksler denir (Şekil 3.4). Beş temel EKG dalga biçimi şunlardır:

P dalgası – atriyal depolarizasyon

QRS kompleksi – ventriküler depolarizasyon

ST Segmenti }
T dalgası } ventriküler repolarizasyon
U dalgası }



Şekil 3.4. EKG grafiğinin temel bileşenleri.

P dalgası, bir uyarının atriyumlar boyunca yayılmasını temsil eder (atriyal depolarizasyon). QRS dalga formu veya kompleksi, ventriküller boyunca yayılan

uyarımı temsil eder (ventriküler depolarizasyon). Adından da anlaşılacağı gibi, QRS sapmaları seti (kompleks), Q, R ve S olarak etiketlenen bir veya daha fazla spesifik dalga içerir. ST (hem dalga formu hem de segment olarak kabul edilir) ve T dalgası (veya “ST-T” dalga formu olarak gruplandırılır), uyarılmış ventriküler kasın dinlenme durumuna (ventriküler repolarizasyon) dönüşünü temsil eder. Ayrıca ST segmentinin başlangıcına (QRS kompleksi ile bulunduğu yer) J noktası denir. U dalgası, bazen T dalgasından hemen sonra görülen küçük bir sapmadır. Kesin mekanizması bilinmemekle birlikte ventriküler repolarizasyonun son aşamasını temsil eder (Goldberger ve Goldberger, 2018).

Listelenen dalgaların veya komplekslerin hiçbiri uyarılmış (depolarize) atriyumun dinlenme durumuna geri dönüşünü temsil etmez. Çünkü atriyal ST segmenti (STa) ve atriyal T dalgası (Ta) genellikle düşük genlikleri nedeniyle rutin EKG'de görülmez.

Özetle, P, QRS, ST-T, U dizisi, normal kalp atışının elektriksel aktivitesinin döngüsünü temsil eder. Bu fizyolojik sinyalleşme süreci, SA düğümü depolarizasyonu ile başlatılan bir uyarının atriyumlara yayılması (P dalgası) ile başlar ve uyarılan ventriküler kasın dinlenme durumuna (ST-T ve U dalgaları) dönmesiyle sona erer. Şekil 3.4'te görüldüğü gibi, temel kalp döngüsü, yaşamın ritmik nabzını koruyarak kendini sürekli tekrar eder.

3.1.3. Elektrokardiyogram ile teşhis edilebilen tıbbi sorunlar

Kalp kası genişlemesi, elektrik iletim blokları, yetersiz kan akışı ve koroner tromboz nedeniyle kalp kasının ölümü dahil olmak üzere birçok kardiyak anormallik EKG yorumuyla tespit edilebilir. EKG, kalp kasının bir bölgesini yok etmekle tehdit eden koroner arter tıkanıklığı için, kalbin hangi koroner arterlerinin bu tıkanıklığa sebep olduğunu bile belirleyebilir. EKG aynı zamanda kalp hızı ve düzenliliği ile ilgili sorunları tanımlamanın birincil yöntemidir. EKG, kalp problemlerini anlamanın yanı sıra, vücuttaki tıbbi durumların teşhisine yardımcı olmak için de kullanılabilir. Örneğin, EKG, potasyum ve kalsiyum gibi kandaki anormal iyon düzeylerini ve tiroid gibi bezlerin anormal işlevlerini ortaya çıkarabilir. Ayrıca bazı ilaçların potansiyel olarak tehlikeli seviyelerini tespit edebilir (Wagner, 2013).

EKG, bazı KY hastalarında belirli bir tanıya yardımcı ipuçları sağlayabilir. Özellikle orta yaşlı ve yaşlı hastalarda belirgin Q dalgaları ve tipik ST-T değişiklikleri, altta

yatan yaygın enfarktüsle birlikte altta yatan iskemik kalp hastalığını düşündürür (Goldberger ve Goldberger, 2018).


Kalp ile ilgili bu denli bilgiler içeren EKG işareti, bu tez çalışması kapsamında DEF-KY ve KEF-KY vakalarının tanısında kullanılmıştır.

3.1.4. EKG için dijital filtreleme


EKG ile yapılan çalışmaya ait iş akış diyagramı Şekil 3.5.'te görülmektedir. Çalışma bu akışa göre yapılmış ve sonuçlar elde edilmiştir. Gönüllülerden veriler alındıktan sonra uzman kardiyolog tarafından etiketleme yapılmıştır. Veriler üzerindeki gürültüleri ve artefaktları temizlemek için dijital filtreler kullanılmıştır. Bu aşamada sinyale 0.25 – 100 Hz aralığında Chebyshev Tip II band geçiren filtre uygulanmıştır. Bu filtre için durdurma bandı zayıflaması 60 dB olarak belirlendi. İkinci aşama olarak, 50 Hz'deki şebeke gürültüsünü temizlemek için sinyale 49 – 51 Hz aralığında çentik filtre uygulanmıştır. Bu filtre için de durdurma bandı zayıflaması 60 dB olarak belirlendi. Son olarak Hareketli Ortalama (Moving Average) filtresi uygulanmıştır. Filtrelenmemiş ham EKG ile filtreleme sonrası elde edilen EKG örneği Şekil 3.6'da görülmektedir.

Chebyshev filtre, durdurma bandında daha keskin inişli olması, bazı filtrelerle kıyasla daha küçük mutlak hataya sebep olması ve daha hızlı performansı sebebiyle tercih edilmiştir (Laghari ve ark., 2014; Sandhu ve Kaur, 2016; Yavuz ve ark., 2007). Filtrelemeye 0.25 Hz ile başlanma nedeni, sinyaldeki DC bileşenleri elimine etmektir.


Yüksek frekanslı bileşen içeren EKG sinyalleri için gürültü arındırma yöntemlerinden biri de Moving Average filtreleridir (Pandey ve Giri, 2016; Vidya ve Sadasiv, 2013). Filtrelenmiş EKG sinyalini yumuşatmak için polinom eğrisi uydurma işlemidir (Aramendi ve ark., 2005). Filtreleme sonucu elde edilen dalga formları, şekil ve maksimum-minimum (QRS ve ST-T seviyesi) gibi tıbbi bilgilerini korur (Pandey ve Giri, 2016). Örneğin Şekil 3.7'de görüldüğü gibi, EKG sinyalinin tepe noktaları bulunmak istenildiğinde, küçük genlikli işaretlerden dolayı yanlış tepe noktaları bulunabilmektedir (Uçar, 2017). Bu da Moving Average filtre kullanmak için geçerli bir sebeptir.



Şekil 3.5. EKG ile yapılan çalışmaya ait iş akış diyagramı.




Şekil 3.6. Filtrelenmeden önce ve filtrelendikten sonra EKG sinyali.



Şekil 3.7. Moving Average Filtre Etkisi (Uçar, 2017).

DEF-KY, sağlıklı ve KEF-KY bireylerin EKG'lerinin grafiksel gösterimi Şekil 3.8'de verilmiştir. Ayrıca EKG'lerin Hızlı Fourier Dönüşümleri ile periodogram grafiği de şekilde verilmiştir. EKG'ler birbirlerine çok benzemesine rağmen periodogramda aralarındaki fark belirgin bir şekilde görülmektedir. Bu nedenle, periodogram kullanmak, makine öğrenimi yöntemleri için faydalı bir yoldur.



Şekil 3.8. EKG'ye ait periodogram grafiği.

3.2. Fotopletismografi Sinyali ve Ondan Türetilen Kalp Hızı Değişkenliği

Fotopletismografi (PPG), eskiden beri var olsa da, günümüzde kullanıldığı yeni alanlar sebebiyle popülerliği artmış bir yöntemdir. Özellikle nabız sayısını ölçmek için sağlık sektöründe kullanılan yöntem, ilk olarak 1938 yılında nabız ölçmek için Hertzman tarafından kullanılmıştır ve yöntemin geçerliliği kanıtlanarak günümüzde de kullanılmaktadır (Challoner ve Ramsay, 1974). Vücudumuzun önemli fizyolojik işaretlerinden biri olan nabız, hekimler tarafından hastanın fizyolojik durumu ile ilgili karar vermek için kullanılır. Örneğin, dinlenme halindeki yüksek nabız, bağımsız bir kardiyovasküler risk faktörü olarak belirtilmiştir (Cook ve ark., 2006).

Nabız ölçmek için, altın standart olan EKG'den başka, en sık kullanılan bir diğer yöntem de PPG'dir. Kan basıncı, nabız ve oksijen saturasyonu gibi parametreleri ölçmede kullanılan PPG, deri üzerindeki ışık şiddeti değişimlerini gözlemlemeye dayalı optik bir tekniktir (Bal ve Bal, 2015).

Kalp hızı değişkenliğinin (KHD) basit temeli, kalp atımları arasında geçen sürenin değişmesidir. KHD, örneğin EKG, nabız dalgaları, kalp tonları veya benzer yöntemlerle farklı şekillerde ölçülebilir. Pratikte en uygun yöntem, EKG'deki QRS mesafelerini milisaniye cinsinden ölçmektir (Ernst, 2014). KHD genellikle EKG'den türetilse de, PPG'den de türetilebileceği gösterilmiştir (Jeyhani ve ark., 2015).

KKY'li hastalarda azalmış KHD fikrinin artık yerleşmiş olduğu varsayılabilir. Farklı KHD belirteçlerinin hem kötüleşme hem de ölüm için öngörücü bir değere sahip olduğu defalarca gösterilmiştir (Ernst, 2014). KHD ile KY arasındaki bu tür bağlantılar nedeniyle, bu tez çalışmasında KY alt tiplerinin tanısı için PPG'den türetilen KHD'nin kullanılabileceği düşünülmüştür.

3.2.1. Fotopletismografi sinyali

Modern nabız oksimetresinde görüntülenen dalga biçimi, zaman içinde yerel doku tarafından ışık absorpsiyonunun yükseltilmiş ve çok iyi filtrelenmiş bir ölçümüdür. Fizyolojik olarak, kardiyovasküler, solunum ve otonomik sistemler arasındaki karmaşık ve iyi anlaşılmamış bir etkileşimin sonucudur. Yeni fizyolojik parametreler geliştirmek için geliştirilmiş sayısal sinyal işleme yöntemlerini kullanarak PPG'yi analiz etmek için araştırma çalışmaları devam etmektedir (Alian ve Shelley, 2014).


PPG, vücudun parmak ucu, kulak memesi gibi cilde yakın bölgelerinde kan akışının hacimsel değişimlerine bağlı olarak kan basıncı, nabız ve oksijen saturasyonu gibi parametrelerle ilgili bilgi sağlayan noninvaziv, elektrooptik bir metottur (Kavsaoglu, 2014).

PPG sinyalinin alternatif akım (AC) ve doğru akım (DC) bileşenleri vardır. Işığın kas, kemik ve deriden yansıyan kısmı DC bileşendir. AC bileşen, damarlardaki yansımalar sonucunda meydana gelir. PPG sinyalinin %99'u kas, kemik ve deriden, %0,9'u toplardamardan, %0,1'i de atardamarlardan gelir (Kavsaoglu, 2014).


Şekil 3.9, DC ve AC bileşenlerden oluşan bir fotopletismografik dalga biçimi örneğini göstermektedir. PPG dalga formunun DC bileşeni, dokudan algılanan iletilen veya yansıtılan optik sinyale karşılık gelir ve dokunun yapısına ve hem arteriyel hem de venöz kanın ortalama kan hacmine bağlıdır. DC bileşeninin solunumla yavaşça değiştiğine dikkat edin. AC bileşen, kalp döngüsünün sistolik ve diyastolik fazları arasında meydana gelen kan hacmindeki değişiklikleri gösterir; AC bileşeninin temel frekansı kalp atış hızına bağlıdır ve DC bileşeninin üzerine bindirilir (Tamura ve ark., 2014).

Şekil 3.10'da gösterildiği gibi, PPG'nin iletim ve yansıma olmak üzere iki modu vardır. PPG ölçme düzeneği temel olarak, dalga boyu bilinen bir ışık göndermek için kullanılan bir LED ve ışığın dokular tarafından soğurulmasının ardından kalan ışığı tespit etmek için bir fotodedektör (FD) olmak üzere iki kısımdan oluşur. LED ve

FD'nin konumları PPG modunu belirler; ikisi de aynı tarafta ise yansıma modu, farklı tarafta ise iletim modu denir (Uçar, 2017).



Şekil 3.9. Doku tarafından ışık Emilimi (Tamura ve ark., 2014).



Şekil 3.10. PPG ölçümü için modlar (Tamura ve ark., 2014).


Dikrotik çentik, aort kapağı kapandığında ortaya çıkan arteriyel kan basıncında küçük ve kısa bir artıştır. Bu işarete, arteriyel dalga formunun (özellikle aort ve ön kol damarlarının) tanımlayıcı analizinde yaygın olarak atıfta bulunulmuştur ve genel olarak sistol sonu sol ventrikül basıncının bir eşdeğeri olarak kullanılır (Dahlgren ve ark., 1991; He'bert ve ark., 1995). PPG ile sol ventrikül basıncının bu ilişkisi sebebiyle, bu tez çalışması kapsamında DEF-KY ve KEF-KY tanısı için PPG'nin kullanılabileceği düşünülmüştür.

Bu tez çalışmasında kullanılan PPG ve EKG verileri, eş zamanlı olarak, Şekil 3.11’de görülen Biopac MP36 cihazı ile kaydedilmiştir. Sinyallerin örnekleme frekansı 200 Hz’dir.



Şekil 3.11. Biopac MP36 cihazı.

Şekil 3.12’de DEF-KY, sağlıklı ve KEF-KY olan bireylerin PPG örnekleri grafik olarak verilmiştir. Ayrıca, PPG’lerin Hızlı Fourier Dönüşümü ile periodogram grafiği de gösterilmektedir. PPG’ler birbirine çok benzerken, periodogramda aralarındaki fark belirgin şekilde görülmektedir.




Şekil 3.12. PPG’ye ait periodogram grafiği.

3.2.2. Kalp hızı değişkenliği

KHD, kalp atımları arasındaki sürelerin incelenmesiyle elde edilir. Uyku, rahatlama, dinlenme ve stres gibi durumlarda dış uyaranlara bağlı olarak otonom sinir sistemi tarafından sürekli ayarlanır.

Şekil 3.13'te EKG ve PPG'den türetilen KHD görülmektedir. Şekilden de görüldüğü üzere KHD dizisinin bileşenlerini, bu sinyallerin tepe noktaları arasında geçen süreler oluşturur. KHD birimi saniye (ya da milisaniye)dir.



Şekil 3.13. EKG ve PPG'den türetilen KHD.


KHD ölçümü için prensip olarak, nabız oksimetresi, parmak arteriyel kan basıncı (KB), invaziv KB ölçümü gibi kalp atışını veya sonuçlarını (örneğin nabız) ölçebilen herhangi bir cihaz kullanılabilir. Gerçekte, çoğu ticari KHD cihazı EKG sinyallerini kaydeder ve QRS mesafelerini milisaniye cinsinden kodlar. Bunlar daha sonra farklı özellikleri hesaplamak için ardışık olarak kullanılır (Ernst, 2014).

3.2.3. PPG için dijital filtreleme


Tez kapsamında PPG ve KHD ile yapılan çalışmaya ait iş akış diyagramı Şekil 3.14'te görülmektedir. Çalışmada bu akış takip edilmiş ve sonuçlar elde edilmiştir. Gönüllülerin sağ el işaret parmağından PPG verileri 10 s süreyle alınmıştır. Aynı gönüllülerden alınan farklı zaman aralıklarındaki veriler de veri setine dahil edilmiştir. Veri setinde 60'ı DEF-KY, 60'ı sağlıklı ve 60'ı KEF-KY olmak üzere toplam 180 veri bulunmaktadır. PPG sinyalleri de Matlab FDATool ile tasarlanan dijital filtreler ile filtrelenmiştir.

Filtreleme adımında veriler öncelikle Chebyshev Tip II band durduran filtre ile 0.25 Hz – 100 Hz aralığında filtrelenmiştir. Durdurma bandı zayıflaması 60 dB olarak

belirlenmiştir. 50 Hz şebeke gürültüsünü elimine etmek için 49 Hz – 51 Hz aralığında çentik filtre uygulanmıştır. Çentik filtre için de durdurma bandı zayıflaması 60 dB olarak belirlenmiştir. Son olarak yüksek frekanslı bileşenleri ve gürültüyü elimine etmek için Moving Average (Hareketli Ortalama) filtresi uygulanmıştır. Filtreleme öncesi ve sonrası PPG sinyali örneği Şekil 3.15’de görülmektedir.



Şekil 3.14. PPG ve KHD ile yapılan çalışmanın iş akış diyagramı.



Şekil 3.15. Filtrelenmeden önce ve filtrelendikten sonra PPG sinyali.

3.2.4. Kalp Hızı Değişkenliğinin PPG'den Türetilmesi

Sağlıklı kalbin atışı tam olarak düzenli değildir. Egzersiz, fiziksel ve zihinsel stres dahil olmak üzere birçok faktörün etkisiyle değişir. Ek olarak, normal sinüs atımları arasındaki aralıklar, solunum, kan basıncının düzenlenmesi, sirkadiyen ritimler ve diğer bilinmeyen faktörler nedeniyle periyodik olarak değişir. Bu tür periyodik ritimler aslında KHD'nin en etkili kaynağıdır (Stein ve ark., 1994). Psikososyal çevre de dahil olmak üzere çevreye yönelik davranış ve tepkilerin, uzun süreli KHD'de önemli bir rol oynadığı kabul edilmektedir.

KHD, kardiyak otonomik modülasyonların tahmini için kullanılan bir araçtır. Son yıllarda yapılan bazı çalışmalar KHD kullanımını üç alanda ilerletmiştir: 1) EKG işleme ve KHD değerlendirmesinin teknik aşamalarında, 2) fizyolojik anlama ve yorumlamada ve 3) klinik ve pratik kullanımda (Ernst, 2014).

KHD sempatik ve parasempatik sistem arasındaki dengeye bağlıdır. KHD sağlıklı kişilerde hasta bireylere göre daha yüksektir ve bu da sağlıklı kişilerin otonom kontrol mekanizmasının iyi çalıştığının önemli bir göstergesidir (Çevik ve ark., 2010). KHD'nin azalması birçok hastalık için kötü sonuçların güçlü bir göstergesidir (Ewing ve ark., 1980; Kleiger ve ark., 1987; Malliani ve ark., 1994).


Bununla birlikte, son yıllarda yapılan çalışmalar KHD'nin yakın zaman için risk tahmini ve KKY'de hastalık ilerlemesinin izlenmesi ve kalp transplantasyonundan

sonra izleme veya yeniden innervasyon için benzer şekilde güçlü bir araç haline gelebileceğini göstermektedir (Ernst, 2014).

Akut miyokard enfarktüsünden (MI) sağ kalanlar arasında, azalan KHD'nin hem ölümü hem de aritmik olayları sol ventrikül ejeksiyon fraksiyonu gibi geleneksel öngörücülerden daha yüksek duyarlılık ve özgüllük ile öngördüğü gösterilmiştir (Bigger ve ark., 1992; Farrell ve ark., 1991).

Bu tez çalışmasında PPG'den elde edilen KHD örneği Şekil 3.16'da görülmektedir. KHD türetilmesi için PPG sinyalinin yerel maksimum noktaları (P_1, P_2, P_3, P_4, P_5) tespit edilmiş ve şekil üzerinde işaretlenmiştir. Elde edilen KHD dizi elemanları ($KHD_1, KHD_2, KHD_3, KHD_4$) da şekil üzerinde işaretlenmiştir.

KHD türetilmesi için yerel maksimum noktalarının bulundukları konumların x eksenindeki değerler ile işlem yapılır. Örneğin P_1 noktasının koordinatları [83, 6.0966] ve P_2 noktasının koordinatları [285, 6.5055]'tir. P_1 ve P_2 noktaları arasında KHD_1 'i hesaplamak için P_1 noktasının x eksen değeri olan 83 ($X_{P_1} = 83$) ve P_2 noktasının x eksen değeri olan 285 ($X_{P_2} = 285$) kullanılır.




Şekil 3.16. PPG ve PPG'den Türetilen KHD örneği.

PPG'nin yerel maksimum noktaları n adet ve $i = 1, 2, 3, \dots (n-1)$ olmak üzere, KHD dizisinin elemanları denklem 3.1'deki gibi hesaplanabilir. KHD dizisinin eleman sayısı $(n-1)$ adettir. KHD_1 için hesaplama örneği denklem 3.1'de görülmektedir.

$$KHD_i = \frac{X_{P_{i+1}} - X_{P_i}}{f_s} \rightarrow KHD_1 = \frac{X_{P_2} - X_{P_1}}{200} = \frac{285 - 83}{200} = 1.01 s \quad (3.1)$$

KKY hastalarında KHD'nin hem zaman hem de frekans alanı ölçümlerinin, normallerdeki KHD'ye kıyasla belirgin şekilde azaldığı gösterilmiştir (Stein ve ark., 1994).


Bu tez çalışması kapsamında kullanılan veri setinde KKY'nin alt tipleri olan DEF-KY ve KEF-KY hasta sınıfları ve sağlıklı sınıfı bulunmaktadır. Bu üç sınıf için elde edilen KHD dizilerinin örneği Şekil 3.17'de görülmektedir. Sağlıklı bireylerin KHD değerleri en yüksek değişkenlik genliklerine sahiptir. KEF-KY olan hastaların KHD değerleri sağlıklı olanlara göre biraz daha düşüktür. DEF-KY olan hastalarda ise, diğer iki sınıfla kıyaslandığında KHD değerleri belirgin bir şekilde düşüktür.




Şekil 3.17. DEF-KY, KEF-KY ve Sağlıklı KHD Dizileri.

Literatürde DEF-KY ve KEF-KY ikili sınıflandırması için PPG ile yapılan bir çalışma bulunmadığı için, tez kapsamında bu ikili sınıflandırma çalışması da yapılmıştır. Sadece KHD özellikleri kullanılarak ve yüksek doğruluk sağlayan bu sınıflandırma çalışmasının sonuçları Bölüm 6'da detaylı olarak verilecektir. Çalışmaya ait akış diyagramı Şekil 3.18'de görülmektedir.

Bu ikili sınıflandırma çalışması için, PPG sinyallerine ait periodogram grafiği Şekil 3.19'da görülmektedir. PPG sinyalleri birbirine çok benzemelerine rağmen, iki sınıfın aralarındaki fark periodogramda net olarak görülmektedir.



Şekil 3.18. KHD ile yapılan ikili sınıflandırma çalışmasına ait akış diyagramı.



Şekil 3.19. DEF-KY ve KEF-KY ikili sınıflandırması için PPG'ye ait periodogram grafiği.

4. KULLANILAN VERİ SETİ, ÖZELLİK ÇIKARMA VE ÖZELLİK SEÇME

4.1. Kullanılan Veri Seti

4.1.1. Gönüllülerden veri toplanması

Tez çalışmasında kullanılacak veriler için Sakarya Üniversitesi Tıp Fakültesi Dekanlığından 16214662/050.01.04/123 numaralı etik kurul raporu alınmıştır. Akabinde, Sakarya Üniversitesi Eğitim ve Araştırma Hastanesi Kardiyoloji Bölümüne muayene için gelenlerden ve yatan hasta servisindeki bireylerden veriler alınmıştır.

Verileri toplamak ve kaydetmek için Biopac MP36 cihazı kullanılmıştır. Örneklem frekansı 200 Hz'dir. Veriler, ekokardiyografik sonuçları uzman bir kardiyolog tarafından yorumlanan ve çalışmaya dahil edilmeye uygun olan bireylerden elde edilmiştir. 25 yaş ve üzeri gönüllülerden EKG ve PPG verileri eş zamanlı olarak, dinlenme durumunda (sırt üstü yatar durumda) alınmıştır.

Tez çalışmasında EKG sinyali, PPG sinyali ve PPG'den türetilmiş KHD verileri kullanılmıştır. PPG'den KHD türetilmesi Bölüm 4'te anlatılmıştır. Kullanılan tüm verilerden çıkarılan özellikler Bölüm 6'da anlatılacaktır.

4.1.2. EKG ile yapılan çalışmanın veri seti

Tez kapsamında EKG ile yapılan üçlü sınıflandırma çalışması için 61 gönüllüden sağ el bileği, sağ ve sol ayak bileği olmak üzere üç kablolu (Bipolar DII) EKG verileri alınmıştır. Aynı gönüllüden alınan farklı zaman aralıklarındaki veriler de veri setine dahil edilmiştir. 10 s'lik EKG verileri kullanılmıştır. Veri setinde 60'ı DEF-KY, 60'ı sağlıklı ve 60'ı KEF-KY olmak üzere toplam 180 veri bulunmaktadır. Gönüllülere ait demografik bilgiler ortalamaları ve standart sapmaları ile Tablo 4.1'de verilmiştir. Dijital filtreleme işlemi Matlab FDATool ile tasarlanan filtrelerle yapılmıştır.

Tablo 4.1. Demografik Bilgiler.

Gruplar	Yaş (yıl)	Kilo (kg)	Boy (cm)	VKİ (kg/m ²)
Erkekler (Ort ± SS)	65.18 ± 12.13	78.39 ± 13.22	170.72 ± 6.07	26.88 ± 4.35
Kadınlar (Ort ± SS)	67.78 ± 15.67	75 ± 22.21	157.71 ± 7.08	39.26 ± 13.07
Toplam (Ort ± SS)	66.37 ± 13.80	76.83 ± 17.83	164.75 ± 9.21	34.72 ± 12.26

4.1.3. PPG ve KHD ile yapılan çalışmanın veri seti

PPG verileri gönüllülerin sağ el işaret parmağından alınmıştır. EKG ve PPG verileri aynı gönüllülerden eş zamanlı alındığı için, PPG ve KHD ile yapılan üçlü sınıflandırma çalışmasına veri sağlayan gönüllülere ait demografik bilgiler tablo 5.1’dedir. Veri setinde 10 s’lik PPG verileri kullanılmıştır.

4.1.4. KHD ile yapılan çalışmanın veri seti

Yalnızca PPG’den türetilen KHD özelliklerinin kullanıldığı DEF-KY ve KEF-KY ikili sınıflandırma çalışması için kullanılan veri seti 60’ı DEF-KY ve 60’ı KEF-KY olmak üzere toplam 120 veri içermektedir. Çalışmada kullanılan verileri sağlayan gönüllülere ait demografik bilgiler Tablo 4.2’de görülmektedir.

Tablo 4.2. KHD ile yapılan çalışmadaki gönüllülere ait demografik bilgiler.

Gruplar	Yaş (yıl)	Kilo (kg)	Boy (cm)	VKİ (kg/m ²)
Erkekler (Ort ± SS)	67.2 ± 12.32	75.75 ± 10.93	172.6 ± 5.98	23.38 ± 2.94
Kadınlar (Ort ± SS)	72.18 ± 12.81	69.09 ± 29.27	158.18 ± 6.03	27.56 ± 11.3
Toplam (Ort ± SS)	68.97 ± 12.52	73.39 ± 19.28	167.48 ± 9.16	26.15 ± 7.01

4.2. Özellik Çıkarma ve Özellik Seçme

Tez çalışmasında kullanılan EKG, PPG ve KHD verilerinden çıkarılan özellikler bu bölümde anlatılacaktır. Özellik çıkarma işleminin adımları tüm veriler için aynıdır. Yani hem EKG, hem PPG hem de KHD için aynı özellikler çıkarılmıştır.

Tez kapsamında EKG ile ayrı bir tanı algoritması çalışması, PPG ve KHD’yi birlikte kullanarak ayrı bir tanı algoritması çalışması ve sadece KHD kullanarak ikili sınıflandırma çalışması yapılmıştır. Yani üç farklı çalışma yapılmıştır, ancak, çıkarılan özellikler aynı olduğu için bu bölümde birlikte anlatılmaktadır.

4.2.1. Özellik çıkarma

Literatürde daha önce EKG ve PPG sinyallerinden çıkarılmış ve çeşitli hastalık teşhisi için kullanılmış olan özellikler çıkarılmıştır (Uçar ve ark., 2018; Bozkurt ve ark., 2019). Verilerden elde edilen 21 adet zaman domenindeki özellikler Tablo 4.3’te verilmiştir. Bu özellikleri hesaplamak için de Matlab kullanılmıştır. Tabloda ilk sütunda özelliklere verilen numaralar, ikinci sütunda özelliklerin isimleri ve üçüncü sütunda özelliklerin denklemleri ya da Matlab fonksiyonları verilmiştir.

Tablo 4.3. Çalışmada verilerden çıkarılan zaman domenindeki özellikler.

No	Özellik	Denklem
1	Basıklık (Kurtosis)	$x_{kur} = \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{(n-1)S^4}$
2	Çarpıklık (Skewness)	$x_{ske} = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)S^3}$
3	*Çeyrekler Arası Açıklık (Interquartile range)	$IQR = iqr(x)$
4	Geometrik Ortalama	$G = (x_1 + \dots + x_n)^{1/n}$
5	Harmonik Ortalama	$H = n / (\frac{1}{x_1} + \dots + \frac{1}{x_n})$
6	Hareketlilik – Hjort Parametreleri	$M = S_1^2 / S^2$
7	Karmaşıklık – Hjort Parametreleri	$C = ((S_2^2 / S_1^2)^2 - (S_1^2 / S^2)^2)^{1/2}$
8	Aktivite – Hjort Parametreleri	$A = S^2$
9	*Maksimum	$x_{max} = \max(x_i)$
10	Medyan	$\tilde{x} = \begin{cases} x_{\frac{n+1}{2}} & : x \text{ tek} \\ \frac{1}{2} \left(x_{\frac{n}{2}} + x_{\frac{n}{2}+1} \right) & : x \text{ çift} \end{cases}$
11	*Ortalama Mutlak Sapma (Mean Absolute Deviation)	$MAD = mad(x)$
12	*Minimum	$x_{min} = \min(x_i)$
13	*Merkezi Momentler	$CM = moment(x, 10)$
14	Ortalama	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$
15	Ortalama Eğri Uzunluğu	$CL = \frac{1}{n} \sum_{i=2}^n x_i - x_{i-1} $
16	Standart Sapma	$S = \left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^{1/2}$
17	Standart Hata	$S_{\bar{x}} = S / \sqrt{n}$
18	Şekil Faktörü	$SF = X_{rms} / \left(\frac{1}{n} \sum_{i=1}^n \sqrt{ x_i } \right)$
19	* Tekil Değer Ayrışımı (Singular Value Decomposition)	$SVD = svd(x)$
20	*%25 Kırılmış Ortalama	$TM25 = trimmean(x, 25)$
21	*%50 Kırılmış Ortalama	$TM50 = trimmean(x, 50)$

*Bu özellik Matlab fonksiyonu ile hesaplanmıştır.

$\bar{x}$: dağılımın ortalaması

n : örneğin gözlem sayısı

S_1 : sinyalin birinci türevinin standart sapması

S_2 : sinyalin ikinci türevinin standart sapması

X_{rms} : Karekök Ortalama $X_{rms} = \left(\frac{1}{n} \sum_{i=1}^n |x_i|^2 \right)^{1/2}$

Daha sonra 16 adet Yule –Walker ve Burg Metodu parametreleri de özellik olarak bu 21 özelliğe eklenmiştir. Yani, EKG, PPG ve KHD verilerinin her birinden 37’şer özellik çıkarılmıştır.

Yule-Walker metodu için aşağıdaki Matlab fonksiyonu kullanılmıştır.

$$[a,e,rc] = \text{aryule}(x,p)$$

Bu fonsiyon x girdi dizisi için p dereceli bir modele karşılık gelen normalleştirilmiş otoregresif (AR) parametreleri (a) hesaplar. Ayrıca beyaz gürültü girişinin tahmini varyansını (e) ve yansıma katsayılarını (rc) döndürür.

Burg metodu için aşağıdaki Matlab fonksiyonu kullanılmıştır.

$$[a,e,rc] = \text{arburg}(x,p)$$

Bu fonsiyon da x girdi dizisi için p dereceli bir modele karşılık gelen normalleştirilmiş otoregresif (AR) parametreleri (a) hesaplar. Ayrıca beyaz gürültü girişinin tahmini varyansını (e) ve yansıma katsayılarını (rc) döndürür.

Burg metodunda, p . dereceden modele karşılık gelen AR parametreleri 4.1 nolu ifadedeki gibi hesaplanır (Bozkurt, 2007).

$$a_{p,i} = \begin{cases} a_{p-1,i} + rc_p a^*_{p-1,p-i}, & i = 1 \dots p-1 \\ rc_p, & i = p \end{cases} \quad (4.1)$$

Yansıma katsayıları için 6.2 nolu ifade kullanılır.

$$rc_p = \frac{-2 \sum_{n=p+1}^N e_{f,p-1}(n) e_{b,p-1}^*(n-1)}{\sum_{n=p+1}^N [|e_{f,p-1}(n)|^2 + |e_{b,p-1}^*(n-1)|^2]} \quad (4.2)$$

Hata için ise 6.5 nolu ifade kullanılır.

$$e_{f,p}(n) = x(n) + \sum_{i=1}^p a_{p,i} x(n-i) \quad n = p+1, \dots N \quad (4.3)$$

$$e_{b,p}(n) = x(n-p) + \sum_{i=1}^p a_{p,i}^* x(n-p+i) \quad n = p+1, \dots N \quad (4.4)$$

$$e_p = e_{f,p} + e_{b,p} \quad (4.5)$$

Yule-Walker metodu için, parametreler aşağıdaki ifadeler ile hesaplanır (Bozkurt, 2007).

$$\begin{bmatrix} r_x(0) & r_x^*(1) & r_x^*(2) & \dots & r_x^*(p) \\ r_x(1) & r_x(0) & r_x^*(1) & \dots & r_x^*(p-1) \\ r_x(2) & r_x(1) & r_x(0) & \dots & r_x^*(p-2) \\ \vdots & \vdots & \vdots & \dots & \vdots \\ r_x(p) & r_x(p-1) & r_x(p-2) & \dots & r_x(0) \end{bmatrix} \begin{bmatrix} 1 \\ a_p(1) \\ a_p(2) \\ \vdots \\ a_p(p) \end{bmatrix} = \epsilon_p \begin{bmatrix} 1 \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (6.6)$$

$$rc(k) = r_x(k) = \frac{1}{N} \sum_{n=0}^{N-1-k} x(n+k)x^*(n) \quad k = 0, 1, \dots, p \quad (6.7)$$

$$\epsilon_p = r_x(0) + \sum_{k=1}^p a_p(k)r_x^*(k) \quad (6.8)$$

Tez çalışmasında kullanılan özellikler için Yule-Walker ve Burg metodlarının ikisi için de 4. dereceden modele karşılık gelen AR parametreleri kullanılmıştır.

21 özellikten sonra elde edilen 16 özellik de genel sıralama numaraları ile Tablo 4.4'te görülmektedir.

Tablo 4.4. Özellik olarak kullanılan Yule-Walker ve Burg metodu parametreleri.

No	Özellik	Simge
22	Yule-Walker metodu 4. dereceden modelin 1. AR parametresi	$a_4(1)$
23	Yule-Walker metodu 4. dereceden modelin 2. AR parametresi	$a_4(2)$
24	Yule-Walker metodu 4. dereceden modelin 3. AR parametresi	$a_4(3)$
25	Yule-Walker metodu 4. dereceden modelin 4. AR parametresi	$a_4(4)$
26	Yule-Walker metodu 4. dereceden modelin beyaz gürültü girişinin tahmini varyansı	ϵ_p
27	Yule-Walker metodu 4. dereceden modelin 1. Yansıma katsayısı	$rc(1)$
28	Yule-Walker metodu 4. dereceden modelin 2. Yansıma katsayısı	$rc(2)$
29	Yule-Walker metodu 4. dereceden modelin 3. Yansıma katsayısı	$rc(3)$
30	Burg metodu 4. dereceden modelin 1. AR parametresi	$a_{4,1}$
31	Burg metodu 4. dereceden modelin 2. AR parametresi	$a_{4,2}$
32	Burg metodu 4. dereceden modelin 3. AR parametresi	$a_{4,3}$
33	Burg metodu 4. dereceden modelin 4. AR parametresi	$a_{4,4}$
34	Burg metodu 4. dereceden modelin beyaz gürültü girişinin tahmini varyansı	e_p
35	Burg metodu 4. dereceden modelin 1. Yansıma katsayısı	rc_1
36	Burg metodu 4. dereceden modelin 2. Yansıma katsayısı	rc_2
37	Burg metodu 4. dereceden modelin 3. Yansıma katsayısı	rc_3

4.2.2. Özellik seçme

4.2.2.1. EKG ile yapılan çalışma için özellik seçme

EKG normal dağılım göstermediği için parametrik olmayan yöntemler kullanılarak istatistiksel olarak incelenebilir. Üç veya daha fazla sınıf olduğunda ve veriler normal dağılım göstermediğinde Kruskal Wallis testi tercih edilir. Bu test, tek yönlü ANOVA'nın parametrik olmayan versiyonudur (McKnight ve Najab, 2010). Bu test, veri setindeki DEF-KY, sağlıklı, ve KEF-KY sınıfları arasında, çıkarılan özellikler açısından belirgin bir fark olup olmadığını araştırmak için kullanılmıştır. Her bir özellik için Kruskal Wallis testi sonucunda elde edilen asimptotik önemler (p değerleri) Tablo 4.5'te verilmiştir.

Tablo 4.5. Kruskal Wallis testi sonucu EKG özelliklerine ait p değerleri.

Özellik No	p değeri	Özellik No	p değeri
1	0.8337	20	0.0000
2	0.0000	21	0.0000
3	0.1095	22	0.6501
4	0.0847	23	0.7135
5	0.8753	24	0.9343
6	0.0007	25	0.9771
7	0.0000	26	0.1214
8	0.1583	27	0.0009
9	0.0014	28	0.0000
10	0.0000	29	0.1137
11	0.1784	30	0.0000
12	0.0107	31	0.0000
13	0.0464	32	0.0002
14	0.7619	33	0.1116
15	0.0261	34	0.0000
16	0.1583	35	0.0007
17	0.1583	36	0.0000
18	0.1457	37	0.0000
19	0.1574		

Tabloya göre 2, 6, 7, 9, 10, 12, 13, 15, 20, 21, 27, 28, 30, 31, 32, 34, 35, 36, 37 özellikleri için $p < 0.05$ 'tir. Yani, bu özellikler karşılaştırılan üç sınıftan en az ikisi için ayırt edicidir.

Mann Whitney U testi, örneklenen iki grubun aynı popülasyondan olup olmadığını belirlemek için kullanılan parametrik olmayan bir testtir (McKnight ve Najab, 2010). Kruskal Wallis testi sonucunda ayırt edici görünen özelliklerin sadece belirli ikili sınıflar için mi yoksa her üç sınıf için mi ayırt edici olduğunu belirlemek için ikili

Mann Whitney-U testleri post-hoc testler olarak yapılmıştır. Mann-Whitney U test sonuçları Tablo 4.6, 4.7 ve 4.8'de verilmiştir. Bu tablolarda özellikler sıralanmıştır.

Tablo 4.6. DEF-KY ve Sağlıklı sınıfları için ikili Mann Whitney U test sonuçları.

Özellik No	R (ETA)	R ²	p değeri
2	0.2932	0.0860	0.0004
36	0.2136	0.0456	0.0029
12	0.1960	0.0384	0.0389
7	0.1835	0.0337	0.0333
20	0.1781	0.0317	0.0035
21	0.1758	0.0309	0.0131
9	0.1734	0.0301	0.9686
6	0.1580	0.0250	0.1482
10	0.1527	0.0233	0.0269
35	0.1482	0.0220	0.1497
27	0.1468	0.0215	0.1497
30	0.1320	0.0174	0.0765
28	0.1294	0.0168	0.0967
31	0.1014	0.0103	0.2345
13	0.0918	0.0084	0.5906
15	0.0907	0.0082	0.4235
32	0.0642	0.0041	0.4174
37	0.0524	0.0027	0.7548
34	0.0518	0.0027	0.4265

Tablo 4.7. DEF-KY ve KEF-KY sınıfları için ikili Mann Whitney U test sonuçları.

Özellik No	R (ETA)	R ²	p değeri
37	0.5576	0.3109	0.0000
2	0.3790	0.1437	0.0000
31	0.3381	0.1143	0.0002
30	0.3347	0.1121	0.0000
35	0.3280	0.1076	0.0002
27	0.3233	0.1045	0.0002
32	0.3144	0.0989	0.0053
6	0.2974	0.0884	0.0002
28	0.2668	0.0712	0.0056
34	0.1362	0.0186	0.0001
36	0.2350	0.0552	0.0235
7	0.1986	0.0395	0.0235
12	0.1218	0.0148	0.1976
9	0.0860	0.0074	0.0199
15	0.0839	0.0070	0.0420
10	0.0666	0.0044	0.0765
13	0.0405	0.0016	0.0837
20	0.0278	0.0008	0.0208
21	0.0236	0.0006	0.0464

Tablo 4.8. KEF-KY ve Sağlıklı sınıfları için ikili Mann Whitney U test sonuçları.

Özellik No	R (ETA)	R ²	p değeri
2	0.6123	0.3750	0.0000
37	0.5713	0.3264	0.0000
30	0.5244	0.2750	0.0000
36	0.5075	0.2575	0.0000
31	0.4578	0.2096	0.0000
7	0.4171	0.1740	0.0000
28	0.3995	0.1596	0.0000
34	0.3870	0.1497	0.0000
32	0.3581	0.1283	0.0000
10	0.2605	0.0679	0.0000
21	0.1885	0.0355	0.0000
12	0.1799	0.0324	0.0055
20	0.0946	0.0089	0.0000
13	0.0917	0.0084	0.0108
9	0.0552	0.0030	0.0001
15	0.0242	0.0006	0.0131
6	0.1555	0.0242	0.0181
35	0.1718	0.0295	0.0202
27	0.1690	0.0286	0.0242

Üç sınıfın her birinin kendi hata yüzdesi olduğundan, 0.05 değeri 3'e bölünür (0.0167) (Buna Bonferroni düzeltmesi denir.) (Haynes, 2013). İlgili özellik için Mann Whitney-U testi sonucu $p < 0.0167$ olduğunda, özelliğin o ikili grup için ayırt edici olduğu söylenir. Yani, örneğin, Tablo 4.8'de 2, 7, 9, 10, 12, 13, 15, 20, 21, 28, 30, 31, 32, 34, 36 ve 37 özellikleri için $p < 0.0167$ olduğundan dolayı KEF-KY ve Sağlıklı ikili sınıflandırması için bu özellikler ayırt edicidir.

Daha sonra en alakalı olanlardan farklı sayıda özellik girdi olarak alınmış ve deneyler yapılmıştır. Daha az özellik / daha yüksek doğruluk ilişkisinde optimum değer belirlenmiştir. Sonuç olarak, 2., 32., 36. ve 37. özellikleri, yani çarpıklık, Burg metodu 4. dereceden modelin 3. AR parametresi, Burg metodu 4. dereceden modelin 2. Yansıma katsayısı ve Burg metodu 4. dereceden modelin 3. Yansıma katsayısı olmak üzere 4 özellik kullanan algoritma sonucunda yüksek doğrulukta sınıflandırma yapılmıştır. Bu özellikler Mann Whitney U test sıralamasında üst sıralarda yer almaktadır. Sınıflandırma sonuçları 6. Bölümde detaylı olarak verilecektir.

4.2.2.2. KHD ile yapılan çalışma için özellik seçme

Ancak Literatür taraması yapılırken, daha önce PPG ile yapılmış DEF-KY ve KEF-KY sınıflandırmaya yönelik bir çalışma olmadığı görülmüştür. Bu nedenle bu ikili sınıflandırma çalışması için veri seti hazırlanıp özellikler çıkarılmıştır.

PPG sinyali de biyolojik sinyal olduğu için normal dağılım göstermez. Bu nedenle EKG’de olduğu gibi, iki sınıf için PPG de parametrik olmayan Mann Whitney U testi ile analiz edilebilir.

Normal dağılımda ortalama, çarpıklık (skewness) ve basıklık (kurtosis) değerleri 0’dır (Kim, 2013). PPG’den türetilen KHD’nin ortalama, çarpıklık ve basıklık değerleri sıfırdan farklıdır. Dolayısıyla normallik şartlarını sağlamaz ve normal dağılım göstermediği için parametrik olmayan Mann Whitney U test yöntemi ile istatistiksel olarak analiz edilebilir.

PPG ve KHD özelliklerinin birlikte analiz edildiği, ancak, Bölüm 8’de anlatılacağı üzere, özellik seçme sonrası sınıflandırmada sadece KHD özelliklerinin kullanıldığı çalışmada, 37 adet PPG özelliği ile 37 adet KHD özelliği birleştirilerek, toplam 74 özellik içeren bir veri seti oluşturulmuştur. İlk 37 özellik PPG özellikleri, diğer 37 özellik ise KHD özellikleridir. Mann Whitney U test sonucunda elde edilen, PPG ve KHD özelliklerine ait p değerleri Tablo 4.9, 4.10 ve 4.11’de verilmiştir. Özellikler sıralanmıştır.

Tablo 4.9. PPG ve KHD özelliklerinin DEF-KY ve KEF-KY ikili sınıflandırma çalışması için Mann Whitney U test sonuçları.

Sıra	Özellik no	R (Eta)	R ²	p değeri
1	47	0.4915	0.2415	0.0000
2	58	0.482	0.2323	0.0000
3	57	0.4166	0.1736	0.0000
4	41	0.4131	0.1707	0.0000
5	42	0.4118	0.1696	0.0000
6	51	0.3915	0.1533	0.0000
7	39	0.3642	0.1327	0.0001
8	33	0.3141	0.0987	0.0025
9	49	0.2701	0.0729	0.0009
10	32	0.2645	0.07	0.0021
11	31	0.2593	0.0672	0.0051
12	44	0.2283	0.0521	0.0008
13	55	0.2086	0.0435	0.0389
14	56	0.1627	0.0265	0.0242
15	30	0.1328	0.0176	0.036

Tablo 4.10. (Devamı) PPG ve KHD özelliklerinin DEF-KY ve KEF-KY ikili sınıflandırma çalışması için Mann Whitney U test sonuçları.

Sıra	Özellik no	R (Eta)	R ²	p değeri
16	72	0.1284	0.0165	0.0281
17	38	0.1094	0.012	0.0139
18	6	0.1032	0.0106	0.0425
19	15	0.0541	0.0029	0.0425
20	35	0.0354	0.0013	0.0223
21	65	0.0137	0.0002	0.0054
22	18	0.2383	0.0568	0.0739
23	66	0.1889	0.0357	0.05
24	3	0.1689	0.0285	0.0739
25	50	0.1605	0.0258	0.1749
26	52	0.1	0.01	0.1667
27	45	0.0954	0.0091	0.5655
28	11	0.0938	0.0088	0.0925
29	13	0.0749	0.0056	0.9102
30	34	0.0689	0.0047	0.6688
31	16	0.0639	0.0041	0.1488
32	17	0.0563	0.0032	0.2784
33	19	0.0448	0.002	0.7628
34	8	0.0278	0.0008	0.795
35	9	0.0238	0.0006	0.4264
36	53	0.0235	0.0006	0.7708
37	36	0.0106	0.0001	0.0748
38	26	0.0499	0.0025	0.0425
39	37	0.0481	0.0023	0.0001
40	48	0.0354	0.0013	0.0223
41	71	0.0137	0.0002	0.0054
42	12	0.0083	0.0001	0.0389
43	63	0.2383	0.0568	0.0739
44	1	0.1924	0.0370	0.6997
45	43	0.1889	0.0357	0.0500
46	67	0.1689	0.0285	0.0739
47	10	0.1636	0.0268	0.4513
48	74	0.1605	0.0258	0.1749
49	27	0.1589	0.0252	0.0905
50	21	0.1162	0.0135	0.8317
51	69	0.1000	0.0100	0.1667
52	73	0.0954	0.0091	0.5655
53	61	0.0938	0.0088	0.0925
54	4	0.0870	0.0076	0.0847
55	22	0.0819	0.0067	0.8728
56	68	0.0749	0.0056	0.9102
57	23	0.0704	0.0050	0.3879
58	64	0.0689	0.0047	0.6688
59	5	0.0668	0.0045	0.7469
60	24	0.0666	0.0044	0.4451
61	40	0.0639	0.0041	0.1488
62	28	0.0617	0.0038	0.8153

Tablo 4.11. (Devamı) PPG ve KHD özelliklerinin DEF-KY ve KEF-KY ikili sınıflandırma çalışması için Mann Whitney U test sonuçları.

Sıra	Özellik no	R (Eta)	R ²	p değeri
63	59	0.0563	0.0032	0.2784
64	20	0.0467	0.0022	0.6726
65	70	0.0448	0.0020	0.7628
66	25	0.0422	0.0018	0.5374
67	2	0.0377	0.0014	0.1147
68	14	0.0343	0.0012	0.7271
69	62	0.0278	0.0008	0.7950
70	7	0.0264	0.0007	0.8646
71	46	0.0238	0.0006	0.4264
72	60	0.0235	0.0006	0.7708
73	29	0.0139	0.0002	0.5305
74	54	0.0106	0.0001	0.0748

Tablo 4.9, 4.10 ve 4.11'e göre 6, 12, 15, 26, 30, 31, 32, 33, 35, 37, 38, 39, 41, 42, 44, 47, 48, 49, 51, 55, 56, 57, 58, 65, 71 ve 72 özellikleri için p değeri 0.05'ten küçüktür. Yani, bu 26 özellik iki sınıf için ayırt edicidir. 47, 57 ve 58 nolu özellikler sıralamada ilk üçtedir. Bu özellikler KHD'nin 10., 20. ve 21. özellikleridir, yani KHD'nin medyan, %25 kırılmış ortalama ve %50 kırılmış ortalama özellikleridir. Bu üç özellikle yapılan sınıflandırma sonucu yüksek doğruluk elde edilmiştir. Sınıflandırma sonuçları Bölüm 6'da detaylı olarak verilecektir.

4.2.2.3. PPG ve KHD ile yapılan çalışma için özellik seçme

EKG ile yapılan üçlü sınıflandırma çalışması PPG ve KHD özellikleri birlikte kullanılarak da yapılmıştır. Bir önceki kısımda anlatıldığı gibi, PPG ve KHD normal dağılım göstermez. Bu sebeple parametrik olmayan istatistiksel yöntemler kullanılır. Veriler normal dağılmadığından ve üç sınıf olduğundan Kruskal Wallis testi uygulanmıştır.

Kruskal Wallis testi sonucunda her bir özellik için elde edilen asimptotik önemler (p-değerleri) Tablo 4.12'de verilmiştir. Tablolara göre 5, 7, 14, 22, 23, 24, 25, 28, 29, 60, 62, 67, 68, 69, 73, 74 özellikleri için $p > 0.05$ 'tir. Dolayısıyla bu özellikler hariç diğer özelliklerin karşılaştırılan üç sınıftan en az ikisi için ayırt edici olduğu söylenebilir. Post-hoc test olarak ikili Mann Whitney U testleri uygulanmış ve hangi ikili sınıflar için hangi özelliklerin ayırt edici olduğu belirlenmiştir. Mann-Whitney U testleri sonucunda elde edilen p değerleri Tablo 4.13, 4.14, 4.15 ve 4.16'da verilmiştir.

Tablo 4.12. Kruskal Wallis test sonucu PPG ve KHD özelliklerine ait p değerleri.

Özellik No	p değeri	Özellik No	p değeri
1	0.0003	38	0.0013
2	0.0001	39	0.0000
3	0.0000	40	0.0008
4	0.0000	41	0.0000
5	0.1210	42	0.0000
6	0.0122	43	0.0000
7	0.9061	44	0.0000
8	0.0000	45	0.0000
9	0.0002	46	0.0000
10	0.0000	47	0.0000
11	0.0000	48	0.0000
12	0.0058	49	0.0000
13	0.0001	50	0.0000
14	0.5468	51	0.0000
15	0.0000	52	0.0000
16	0.0000	53	0.0000
17	0.0000	54	0.0000
18	0.0000	55	0.0031
19	0.0000	56	0.0110
20	0.0000	57	0.0000
21	0.0000	58	0.0000
22	0.9656	59	0.0000
23	0.6591	60	0.1020
24	0.6952	61	0.0011
25	0.5743	62	0.5592
26	0.0012	63	0.0021
27	0.0260	64	0.0000
28	0.8571	65	0.0000
29	0.4613	66	0.0001
30	0.0000	67	0.0525
31	0.0000	68	0.9665
32	0.0000	69	0.3951
33	0.0000	70	0.0214
34	0.0000	71	0.0000
35	0.0017	72	0.0000
36	0.0002	73	0.8365
37	0.0001	74	0.3697

Tablo 4.13. PPG ve KHD özellikleri ile DEF-KY ve Sağlıklı ikili sınıfı için Mann Whitney U testi sonucunda elde edilen p değerleri.

Özellik No	p değeri	Özellik No	p değeri
1	0.0041	39	0.0099
2	0.0320	40	0.0424
3	0.0000	41	0.2761
4	0.0000	42	0.6880
6	0.8440	43	0.0000
8	0.0000	44	0.6688
9	0.0002	45	0.0003
10	0.0000	46	0.0001
11	0.0000	47	0.7074

Tablo 4.14. (Devamı) PPG ve KHD özellikleri ile DEF-KY ve Sağlıklı ikili sınıfı için Mann Whitney U testi sonucunda elde edilen p değerleri.

Özellik No	p değeri	Özellik No	p değeri
12	0.0028	48	0.0010
13	0.0001	49	0.1147
15	0.0000	50	0.0004
16	0.0000	51	0.0493
17	0.0000	52	0.0009
18	0.0001	53	0.0003
19	0.0000	54	0.0003
20	0.0000	55	0.0061
21	0.0000	56	0.0635
26	0.0008	57	0.3515
27	0.4451	58	0.5357
30	0.0001	59	0.0005
31	0.0001	61	0.0277
32	0.0002	63	0.0007
33	0.0003	64	0.0000

Tablo 4.15. PPG ve KHD özellikleri ile KEF-KY ve Sağlıklı ikili sınıfı için Mann Whitney U testi sonucunda elde edilen p değerleri.

Özellik No	p değeri	Özellik No	p değeri
1	0.0001	39	0.0000
2	0.0000	40	0.0001
3	0.0001	41	0.0000
4	0.0000	42	0.0000
6	0.0051	43	0.0000
8	0.0002	44	0.0000
9	0.0120	45	0.0000
10	0.0000	46	0.0000
11	0.0001	47	0.0000
12	0.1326	48	0.0000
13	0.0014	49	0.0000
15	0.0001	50	0.0000
16	0.0002	51	0.0001
17	0.0002	52	0.0000
18	0.0013	53	0.0000
19	0.0002	54	0.0000
20	0.0000	55	0.6125
21	0.0000	56	0.1300
26	0.0238	57	0.0000
27	0.0063	58	0.0000
30	0.0000	59	0.0000
31	0.0000	61	0.0004
32	0.0000	63	0.0557
33	0.0000	64	0.0000
34	0.0000	65	0.0000
35	0.0019	66	0.0000
36	0.0000	70	0.0053
37	0.0175	71	0.0000
38	0.0008	72	0.0000

Tablo 4.16. PPG ve KHD özellikleri ile DEF-KY ve KEF-KY ikili sınıfı için Mann Whitney U testi sonucunda elde edilen p değerleri.

Özellik No	p değeri	Özellik No	p değeri
1	0.6997	39	0.0001
2	0.1147	40	0.1488
3	0.0300	41	0.0000
4	0.0847	42	0.0000
6	0.0214	43	0.0500
8	0.0238	44	0.0009
9	0.0128	45	0.0425
10	0.4513	46	0.4264
11	0.0288	47	0.0000
12	0.0389	48	0.0223
13	0.0414	49	0.0025
15	0.0038	50	0.0281
16	0.0238	51	0.0000
17	0.0238	52	0.0139
18	0.0262	53	0.0425
19	0.0238	54	0.0748
20	0.6726	55	0.0021
21	0.8317	56	0.0051
26	0.0425	57	0.0000
27	0.0905	58	0.0000
30	0.0000	59	0.2784
31	0.0000	61	0.0925
32	0.0000	63	0.0739
33	0.0000	64	0.6688
34	0.0049	65	0.0242
35	0.0022	66	0.0360
36	0.0217	70	0.7628
37	0.0001	71	0.0054
38	0.0389	72	0.0008

Testler sonucunda örneğin KEF-KY ve Sağlıklı çifti için 12, 26, 37, 55, 56 ve 63 dışındaki tüm özellikler için p değeri 0.0167'den azdır. Yani bu özellikler dışındaki diğer özelliklerin hepsi, bu sınıf ikilisi için ayırt edicidir (Bonferroni düzeltmesi). Bundan sonra, en ayırt edici olanlarından, farklı sayılarda ve kombinasyonlarda özellikler ile denemeler yapıldı. Optimum değer, daha az özellik / daha yüksek doğruluk ilişkisinde belirlendi. Sonuç olarak algoritma ile 4, 6, 15, 34, 35, 40, 47, 54 olmak üzere sekiz özellik kullanılarak yeterince yüksek doğrulukta sınıflandırma yapılmıştır. Sınıflandırma sonuçları Bölüm 6'da verilmiştir.

5. SINIFLANDIRMADA KULLANILAN ALGORİTMALAR

5.1. Giriş

Özellik çıkarma işlemlerinden sonra veriler istatistiksel olarak analiz edilmiştir. Sonrasında ise sınıflandırma çalışmaları yapılmıştır. Sınıflandırma çalışmaları için k-en yakın komşu (k-NN) Algoritması, Destek Vektör Makinaları (DVM), Karar Ağaçları ve topluluk sınıflandırıcılar kullanılmıştır. Bu bölümde kullanılan sınıflandırıcılar detaylı şekilde anlatılmıştır.

Tez çalışması kapsamında üç ayrı veri seti için sınıflandırma çalışmaları yapılmıştır. Bunlardan ilki, 3 kablolu EKG verileri kullanılarak DEF-KY, sağlıklı ve KEF-KY sınıflarını birbirinden ayırmak için yapılan üçlü sınıflandırma çalışmasıdır. İkinci çalışma, PPG'den türetilen KHD özellikleri kullanılarak DEF-KY ve KEF-KY sınıflarını ayırmak için yapılan ikili sınıflandırma çalışmasıdır. Üçüncü sınıflandırma çalışması ise PPG ve KHD özelliklerini birlikte kullanarak DEF-KY, sağlıklı ve KEF-KY sınıflarını birbirinden ayırmak için yapılan üçlü sınıflandırma çalışmasıdır. Çalışmaların amacı, uzman hekimler için bile zor olan ve gözden kaçabilen KY vakalarının tanısı için tıbbi karar destek sistemi oluşturmak ve hekimlerin tanı koymasını kolaylaştırmaktır.

5.2. k - En Yakın Komşu (k-NN) Algoritması

k-En Yakın Komşu (k-NN), parametrik olmayan bir sınıflandırma algoritmasıdır, yani temel veri kümesi üzerinde herhangi bir varsayımda bulunmaz. Sadeliği ve etkinliği ile bilinir. Denetimli bir öğrenme algoritmasıdır. Etiketlenmemiş verilerin sınıfının tahmin edilebilmesi için veri noktalarının çeşitli sınıflara ayrıldığı etiketli bir eğitim veri kümesi kullanılır.

Sınıflandırmada, farklı özellikler, etiketlenmemiş verilerin ait olduğu sınıfı belirler. k-NN çoğunlukla sınıflandırıcı olarak kullanılır. Belirli bir bölgedeki en yakın veya komşu eğitim örneklerine dayalı olarak verileri sınıflandırır. Bu yöntem, çalışma

kolaylığı ve hızlı hesaplama için tercih edilir. Sürekli veriler için en yakın komşularını hesaplamada Öklid mesafesi kullanılır (Taunk ve ark., 2019).

Yeni bir girdi için, k en yakın komşu hesaplanır ve komşu veriler arasındaki çoğunluk, yeni girdi için sınıflandırmaya karar verir. Bu sınıflandırıcı basit olmasına rağmen, etiketlenmemiş verilerin sınıflandırılmasında ' k ' değeri önemli bir rol oynamaktadır.

' k ' değerlerine karar vermenin birçok yolu vardır, ancak hangi değerin en etkili sonucu verdiğini görmek için sınıflandırıcı farklı değerlerle birden çok kez çalıştırılabilir. Hesaplama maliyeti biraz yüksektir, çünkü tüm hesaplamalar veri setinde karşılaşıldığında değil, eğitim verileri sınıflandırılırken yapılır.

Eğitim veri seti üzerinde genelleme yapmaz. Bu nedenle, test aşamasındayken eğitilen tüm temel veri kümesi gereklidir. Regresyonda, k -NN sürekli değerleri tahmin eder. Bu değer, k - en yakın komşularının değerlerinin ortalamasıdır.


k -NN, yeni girdinin sınıfının belirlenebilmesi için verilerin farklı kümelere ayrıldığı veri setlerinde kullanılır. k -NN, kullanılan veriler hakkında önceden bilgi bulunmayan bir çalışma için daha önemlidir.

k -NN bir sınıflandırma algoritmasıdır. Temelde sınıflandırmada iki adım vardır:

1. Öğrenme Adımı: Eğitim verileri kullanılarak bir sınıflandırıcı oluşturulur.
2. Sınıflandırıcının değerlendirilmesi.

En yakın komşu tekniğine göre, yeni etiketlenmemiş veriler, komşularının hangi sınıflara ait olduğu belirlenerek sınıflandırılır. k -NN algoritması, hesaplamasında bu kavramı kullanır. k -NN algoritmasında, bilinmeyen verileri sınıflandırmaya yardımcı olan belirli bir k değeri sabitlenir.

Veri setinde etiketlenmemiş yeni bir veri ile karşılaşıldığında k -NN iki işlem gerçekleştirir. İlk olarak, yeni veri noktasına en yakın k adet noktayı, yani en yakın k adet komşusunu analiz eder. İkinci olarak, k -NN, komşuların sınıflarını kullanarak yeni verilerin hangi sınıfa sınıflandırılacağını belirler. Şekil 5.1, basit bir k -NN yapısını göstermektedir.



Şekil 5.1. (a) Basit bir k-NN, (b) Yeni etiketlenmemiş verinin k değerlerine göre komşuluk mesafeleri.

k-NN'nin performansını etkileyen faktörler k değeri, Öklid mesafesi ve parametrelerin normalizasyonudur. Algoritmanın ayrıntılı çalışmasını anlamak için adımlar aşağıdaki gibidir:

Eğitim veri kümesi göz önüne alındığında:

$$\{ (x(1), y(1)) , (x(2), y(2)), \dots , (x(m), y(m)) \}$$

1. Eğitim setini saklamak
2. Etiketlenmemiş her yeni veri için, aşağıdaki formülü kullanarak tüm eğitim veri noktalarıyla Öklid mesafesini hesaplamak için (7.1) ifadesi kullanılır:

$$\sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (5.1)$$

3. k adet en yakın komşuları bulmak.
4. En fazla sayıda yakın komşuların olduğu sınıfı atamak.


k=1 ise, veri basitçe en yakın komşusunun sınıfına atanır. k=1'de, eğitim verileri için hata oranı sürekli olarak sıfırdır. Bunun nedeni, herhangi bir eğitim veri noktasına en yakın noktanın kendisi olmasıdır. Dolayısıyla en iyi sonuçlar k=1 ise elde edilir. Ancak k=1 ile sınırlar aşırı yüklenir. Çok küçük 'k' değerleri olması durumunda, algoritma gürültüye karşı çok hassastır. Uygun bir k değeri elde etmek için eğitim ve doğrulama seti, ilk veri setinden ayrılmalıdır. En yakın iki komşu (k=2) iki farklı sınıfa aitse sonuç bilinmez. Bu yüzden k değeri için 1, 3, 5, 7 gibi tek sayılar seçmek daha uygundur.

Tez kapsamında EKG, PPG ve KHD ile yapılan tüm çalışmalarda kullanılan k-NN için $k=1$ ve metrik mesafe Öklid seçilmiştir.

5.3. Destek Vektör Makinaları

Destek Vektör Makinaları (DVM) başlangıcından bu yana yaygın olarak kullanılan önde gelen bir sınıflandırma tekniğidir. İlk olarak 1995 yılında Cortes ve Vapnik tarafından ikili sınıflandırma problemleri için tanımlanmıştır (Tanveer ve ark., 2022). DVM, veri noktalarını iki sınıfa ayırabilen karar sınırını belirleyen karar hiper düzlemi bulmaya çalışır. Bu karar düzlemlerine destek hiperdüzlemleri denir ve aralarındaki mesafe bir kuadratik programlama problemi çözülerek maksimize edilir. DVM, çekirdek hilesi kullanarak doğrusal olarak ayrılamayan durumlarda bile hesaplama açısından güçlüdür. DVM örneği Şekil 5.2’de görülmektedir.

DVM, daha iyi genelleme sağlayan ve eğitim aşamasında hatayı azaltan yapısal risk minimizasyonu ilkesini kullandığı için önemli avantajlara sahiptir. Yüksek sınıflandırma doğruluğu ve hızlı sınıflandırma performansı avantajına sahiptir. Ayrıca, düşük veri kalitesiyle karşılaşıldığında daha iyi sınıflandırma performansı sağlar (Tanveer ve ark., 2022). DVM, diğer sistemlerin çoğundan daha iyi performans gösterir, ancak, performansı büyük ölçüde çekirdek fonksiyonlarının ve parametrelerinin seçimine bağlıdır.



Şekil 5.2. DVM örneği (a) doğrusal, (b) doğrusal olmayan ayrılma.

EKG ile ilgili çalışmada kullanılan DVM için çekirdek fonksiyonu polinom ve polinom derecesi 3’tür. Çekirdek ölçeği otomatik, ve “Box Constraint” parametresi 1 olarak belirlenmiştir.


PPG ve KHD birlikte kullanılarak yapılan çalışmada kullanılan DVM için çekirdek fonksiyonu 2. derece polinomdur. Yine çekirdek ölçeği otomatik, ve “Box Constraint” parametresi 1 olarak belirlenmiştir.

KHD ile yapılan çalışmada kullanılan DVM için çekirdek fonksiyonu Gauss ve çekirdek ölçeği 0.35’tir. “Box Constraint” parametresi 1 olarak belirlenmiştir.

5.4. Karar Ağaçları

Karar Ağaçları (KA), hem sınıflandırma hem de regresyon sorunları için kullanılabilen denetimli bir öğrenme yöntemidir, ancak çoğunlukla sınıflandırma için tercih edilir. KA, Şekil 5.3’te gösterildiği gibi iç düğümlerin bir veri kümesinin özelliklerini ele aldığı, dalların karar yönergelerini ele aldığı ve her yaprak düğümün sonucu ele aldığı ağaç düzeninde bir sınıflandırıcıdır.

Bir karar ağacında, karar düğümü ve yaprak düğümü olmak üzere iki düğüm vardır. Karar düğümleri, herhangi bir karar üzerinde uzlaşmak için kullanılır ve farklı dallara sahiptir, yaprak düğümleri ise bu kararların getirisi ve başka dal içermez. Karar olarak bilinir, çünkü bir ağaç gibi, daha fazla dal geliştiren ve ağaç benzeri bir yapı oluşturan kök merkezi ile başlar.



Şekil 5.3. Karar Ağaçları Sınıflandırıcı.

Kök Düğümü: Ağacın başladığı noktadır. Tüm veri kümesine yönelir, bu da herhangi bir oranda iki homojen kümeye bölünür.

Yaprak Dügümü: Son aşamadır ve ağaç bir yaprak noktasına ulaştıktan sonra daha fazla bölünmez.

KA Algoritması adımları:

1. Ağaç, tüm veri kümelerinden oluşan kök noktasıyla başlatılır, buna R diyelim.
2. Öznitelik Seçim Ölçüsü (Attribute Selection Measure (ASM)) kullanılarak veri kümesindeki en iyi bölme testi bulunur.
3. R en iyi sonuçlar için beklenen özellikleri içeren alt kümelere ayrılır.
4. En iyi özelliği içeren ağaç oluşturulur.
5. 3. adımda yapılan veri kümesinin alt kümelerini kullanarak yinelemeli olarak yeni seçim ağaçları yapılır.

Daha fazla bölünemeyen ve son nokta olan yaprak noktasına ulaşana kadar bu döngüye devam edilir (Liang ve ark., 2021).

ASM yöntemleri Bilgi Kazancı (Information Gain (IG)) ve Gini indeksi (GI) olmak üzere 2 tiptir. Bilgi Kazancı (IG), bir veri kümesinin bir özelliğe bağlı olarak bölünmesinden sonra entropideki değişikliklerin tahminidir. Bir özelliğin bize bir sınıf hakkında ne kadar veri verdiğini tespit eder. Entropi, belirli bir gruptaki safsızlığı değerlendirmek için bir tahmindir. Verilerin değişkenliğine karar verir.

Gini indeksi, bir karar ağacına yerleşirken oluşan kusursuzluk veya kirlilik oranıdır. Düşük Gini indeksi (GI) olan bir özelliğin tercih edilmesi gerekir.

Genellikle KA sınıflandırması kullanılarak oluşturulan sağlık izleme sistemleri, sağlık maliyetlerini azaltmak ve sağlık kalitesini artırmak için hastaların sağlık durumlarını periyodik olarak test etmelerine yardımcı olur (Liang ve ark., 2021). Bu nedenle bu çalışmada KA algoritması da kullanılmıştır.

Tez çalışmasında kullanılan KA sınıflandırıcı için bölme kriteri Gini'nin çeşitlilik indeksidir ve maksimum bölme sayısı 100 dür.


5.5. Torbalı Ağaçlar Topluluk Sınıflandırıcı

Tez çalışması kapsamında kullanılan sınıflandırıcılardan biri de ağaç tabanlı bir algoritma olan torbalı ağaçlar topluluk sınıflandırıcıdır. Torbalama yöntemi ilk olarak Leo Breiman tarafından 1996 yılında geliştirilmiştir (Breiman, 1996). Sınıflandırıcılar, ayrı ve çeşitli olmalarına rağmen, bir koleksiyon veya topluluk olarak kullanıldığında

daha iyi çalışır. Toplu öğrenme yöntemlerinin amacı, doğru sonuçlar elde etmek için bu sınıflandırıcıların bir birleşimini kullanmaktır. Bunu yapmak için öne çıkan iki yöntem, önyükleme toplamı, yani "torbalama (bagging)" ve Adaboost algoritma ailesi, yani "artırma (boosting)"dır.

Torbalı ağaç topluluğu, temel bir öğrenme algoritması olarak çalışır. Aynı şeyi birkaç kez çağırmak için farklı eğitim setleri kullanılır (Şekil 5.4). Orijinal veri setinden, önyükleme kopyası ile örneğin n sayıda alt veri setleri oluşturulur. Bu alt setlerin her biri için bir temel model oluşturulur. Bu modeller birbirinden bağımsızdır, paralel olarak çalışırlar. Son tahmin, tüm modellerin sonucunda elde edilen tahminlerin birleştirilmesiyle belirlenir. Son tahmin aşamasında sonuçlar, sınıflandırma ağaçlarında oylama ile belirlenirken, regresyon ağaçlarında ortalama alınarak belirlenir. Eğitilmiş sınıflandırıcılar, verilerdeki küçük değişikliklerden büyük ölçüde etkilenir. Öğrenme algoritmasının bu kararsızlığı, sınıflandırma doğruluğunu iyileştirmek için kullanılır (Dietterich, 2000).

Bu tez çalışmasında kullanılan torbalı ağaçlar topluluk sınıflandırıcı için öğrenici tipi KA'dır. Veri seti 180 veriden olduğundan maksimum bölünme sayısı 179'dur. Öğrenici sayısı 30'dur.



Şekil 5.4. Topluluk Sınıflandırıcı.

Her sınıflandırıcı için veri seti, eğitim ve test olmak üzere iki bölüme ayrılmıştır. EKG ile yapılan çalışmada veri setinin rasgele %80'i eğitim, %20'si test veri seti olacak şekilde seçilmiştir. PPG ve KHD ile yapılan üçlü sınıflandırma ve KHD ile yapılan ikili sınıflandırma çalışmalarında 10 kat çapraz doğrulama yöntemi kullanılmıştır.

5.6. Performans Kriterleri


Önerilen tanı algortimalarının performanslarını test etmek için çeşitli değerlendirme kriterleri kullanılmıştır. Bu kriterler, doğruluk oranı, duyarlılık, özgüllük, F-ölçümü, Kappa değeri, alıcı işletim karakteristiği (Receiver Operating Characteristic, ROC) eğrisi, ROC eğrisinin altındaki alan (Area Under Curve, AUC) ve k-kat çapraz doğrulamadır. Alt başlıklarda bu kriterler açıklanmaktadır.

5.6.1. k - kat çapraz doğrulama

Şekil 5.5'teki akış şeması, k-katlı (10-kat) çapraz doğrulamanın, verileri rastgele k (10) gruplarına bölerek başladığını ve ardından her grup için aşağıdaki işlemlerin gerçekleştirildiğini göstermektedir:

1. Test veri seti olarak eğitim katlarından biri seçilir.
2. Kalan $k - 1$ grupları (9 grup) eğitim seti olarak kullanılır.
3. Modeli eğitmek ve test veri kümesiyle değerlendirmek için seçilen eğitim veri seti kullanılır.

Bu şekilde tüm veriler eğitim ve test aşamalarında kullanılır.



Şekil 5.5. 10 - kat çapraz doğrulama.

Tez çalışmasında 10 kat çapraz doğrulama kullanılmıştır.

5.6.2. Doğruluk, duyarlılık, özgüllük, F-ölçümü, Kappa değeri

Karışıklık matrisi, Şekil 5.6’da gösterildiği gibi, gerçek sınıflandırma ve tahmin edilen sınıflandırma olmak üzere iki puanlayıcı arasındaki olayların sayısını kaydeden bir çapraz tablodur.

		Tahmin Edilen Sınıf			
		Sınıflar	DEF-KY	Sağlıklı	KEF-KY
Gerçek Sınıf	DEF-KY	TN	FP	TN	
	Sağlıklı	FN	TP	FN	
	KEF-KY	TN	FP	TN	

Şekil 5.6. Karışıklık matrisi.

Doğruluk, çok sınıflı sınıflandırmada en popüler metriklerden biridir ve doğrudan karışıklık matrisinden hesaplanır. Dengeli veri setleri için her bir sınıf için bulunan doğruluk değerlerinin ortalaması nihai doğruluk oranını verir (Grandini ve ark., 2020). Her bir sınıf için doğruluk hesaplaması denklem 7.2’deki gibi yapılır. i. sınıf için doğruluk:

$$Doğruluk_i = \frac{TP_i + \sum TN_i}{TP_i + \sum TN_i + \sum FP_i + \sum FN_i} \quad (5.2)$$

F1-ölçümü, sınıflandırma modelinin performansını karışıklık matrisinden başlayarak değerlendirir, hassasiyet ve geri çağırma ölçümlerinin harmonik ortalamasıdır. Denklem 7.3’teki gibi hesaplanır.

$$F_Ölçümü = \frac{\sum_{i=1}^3 TP_i}{Grand\ Total} \quad (5.3)$$

Cohen’in Kappa’sı, iki rastgele kategorik değişken olarak kabul edilen, tahmin edilen ve gerçek etiketler arasındaki uyumu ölçme fikri üzerine kuruludur (Ranganathan ve ark., 2017). Karışıklık matrisini oluşturan ve marjinal satırları ve marjinal sütun dağılımlarını hesaplayan iki kategorik değişkeni karşılaştırır. Denklem 7.4’teki gibi hesaplanır.

$$Kappa = \frac{cs - \sum_{i=1}^3 p_i t_i}{s^2 - \sum_{i=1}^3 p_i t_i} \quad (5.4)$$

$c = \sum_{i=1}^3 C_{ii}$ doğru tahmin edilen elemanların toplam sayısı
 $s = \sum_i^3 \sum_j^3 C_{ij}$ toplam eleman sayısı
 $p_i = \sum_k^3 C_{ik}$ i. sınıf için tahmin edilen değerler (sütun toplamı)
 $t_i = \sum_k^3 C_{ki}$ i. sınıf için gerçek değerler (satır toplamı)

Duyarlılık, Gerçek Pozitif (TP) öğelerin toplam pozitif olarak sınıflandırılmış birim sayısına bölümüdür (gerçek pozitiflerin satır toplamı). Özellikle Yanlış Negatif (FN), model tarafından negatif olarak etiketlenmiş ancak aslında pozitif olan unsurlardır. Duyarlılık, ikili sınıflandırma için, sistemin gerçek hasta sınıfında hastaları ayırt etme yeteneğinin göstergesidir. Üç sınıflı sınıflandırmalarda her bir sınıf için ayrı ayrı hesaplanan değerlerin ortalaması kullanılmıştır. Duyarlılık denklem 7.5'teki gibi hesaplanır.

$$\text{Duyarlılık}_i = \frac{TP_i}{TP_i + \sum FN_i} \quad (5.5)$$

Özgüllük, ikili sınıflandırma için sistemin sağlıklı gruplar içerisinde sağlıklıları ayırt etme yeteneğini gösterir. Üçlü sınıflandırma için yine üç sınıf özgüllüğünün ortalaması kullanılmıştır. Denklem 7.6'daki gibi hesaplanır.

$$\text{Özgüllük}_i = \frac{\sum TN_i}{\sum TN_i + \sum FP_i} \quad (5.6)$$

6. SONUÇLAR VE ÖNERİLER

6.1. Sonuçlar

Bu bölümde tez kapsamında yapılan çalışmaların sonuçları detaylı olarak verilmiştir. Tez çalışmasında, ekokardiyografiye ulaşımın zor ve kısıtlı olduğu durumlarda, ya da hastanın ekokardiyografi sonuçlarını beklemeksizin acil bir şekilde tedaviye başlanması gereken durumlarda, KY alt tipleri için hekimlerin tanı koymasını kolaylaştıracak bir tıbbi karar destek sistemi geliştirilmiştir.

6.1.1. EKG ile yapılan çalışma sonuçları

Bu çalışmada, 3 kablolu EKG sinyalinden türetilen özellikler kullanılarak makine öğrenimi tabanlı bir sistem geliştirilmiştir. EKG'den toplam 37 özellik türetilmiştir. Ancak, gerçek zamanlı sistemlerde bu kadar çok özelliği üretmek zordur. Bu nedenle özellik sayısı azaltılıp sistemin iyileştirilmesi sağlanmıştır. Sınıflandırıcının performansını artırmak için Kruskal Wallis Testi ve Mann Whitney-U Testi yöntemleri ile 4 özellik seçilmiş ve kullanılmıştır.

EKG ile yapılan çalışma Şekil 3.5'teki akış diyagramındaki işlem sırası ile yapılmış ve sonuçlar alınmıştır. EKG'den çıkarılan 37 özelliğin istatistiksel analiz ile DEF-KY, Sağlıklı ve KEF-KY sınıfları için ayırt edici olup olmadıkları tespit edilmiştir. 37 özelliğin 19'u üç sınıf için ayırt edici bulunmuştur. Daha sonra ikili Mann Whitney U testleri ile hangi özelliklerin hangi ikili gruplar için ayırt edici oldukları tespit edilmiş ve EKG özellikleri ile sınıflar arasındaki Eta korelasyon katsayılarına göre özellikler sıralanmıştır. Sonuçlar 4.5, 4.6, 4.7 ve 4.8 numaralı tablolarda verilmiştir.

Daha sonra en alakalı olanlardan farklı sayıda özellik girdi olarak alınmış ve deneyler gerçekleştirilmiştir. Optimum değer, daha az özellik / yüksek doğruluk ilişkisinde belirlenmiştir. Sonuç olarak 2., 32., 36. ve 37. özelliklerin, yani çarpıklık, Burg metodu 4. dereceden modelin 3. AR parametresi, Burg metodu 4. dereceden modelin 2. Yansıma katsayısı ve Burg metodu 4. dereceden modelin 3. Yansıma katsayısı olmak üzere 4 özelliğin kullanıldığı algoritmalar sonucunda yüksek doğrulukta sınıflandırma gerçekleştirilmiştir. (Hangi özelliğe hangi numaranın verildiği Tablo 4.1 ve 4.2'de

görülmektedir.) Bu özellikler Mann Whitney U test sıralamasında üst sıralarda yer almaktadır. Sınıflandırma performans parametreleri Tablo 6.1'de verilmektedir. Tablodaki sonuçlar sadece dört özellik ile elde edilmiştir. Bu, pratikte kullanılabilecek bir sistem için etkileyici bir performans olarak düşünülebilir.

Tablo 6.1. EKG ile yapılan çalışmanın performans parametreleri.

MÖ Algoritması	Doğruluk (%)	Duyarlılık	Özgüllük	F-ölçümü	Kappa	AUC
k-NN	100	1	1	1	1	1
DVM	97.22	0.9722	0.9861	0.9722	0.9583	0.9942
Karar Ağaçları	91.67	0.9167	0.9583	0.9167	0.8750	0.9780
Topluluk Sınıflandırıcı	97.22	0.9722	0.9861	0.9722	0.9583	0.9896

Tablo 6.2 ve 6.3'te her bir sınıflandırıcı için dört farklı MÖ algoritması ile sınıflandırıcı sonuçları ayrıntılı olarak verilmiştir. Sınıflandırma işlemleri sırayla gerçekleştirilmiştir. İlk olarak 37 EKG özelliği herhangi bir özellik seçim algoritması uygulanmadan sınıflandırılmış ve sınıflandırıcının performansını ölçmek için performans parametreleri hesaplanarak ilgili sütuna kaydedilmiştir. Daha sonra Kruskal Wallis Testi ile 37 öznitelik 19'a indirilmiş ve aynı işlem tekrarlanmıştır. Son olarak Mann Whitney-U Testi ile 19 öznitelik 4'e indirilmiş ve aynı işlem tekrarlanmıştır. Sınıflandırıcılar için performans parametreleri hesaplanmış ve tabloda verilmiştir. Tabloya göre en iyi sonuçlar k-NN sınıflandırıcı ile elde edilmiştir. Tabloda özellik seçimi ile özellik sayısının azaltılması genel olarak sistem performansını düşürmemiş hatta daha da artırmıştır. k-NN, DVM ve Topluluk sınıflandırıcıları için bu artış oldukça belirgindir. Ayrıca gerçek zamanlı sistemlerin daha az iş yüküne sahip olması ve daha verimli çalışabilmesi için 37 veya 19 özellik yerine 4 özellik ile en yüksek performans parametrelerinin elde edilmesi önemlidir. Karar Ağaçları sınıflandırıcısı için özellik seçimi ile performans parametrelerinde önemli bir artış olmamasına rağmen, ayrıntılı olarak bakıldığında her sınıf için AUC artmıştır. 37 veya 19 özellik ile elde edilebilecek performans parametrelerinin 4 özellik ile elde edilmesi de avantajlı olmuştur.

Sınıflandırıcılar için ROC eğrileri Şekil 6.1'de verilmiştir. Bir ROC eğrisi şu şekilde değerlendirilebilir: eğri sol eksene daha yakınsa pozitif sınıfı daha iyi teşhis edebilir; Eğri üst eksene yakınsa kontrol grubunu daha iyi tanımlayabilir. Şekil ile ilgili olarak, örneğin, Sağlıklı sınıf için ROC eğrisinde, pozitif sınıf "Sağlıklı" ve kontrol sınıfı "DEF-KY ve KEF-KY"dir.


Tablo 6.2. EKG ile yapılan çalışma için sınıflandırıcı sonuçları.

k-NN Sınıflandırıcı Sonuçları												
	Tüm özellikler varken (ÖS=37)				Kruskal Wallis Testi sonrası (ÖS=19)				Mann Whitney-U Test sonrası (ÖS=4)			
	Ü.S.	DEF-KY	Sağlıklı	KEF-KY	Ü.S.	DEF-KY	Sağlıklı	KEF-KY	Ü.S.	DEF-KY	Sağlıklı	KEF-KY
Duyarlılık	0.9167	0.9167	0.9167	0.9167	0.9722	1	0.9167	1	1	1	1	1
Özgüllük	0.9583	0.9583	0.9583	0.9583	0.9861	0.9583	1	1	1	1	1	1
AUC	0.9375	0.9375	0.9375	0.9375	0.9792	0.9792	0.9583	1	1	1	1	1
F-ölçümü	0.9167				0.9722				1			
Kappa	0.8750				0.9583				1			
Doğruluk (%)	91.67				97.22				100			
DVM Sınıflandırıcı Sonuçları												
	Tüm özellikler varken (ÖS=37)				Kruskal Wallis Testi sonrası (ÖS=19)				Mann Whitney-U Test sonrası (ÖS=4)			
	Ü.S.	DEF-KY	Sağlıklı	KEF-KY	Ü.S.	DEF-KY	Sağlıklı	KEF-KY	Ü.S.	DEF-KY	Sağlıklı	KEF-KY
Duyarlılık	0.8889	0.8333	0.8333	0.8889	0.8333	0.8333	0.8889	0.8333	0.8333	0.8889	0.8333	0.8333
Özgüllük	0.9444	0.9583	0.9583	0.9444	0.9583	0.9583	0.9444	0.9583	0.9583	0.9444	0.9583	0.9583
AUC	0.9340	0.8785	0.9653	0.9340	0.8785	0.9653	0.9340	0.8785	0.9653	0.9340	0.8785	0.9653
F-ölçümü	0.8889			0.8889			0.8889			0.8889		
Kappa	0.8333			0.8333			0.8333			0.8333		
Doğruluk (%)	88.99			88.99			88.99			88.99		

Tablo 6.3. (Devamı) EKG ile yapılan çalışma için sınıflandırıcı sonuçları.

Karar Ağaçları Sınıflandırıcı Sonuçları												
	Tüm özellikler varken (ÖS=37)				Kruskal Wallis Testi sonrası (ÖS=19)				Mann Whitney-U Test sonrası (ÖS=4)			
	Ü.S.	DEF-KY	Sağlıklı	KEF-KY	Ü.S.	DEF-KY	Sağlıklı	KEF-KY	Ü.S.	DEF-KY	Sağlıklı	KEF-KY
Duyarlılık	0.9167	0.9167	0.9167	0.9167	0.9167	0.8333	1	0.9167	0.9167	0.9167	0.9167	0.9167
Özgüllük	0.9583	0.9167	0.9583	1	0.9583	0.9583	0.9167	1	0.9583	0.9167	0.9583	1
AUC	0.9537	0.9479	0.9774	0.9358	0.9352	0.8837	0.9514	0.9705	0.9780	0.9705	0.9878	0.9757
F-ölçümü	0.9167				0.9167				0.9167			
Kappa	0.8750				0.8750				0.8750			
Doğruluk (%)	91.67				91.67				91.67			
Topluluk Sınıflandırıcı Sonuçları												
	Tüm özellikler varken (ÖS=37)				Kruskal Wallis Testi sonrası (ÖS=19)				Mann Whitney-U Test sonrası (ÖS=4)			
	Ü.S.	DEF-KY	Sağlıklı	KEF-KY	Ü.S.	DEF-KY	Sağlıklı	KEF-KY	Ü.S.	DEF-KY	Sağlıklı	KEF-KY
Duyarlılık	0.9167	0.9167	0.8333	1	0.9167	0.8333	1	0.9167	0.9722	1	0.9167	1
Özgüllük	0.9583	0.9167	0.9583	1	0.9583	1	0.9167	0.9583	0.9861	0.9583	1	1
AUC	0.9699	0.9444	0.9653	1	0.9658	0.9375	0.9722	0.9878	0.9896	0.9826	0.9861	1
F-ölçümü	0.9167				0.9167				0.9722			
Kappa	0.8750				0.8750				0.9583			
Doğruluk (%)	91.67				91.67				97.22			

Ü.S. Üçlü Sınıflandırma, ÖS Özellik Sayısı



Şekil 6.1. Özellik seçimi olmadan (ÖS=37), Kruskal Wallis testi sonrası (ÖS=19) ve Mann Whitney U testi sonrası sınıflandırıcı ROC eğrileri.

Şekil 6.1'e göre, k-NN için 37 özellik olduğunda, üç sınıfın tümü için AUC 0.938'dir. 19 özellik olduğunda her üç sınıf için de AUC değerleri artmıştır. KEF-KY idealdir, pozitif sınıf Sağlıklı sınıf için daha iyi ayırt edilmiş, kontrol sınıfı (KEF-KY ve Sağlıklı) DEF-KY için daha iyi ayırt edilmiştir. 4 özellik ile tüm sınıflar için ideal sonuçlara ulaşılmıştır.

SVM için 37 özellik olduğunda, kontrol sınıfları KEF-KY ve Sağlıklı sınıflar için daha iyi ayrılırken, DEF-KY için pozitif sınıf daha iyi ayırt edilmiştir. 19 özellik ile KEF-KY idealdir, AUC ise diğer sınıflar için biraz azalmıştır. 4 özellik varken DEF-KY idealdir ve KEF-KY ve Sağlıklı sınıflar için durumlar ideale yakındır.

Karar Ağacı için 37 özellik olduğunda, pozitif sınıf KEF-KY için daha iyi ayırt edilirken, kontrol sınıfları Sağlıklı ve DEF-KY sınıfları için daha iyi ayırt edilmiştir. 19 özellik olduğunda DEF-KY için AUC değeri önemli ölçüde azalmıştır. 4 özellik olduğunda her üç sınıf için daha iyi sonuçlar elde edilmiştir.

Topluluk sınıflandırıcı için 37 özellik olduğunda, KEF-KY idealdir, DEF-KY için kontrol sınıfı daha iyi ayırt edilmiştir. 19 özellik olduğunda, DEF-KY için pozitif sınıf daha iyi ayırt edilmiştir. 4 özellik ile KEF-KY idealdir, DEF-KY için kontrol sınıfı daha iyi ayırt edilmiştir ve pozitif sınıf Sağlıklı grup için daha iyi ayırt edilmiştir.

Bu çalışmanın gelecekte ölçüm cihazlarına yerleştirilebileceği düşünülmektedir. Endüstriyel uygulamalarda yaygın olarak kullanıldığı için k-NN sınıflandırıcısı üzerinde durulmuştur (Kier ve Aach, 2006). Çalışmayı desteklemek ve 3 derivasyonlu EKG kullanılarak bu üçlü sınıflandırmanın uygulanabilirliğini görmek için de diğer üç algoritma kullanılmıştır. Bu algoritmalar da gömülü sistemlerde gerçek zamanlı olarak çalıştırılabilir potansiyeldedir (Haigh ve ark., 2015). Elde edilen sonuçlara göre bu sınıflandırma yüksek doğrulukla yapılabilmiş ve en iyi sonuçlar k-NN yöntemi ile elde edilmiştir. Özen Kavas ve ark. (2022) çalışmasında bu sonuçlardan yapılan uluslararası indeksli makale görülmektedir.

Alandaki diğer çalışmalarla karşılaştırıldığında, bu çalışmada yapılan sınıflandırmada DEF-KY, Sağlıklı ve KEF-KY olmak üzere üç sınıf bulunmaktadır. Sadece KY'nin varlığı veya yokluğu değil, KY varsa "hangisi" sorusu da cevaplanır.

Bu çalışma, DEF-KY ve KEF-KY'nin sadece 3 kablolu EKG ile teşhis edilebileceğini göstererek literatüre katkıda bulunmuştur. Bu konuda ileride yapılacak çalışmalara öncü olacağı düşünülmektedir.

6.1.2. KHD ile yapılan çalışma sonuçları

KHD ile yapılan sınıflandırma çalışmasında Şekil 3.16'da görülen iş akışı takip edilmiş ve sonuçlar alınmıştır. Bölüm 6'da anlatıldığı şekilde özellik çıkarma ve istatistiksel analiz adımlarından sonra Bölüm 5'te anlatılan sınıflandırıcılar kullanılarak çalışma yapılmıştır.

DEF-KY ve KEF-KY teşhisi için KHD'den çıkarılan yalnızca üç özellik kullanılarak yeni bir algoritma geliştirilmiştir. İlk başta, çıkarılan özellik sayısı 37'dir. Ancak gerçek zamanlı sistemler için bu kadar çok özellekle çalışmak zor olacağından, performansı artırmak için özelliklerin sayısı azaltılmıştır. Mann Whitney U Testi sonuçları tablosunda tüm özellikler için özellik sıralaması verilmiş, sınıflandırma etkinliğini artırmak için özellik sayısı üçe indirilmiş ve kullanılmıştır. Sınıflandırma için kullanılan bu üç özellik, sıralamada ilk üçte yer almaktadır (Tablo 4.9).


Algoritmalar sonucunda KHD'nin 10., 20. ve 21. Özellikleri, yani medyan, %25 Kırpılmış Ortalama ve %50 Kırpılmış Ortalama özellikleri kullanılarak yüksek doğruluklar elde edilmiştir. Sınıflandırma sonuçları Tablo 6.4'te verilmiştir. Sadece üç özellik kullanılarak elde edilen bu sonuçların pratikte kullanım açısından önemli bir sistem performansı olduğu söylenebilir.

Tablo 6.4. KHD ile yapılan çalışma için sınıflandırma performans parametreleri.

MÖ Algoritması	Doğruluk (%)	Duyarlılık	Özgüllük	F-ölçümü	Kappa	AUC
DVM	98.33	0.9667	1	0.9818	0.9667	0.9833
k-NN	96.67	0.9333	1	0.9618	0.9333	0.9667
Karar Ağaçları	95.83	0.9333	0.9833	0.9561	0.9167	0.9583

DEF-KY ve KEF-KY ikili sınıflandırması literatürde daha önce PPG veya PPG'den türetilen KHD ile çalışılmamıştır. Bu çalışmada sadece KHD'den çıkarılan 3 özellik ile yüksek doğrulukta sınıflandırma yapılmıştır.

Sınıflandırıcıların ROC eğrileri Şekil 6.2'de verilmiştir. Şekle göre DVM ve k-NN sınıflandırıcıların duyarlılıkları çok iyidir, tüm sınıflandırıcılar ideale çok yakındır ve iyi sonuçlar vermiştir.



Şekil 6.2. KHD ile yapılan çalışma için sınıflandırıcılara ait ROC eğrileri.

6.1.3. PPG ve KHD ile yapılan çalışma sonuçları

PPG ve PPG'den türetilen KHD özelliklerinin kullanıldığı çalışmada, Şekil 3.12'deki iş akışına göre adımlar takip edilerek sonuçlar elde edilmiştir. Bölüm 4'te anlatıldığı şekilde özellik çıkarma ve seçme işlemlerinden sonra, Bölüm 5'te anlatılan sınıflandırıcılar kullanılarak DEF-KY, Sağlıklı ve KEF-KY gruplarının bulunduğu üçlü sınıflandırma çalışmaları yapılmıştır. Bu çalışmanın amacı da EKG ile yapılan çalışmada olduğu gibi, ekokardiyografiye ulaşımın zor olduğu veya ekokardiyografi verilerinden önce derhal tedaviye başlanması gereken durumlarda, doktorun tanı koymasını hızlandıracak ve kolaylaştıracak, ya da uzman hekimin olmadığı yerlerde mevcut hekimlerin tanı koymasına yardımcı olacak bir tıbbi karar destek sistemi tasarlanmıştır.

5'i PPG özellikleri, 3'ü KHD özellikleri olmak üzere, toplam 8 özellik ile önemli sonuçlar elde edilmiştir. PPG'nin 4., 6., 15., 34. ve 35. özellikleri, yani geometrik ortalama, Hjort hareketlilik parametresi, ortalama eğri uzunluğu, Burg metodu 4. dereceden modelin beyaz gürültü girişinin tahmini varyansı, ve Burg metodu 4. dereceden modelin 1. yansıma katsayısı özellikleri ile KHD'nin 3., 10. ve 17. özellikleri, yani çeyrekler arası açıklık, medyan ve standart hata özellikleri kullanılmıştır. Sınıflandırma sonucu elde edilen performans parametreleri Tablo 6.5'te verilmiştir. Detaylı sonuçlar Tablo 6.6'da görülmektedir.

Tablo 6.5. PPG ve KHD ile yapılan çalışma için sınıflandırma performans parametreleri.

MÖ Algoritması	Doğruluk (%)	Duyarlılık	Özgüllük	F-ölçümü	Kappa
DVM	82.78	0.8278	0.9139	0.8278	0.7417
k-NN	82.22	0.8222	0.9111	0.8222	0.7333
Topluluk Sınıflandırıcı	87.78	0.8778	0.9389	0.8778	0.8167

Tablo 6.6. PPG ve KHD ile yapılan çalışmanın sınıflandırıcı sonuçları.

DVM Sınıflandırıcı Sonuçları				
	Ü.S.	DEF-KY	Sağlıklı	KEF-KY
Duyarlılık	0.8278	0.7333	0.7667	0.9833
Özgüllük	0.9139	0.9417	0.8917	0.9083
F-ölçümü	0.8278			
Kappa	0.7417			
Doğruluk (%)	82.78			
k-NN Sınıflandırıcı Sonuçları				
	Ü.S.	DEF-KY	Sağlıklı	KEF-KY
Duyarlılık	0.8222	0.7	0.8167	0.95
Özgüllük	0.9111	0.9333	0.875	0.925
F-ölçümü	0.8222			
Kappa	0.7333			
Doğruluk (%)	82.22			
Topluluk Sınıflandırıcı Sonuçları				
	Ü.S.	DEF-KY	Sağlıklı	KEF-KY
Duyarlılık	0.8778	0.8333	0.8167	0.9833
Özgüllük	0.9389	0.9083	0.9417	0.9667
F-ölçümü	0.8778			
Kappa	0.8167			
Doğruluk (%)	87.78			

Ü.S. Üçlü Sınıflandırma

Tablolara göre, topluluk sınıflandırıcı en iyi sonuçları vermiştir. DVM ve k-NN sınıflandırıcıları da önemli sonuçlara sahiptir.

Çalışmayı desteklemek için üçlü sınıflandırmada kullanılan verilerle KY ve Sağlıklı ikilisi için ve DEF-KY ve KEF-KY ikilisi için sınıflandırma çalışmaları da yapılmıştır. Bu sınıflandırmalar için üçlü sınıflandırmada kullanılan özellikler içerisinde, ilgili ikili grup için ayırt edici olan özellikler kullanılmıştır.

KY ve Sağlıklı ikili sınıflandırması için Mann Whitney U testi sonucunda elde edilen p değerleri Tablo 6.7'de verilmiştir. Üçlü sınıflandırmada kullanılan 6. ve 35. özelliklerin bu ikili sınıflandırma için ayırt edici olmadığı görülmektedir (ilgili

özellikler için $p > 0.05$). Bu nedenle, bunlar hariç tutularak 4, 15, 34, 40, 47, 54 numaralı diğer altı özellik kullanılarak sınıflandırma yapılmıştır.

Tablo 6.7. PPG ve KHD özellikleri ile KY ve Sağlıklı ikili sınıflandırması için Mann Whitney U testi sonuçları.

Özellik No	p değeri	Özellik No	p değeri
1	0.0001	38	0.0014
2	0.0001	39	0.0000
3	0.0000	40	0.0006
4	0.0000	41	0.0266
5	0.0407	42	0.0027
6	0.0829	43	0.0000
7	0.6787	44	0.0052
8	0.0000	45	0.0000
9	0.0003	46	0.0000
10	0.0000	47	0.0001
11	0.0000	48	0.0000
12	0.0093	49	0.0000
13	0.0001	50	0.0000
14	0.3015	51	0.2713
15	0.0000	52	0.0000
16	0.0000	53	0.0000
17	0.0000	54	0.0000
18	0.0000	55	0.1966
19	0.0000	56	0.8448
20	0.0000	57	0.0130
21	0.0000	58	0.0007
22	0.8830	59	0.0000
23	0.7169	60	0.0359
24	0.6654	61	0.0009
25	0.3683	62	0.2944
26	0.0012	63	0.0021
27	0.0431	64	0.0000
28	0.6479	65	0.0000
29	0.2780	66	0.0001
30	0.6479	67	0.1081
31	0.7146	68	0.8211
32	0.7535	69	0.6876
33	0.7836	70	0.0064
34	0.0005	71	0.0000
35	0.0823	72	0.0000
36	0.0007	73	0.8710
37	0.9746	74	0.9383

DEF-KY ve KEF-KY ikili sınıflandırması için de Tablo 4.9, 4.10 ve 4.11'deki p değerlerine göre bu ikili sınıflandırma için ayırt edici olan 15, 34, 35 ve 47 numaralı

dört özellik kullanılarak sınıflandırma yapılmıştır. Bu ikili sınıflandırmalar için de 10 kat çapraz doğrulama sonucunda elde edilen sonuçlar Tablo 6.8'de verilmiştir.

Tablo 6.8. PPG ve KHD özellikleri ile ikili sınıflandırma sonuçları.

KY ve Sağlıklı İkili Sınıflandırma Sonuçları			
	MÖ Algoritması		
	DVM	k-NN	Topluluk Sınıflandırıcı
Duyarlılık	0.9250	0.9250	0.9250
Özgüllük	0.7333	0.7833	0.7667
F-ölçümü	0.7894	0.8396	0.8203
Kappa	0.6685	0.7178	0.7044
AUC	0.8292	0.8542	0.8458
Doğruluk (%)	86.11	87.78	87.22

DEF-KY ve KEF-KY İkili Sınıflandırma Sonuçları			
	MÖ Algoritması		
	DVM	k-NN	Topluluk Sınıflandırıcı
Duyarlılık	0.9333	0.9667	0.9667
Özgüllük	1	0.9833	0.9833
F-ölçümü	0.9636	0.9470	0.9727
Kappa	0.9333	0.9000	0.9500
AUC	0.9667	0.95	0.9750
Doğruluk (%)	96.67	97.50	97.50

Tablo 6.8'deki sonuçlara göre, sistem DEF-KY ve KEF-KY ikili sınıflandırmasında oldukça yüksek doğruluk vermiştir. Bu çalışmadaki sonuçlar Pandey ve ark. (2018) ve Savji ve ark. (2018) çalışmalarındaki DEF-KY ve KEF-KY sınıflandırma sonuçlarından çok daha iyidir. Ayrıca bu çalışmalarda demografik ve klinik özellikler kullanılmıştır. KY ve Sağlıklı ikili sınıflandırmanın sonucunda da dikkat çekici doğruluk elde edilmiştir. PPG kullanılarak farklı bir sınıflandırma yöntemi ile KY ve Sağlıklı ayrımının yapıldığı bir çalışmada (Baldoumas ve ark., 2019) elde edilen doğruluk ve duyarlılık değerlerine çok yakın sonuçlar elde edilmiştir. Bu çalışmadaki KY ve Sağlıklı sınıflandırma sonuçları, KY tanı çalışmasının PPG ve giyilebilir cihazlar kullanılarak ölçülen ivmeölçer verileriyle gerçekleştirildiği Shah ve ark. (2020)'da elde edilen sonuçlardan daha yüksektir. PPG ve KHD özelliklerinin kullanıldığı bu çalışma sonuçları Özen Kavas ve ark. (2023) çalışmasında uluslararası indeksli makale olarak yayımlanmıştır.

6.2. Öneriler

Bu tez çalışmasında hekimin teşhis koymasını destekleyen ve uzman gerektirmeyen, sadece 3 kablolu EKG veya sadece parmaktan basit bir şekilde ölçülen PPG sinyali kullanılarak, gözden kaçan ve teşhisi zor olan iki KY alt tipi için tanı algoritması geliştirmek amaçlanmıştır.

Bu çalışmada elde edilen sonuçlara dayanarak, sadece 3 kablolu EKG ya da sadece PPG özelliklerinin DEF-KY ve KEF-KY tanısında kullanılabileceği ve önemli sonuçlar sağlayacağı belirlenmiştir. Bu çalışma ile, tek bir sinyalle DEF-KY ve KEF-KY teşhis etme olasılığının yolu açılmıştır. Sinyallerin kolay ölçülmesi ve işlenmesi, gerçek zamanlı sistemlerin pratikliğini artıracaktır.

Bu tez çalışmasında kullanılan veri seti çok büyük değildir. Bu nedenle geleneksel MÖ yöntemleri kullanılmıştır. Daha büyük bir veri seti ile daha yeni MÖ yöntemleri kullanılarak yeni çalışmalar yapılabilir.

KY'de doğru hastaya doğru bakımın sağlanması, tanısal belirsizlik, klinik araştırma sonuçlarının optimal olmayan genellenabilirliği nedeniyle tedavideki çeşitlilik ve güvenilirlik yanıtı, risk sınıflandırmasında karmaşıklık ve bakım noktasında sınırlı bilgi entegrasyonu nedeniyle zorlanır. MÖ, KY'deki bu boşlukları kapatmada önemli bir rol oynayabilir ve geleneksel insan kaynaklı modellere göre önemli avantajlara sahiptir (Averbuch ve ark., 2022). MÖ, bilgisayarlara programlı algoritmaların ötesinde verileri değerlendirme, veri içindeki kalıpları tanımlama, öğrenilen kalıpları görülmeyen verilerle eşleştirme ve hesaplama görevlerinin performansını insan yeteneklerinin ötesinde iyileştirme kapasitesi sağlar. Bu tez çalışmasında kullanılan MÖ algoritmalarından biri olan k-NN, gerçek değerli veya ayrık değerli hedef fonksiyona kavramsal olarak yaklaşmak için çok basit ve güçlü bir yaklaşımdır. Birçok araştırmacı yakın zamanda k-NN'nin birçok farklı türde veri seti kullanan çeşitli gerçek dünya sistemleri için yüksek bir tahmin doğruluğu olduğunu göstermiştir (Aung ve ark., 2018). Bu çalışma gelecekte ölçüm cihazlarına implante edilebilir olarak düşünülmüştür. k-NN sınıflandırıcısı, endüstriyel uygulamalarda yaygın olarak kullanıldığı için, bu algoritma tercih edilmiştir (Kier ve Aach, 2006). Aynı şekilde DVM ve Karar Ağaçları yöntemleri de yüksek donanım gerektirmeyen ve yaygın olarak kullanılan, düşük maliyetli ve kısa sürede sonuç veren yöntemler oldukları için tercih edilmişlerdir.

Bölüm 1’de anlatıldığı üzere, literatürde EKG veya PPG sinyalleri ve MÖ algoritmaları kullanılarak farklı kalp hastalıkları ile ilgili çalışmalar yapılmıştır. EKG’nin kullanıldığı DEF-KY ve KEF-KY ikili sınıflandırması yapılan çalışmalar da mevcuttur. Ancak EKG ile birlikte ekokardiyografi verileri, demografik bilgiler, hastanın kullandığı ilaçlar vs. olmak üzere çok çeşitli veriler aynı anda kullanılmıştır. Sadece EKG’nin kullanıldığı farklı KY çalışmalarında da hastanelerde kullanılan geleneksel 12 derivasyonlu EKG verileri kullanılmıştır. PPG ile DEF-KY ve KEF-KY sınıflandırmasıyla ilgili bir çalışma daha önce yapılmamıştır. Hasta konforu açısından bu tez çalışmasında kullanılan EKG daha avantajlı, PPG en avantajlıdır.

DEF-KY ve KEF-KY’yi teşhis etmek için ekokardiyografi veya bazı kan testleri gereklidir. Bu zahmetli ve pahalı testlerden önce 3 kablolu EKG ya da PPG, yani tek sinyal kullanmak iş yükünü azaltacaktır. Sadece üç kablolu EKG, ya da sadece PPG verileri kullanılarak, KY belirtileriyle hastaneye gelen kişinin DEF-KY vakası mı, KEF-KY mi, yoksa sağlıklı mı olduğu ile ilgili doktora ilk etapta ve saniyeler içerisinde cevap veren böyle bir sistem ile gereksiz yere yapılan testlerin sayısı azaltılarak hem zaman açısından hem de ekonomik açıdan tasarruf sağlanacaktır. Uzman doktorun bulunmadığı taşralarda da herhangi bir hekimin bu vakaları farkedip vakit kaybetmeden hastayı uzman hekime yönlendirmesi açısından da avantajlıdır.

Ekokardiyogram ve EKG, KY şüphesi olan hastalarda en sık kullanılan testlerdir. SVEF sadece hastalığın bir belirtisi olarak değil, aynı zamanda çoğu klinik çalışmada hastaların SVEF ile tanımlanması nedeniyle önemlidir. LVEF genellikle ekokardiyogram ile belirlenir. Nadiren SPECT (Single Photon Emission Computerized Tomography) ve radyonüklid ventrikülografi veya radyonüklid anjiyografi (Multiple-gated Acquisition - MUGA) de kullanılmaktadır. Bu cihazlar pahalıdır, bazı yöntemler invazivdir ve hepsi uzman doktor gerektirir. Ayrıca bu cihazlara erişimin kısıtlı olduğu durumlar olabilir. EKG ve PPG ise pahalı değildir, elde edilmeleri kolaydır, uzman doktor gerektirmezler ve kısa sürede sonuç verirler.

Bu çalışmanın ilerleyen zamanlarda cihazlara yerleştirilebileceği düşünülerek, kolay ölçülebilen EKG ve akıllı telefonlarla bile kolayca elde edilebilen PPG sinyalleri kullanılmıştır.

Tez çalışmasının literatüre katkı sağladığı nokta, DEF-KY ve KEF-KY'nin EKG ya da PPG kullanılarak tek bir sinyal ile ayırt edilebilmesidir. Konuyla ilgili bundan sonraki araştırmalara öncülük edeceği düşünülmektedir.



KAYNAKLAR

- Abdalla, F. Y. O., Wu, L., Ullah, H., Ren, G., Noor, A., Mkindu, H., ve Zhao, Y. (2020). Deep convolutional neural network application to classify the ECG arrhythmia. *Signal, Image and Video Processing*, 14(7), 1431–1439. <https://doi.org/10.1007/S11760-020-01688-2/TABLES/5>
- Adebayo, P. B., Akintunde, A. A., Adebayo, A. J., Asaolu, S. O., Audu, M., ve Ayodele, O. E. (2017). Comparison of Neuropsychological Patterns in Nigerians with different Heart Failure Phenotypes. *Archives of clinical neuropsychology: the official journal of the National Academy of Neuropsychologists*, 32(3), 280–288. <https://doi.org/10.1093/ARCLIN/ACW113>
- Albert, N., Trochelman, K., Li, J., ve Lin, S. (2010). Signs and Symptoms of Heart Failure: Are You Asking the Right Questions? *American Journal of Critical Care*, 19(5), 443–452. <https://doi.org/10.4037/AJCC2009314>
- Alian, A. A., ve Shelley, K. H. (2014). Photoplethysmography. *Best Practice ve Research Clinical Anaesthesiology*, 28(4), 395–406. <https://doi.org/10.1016/J.BPA.2014.08.006>
- Amin, M. G., Chowdhury, A. W., Ahmed, M., Sabah, K. M. N., Haque, H. F., Kabir, S. R., Islam, K. N., ve Saleh, M. A. D. (2017). Lead-Reversal ECG Simulating Myocardial Infarction – A Case Report and Literature Review. *Bangladesh Heart Journal*, 31(2), 104–108. <https://doi.org/10.3329/bhj.v31i2.32382>
- Aramendi, E., Ruiz, J., Ruiz De Gauna, S., Irusta, U., Lazkano, A., ve Gutierrez, J. (2005). A simple effective filtering method for removing CPR caused artefacts from surface ECG signals. *Computers in Cardiology*, 32, 547–550. <https://doi.org/10.1109/CIC.2005.1588159>
- Ary L. Goldberger, Zachary D Goldberger, A. S. (2018). *Goldberger's Clinical Electrocardiography: A Simplified Approach* (Ninth). Elsevier Inc.
- Attia, Z. I., Kapa, S., Lopez-Jimenez, F., McKie, P. M., Ladewig, D. J., Satam, G., Pellikka, P. A., Enriquez-Sarano, M., Noseworthy, P. A., Munger, T. M., Asirvatham, S. J., Scott, C. G., Carter, R. E., ve Friedman, P. A. (2019). Screening for cardiac contractile dysfunction using an artificial intelligence-enabled electrocardiogram. *Nature Medicine* 2019 25:1, 25(1), 70–74. <https://doi.org/10.1038/s41591-018-0240-2>
- Attia, Z. I., Noseworthy, P. A., Lopez-Jimenez, F., Asirvatham, S. J., Deshmukh, A. J., Gersh, B. J., Carter, R. E., Yao, X., Rabinstein, A. A., Erickson, B. J., Kapa, S., ve Friedman, P. A. (2019). An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction. *The Lancet*, 394(10201), 861–867. [https://doi.org/10.1016/S0140-6736\(19\)31721-0](https://doi.org/10.1016/S0140-6736(19)31721-0)

- Aung, S. S., Nagayama, I., & Tamaki, S. (2018). Regional distance-based k-NN classification. *ICIIBMS 2017 - 2nd International Conference on Intelligent Informatics and Biomedical Sciences*, 2018-January, 56–62. <https://doi.org/10.1109/ICIIBMS.2017.8279719>
- Averbuch, T., Sullivan, K., Sauer, A., Mamas, M. A., Voors, A. A., Gale, C. P., Metra, M., Ravindra, N., & Van Spall, H. G. C. (2022). Applications of artificial intelligence and machine learning in heart failure. *European Heart Journal - Digital Health*. <https://doi.org/10.1093/ehjdh/ztac025>
- Avram, R., Tison, G., Kuhar, P., Marcus, G., Pletcher, M., Olgin, J. E., ve Aschbacher, K. (2019). PREDICTING DIABETES FROM PHOTOPLETYSMOGRAPHY USING DEEP LEARNING. *Journal of the American College of Cardiology*, 73(9), 16. [https://doi.org/10.1016/S0735-1097\(19\)33778-7](https://doi.org/10.1016/S0735-1097(19)33778-7)
- Bal, U., ve Bal, A. (2015). Temassız Fotoplatismografi İle Nabız Kestiriminde Hemoglobin Seviyesinin Etkisi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 17(50), 47–53.
- Baldoumas, G., Peschos, D., Tatsis, G., Christofilakis, V., Chronopoulos, S. K., Kostarakis, P., Varotsos, P. A., Sarlis, N. V., Skordas, E. S., Bechlioulis, A., Michalis, L. K., ve Naka, K. K. (2020). Remote sensing natural time analysis of heartbeat data by means of a portable photoplethysmography device. *International Journal of Remote Sensing*, 42(6), 2292–2302. <https://doi.org/10.1080/2150704X.2020.1847351>
- Baldoumas, George, Peschos, D., Tatsis, G., Chronopoulos, S. K., Christofilakis, V., Kostarakis, P., Varotsos, P., Sarlis, N. V., Skordas, E. S., Bechlioulis, A., Michalis, L. K., ve Naka, K. K. (2019). A Prototype Photoplethysmography Electronic Device that Distinguishes Congestive Heart Failure from Healthy Individuals by Applying Natural Time Analysis. *Electronics 2019, Vol. 8, Page 1288*, 8(11), 1288. <https://doi.org/10.3390/ELECTRONICS8111288>
- Berberi, E. J. (2014). Principles of Electrocardiography. *Biomedical Engineering Fundamentals*, 45-1-45–12. <https://doi.org/10.1201/B15482-50/PRINCIPLES-ELECTROCARDIOGRAPHY-EDWARD-BERBARI>
- Besleaga, T., Badiani, S., Lloyd, G., Toschi, N., Canichella, A., Demosthenous, A., Lambiase, P. D., ve Orini, M. (2019). Non-Invasive Detection of Mechanical Alternans Utilizing Photoplethysmography. *IEEE Journal of Biomedical and Health Informatics*, 23(6), 2409–2416. <https://doi.org/10.1109/JBHI.2018.2882550>
- Bigger, J. T., Fleiss, J. L., Steinman, R. C., Rolnitzky, L. M., Kleiger, R. E., ve Rottman, J. N. (1992). Frequency domain measures of heart period variability and mortality after myocardial infarction. *Circulation*, 85(1), 164–171. <https://doi.org/10.1161/01.CIR.85.1.164>
- Blok, S., Piek, M. A., Tulevski, I. I., Somsen, G. A., ve Winter, M. M. (2021). The accuracy of heartbeat detection using photoplethysmography technology in cardiac patients. *Journal of Electrocardiology*, 67, 148–157. <https://doi.org/10.1016/J.JELECTROCARD.2021.06.009>

- Borlaug, B. A., ve Paulus, W. J. (2011). Heart failure with preserved ejection fraction: pathophysiology, diagnosis, and treatment. *European Heart Journal*, 32(6), 670–679. <https://doi.org/10.1093/EURHEARTJ/EHQ426>
- Bozkurt, B., Coats, A. J. S., Tsutsui, H., Abdelhamid, C. M., Adamopoulos, S., Albert, N., Anker, S. D., Atherton, J., Böhm, M., Butler, J., Drazner, M. H., Michael Felker, G., Filippatos, G., Fiuzat, M., Fonarow, G. C., Gomez-Mesa, J. E., Heidenreich, P., Imamura, T., Jankowska, E. A., ... Zieroth, S. (2021). Universal definition and classification of heart failure: a report of the Heart Failure Society of America, Heart Failure Association of the European Society of Cardiology, Japanese Heart Failure Society and Writing Committee of the Universal Definition of Heart Failure. *European Journal of Heart Failure*, 23(3), 352–380. <https://doi.org/10.1002/EJHF.2115>
- Bozkurt, M. R., Uçar, M. K., Bozkurt, F., ve Bilgin, C. (2020). Development of hybrid artificial intelligence based automatic sleep/awake detection; Development of hybrid artificial intelligence based automatic sleep/awake detection. *IET Science*. <https://doi.org/10.1049/iet-smt.2019.0034>
- Bozkurt, M. R. (2007). *EMG Sinyallerinin Modern Yöntemlerle Önişlenmesi ve Sınıflandırılması* [Doktora Tezi]. Sakarya University.
- Bozkurt, M. R., Uçar, M. K., Bozkurt, F., ve Bilgin, C. (2019). In obstructive sleep apnea patients, automatic determination of respiratory arrests by photoplethysmography signal and heart rate variability. *Australasian Physical and Engineering Sciences in Medicine*, 42(4), 959–979. <https://doi.org/10.1007/s13246-019-00796-9>
- Breiman, L. (1996). Bagging predictors. *Machine Learning* 1996 24:2, 24(2), 123–140. <https://doi.org/10.1007/BF00058655>
- Butler, J., Fonarow, G. C., Zile, M. R., Lam, C. S., Roessig, L., Schelbert, E. B., Shah, S. J., Ahmed, A., Bonow, R. O., Cleland, J. G. F., Cody, R. J., Chioncel, O., Collins, S. P., Dunnmon, P., Filippatos, G., Lefkowitz, M. P., Marti, C. N., McMurray, J. J., Misselwitz, F., ... Gheorghiade, M. (2014). Developing therapies for heart failure with preserved ejection fraction. Current state and future directions. *JACC: Heart Failure*, 2(2), 97–112. <https://doi.org/10.1016/J.JCHF.2013.10.006>
- Çavuşoğlu, Y., Marc Weinstein, J., ve Türk Kardiyoloji Derneği Kalp Yetersizliği Çalışma Grubu. (2015). Kronik kalp yetersizliği tedavisinde pratik yaklaşımlar Güncel uygulamada sık sorulanlar, gözden kaçanlar, tartışmalı durumlar Türkçe baskı / Turkish edition. *Official journal of the The Anatolian Journal of Cardiology*, 15(2), 1–65.
- Çevik, F. C., Yazıcı, S., Kara, A. F., Atılgan, Z., Çil, H., Tekbaş, E., Çevik, R., Tahtasız, M., Saraç, A. J., ve Tarihi, G. (2010). Romatoid artritli hastalarda kardiyak sempatovagal aktivitenin kalp hızı değişkenliği ile değerlendirilmesi. *Dicle Tıp Dergisi / Dicle Medical Journal Cilt*, 37(4), 346–352.
- Challoner, A. V. J., ve Ramsay, C. A. (1974). A photoelectric plethysmograph for the measurement of cutaneous blood flow. *Physics in Medicine ve Biology*, 19(3), 317. <https://doi.org/10.1088/0031-9155/19/3/003>

- Choi, D. J., Park, J. J., Ali, T., ve Lee, S. (2020). Artificial intelligence for the diagnosis of heart failure. *npj Digital Medicine* 2020 3:1, 3(1), 1–6. <https://doi.org/10.1038/s41746-020-0261-3>
- Cook, S., Togni, M., Schaub, M. C., Wenaweser, P., ve Hess, O. M. (2006). High heart rate: a cardiovascular risk factor? *European Heart Journal*, 27(20), 2387–2393. <https://doi.org/10.1093/EURHEARTJ/EHL259>
- Dahlgren, G., Veintemilla, F., Settergren, G., ve Liska, J. (1991). Left ventricular end-systolic pressure estimated from measurements in a peripheral artery. *Journal of Cardiothoracic and Vascular Anesthesia*, 5(6), 551–553. [https://doi.org/10.1016/1053-0770\(91\)90004-D](https://doi.org/10.1016/1053-0770(91)90004-D)
- Dickstein, K., Cohen-Solal, A., Filippatos, G., McMurray, J. J. V., Ponikowski, P., Poole-Wilson, P. A., Strömberg, A., van Veldhuisen, D. J., Atar, D., Hoes, A. W., Keren, A., Mebazaa, A., Nieminen, M., Priori, S. G., Swedberg, K., Vahanian, A., Camm, J., De Caterina, R., Dean, V., ... Zannad, F. (2008). ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure 2008†. *European Journal of Heart Failure*, 10(10), 933–989. <https://doi.org/10.1016/J.EJHEART.2008.08.005>
- Dietterich, T. G. (2000). An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees: Bagging, Boosting, and Randomization. *Machine Learning*, 40(2), 139–157. <https://doi.org/10.1023/A:1007607513941>
- El-Hajj, C., ve Kyriacou, P. A. (2020). A review of machine learning techniques in photoplethysmography for the non-invasive cuff-less measurement of blood pressure. *Biomedical Signal Processing and Control*, 58, 101870. <https://doi.org/10.1016/J.BSPC.2020.101870>
- Ernst, G. (2014). *Heart rate variability*. Springer-Verlag London Ltd. <https://doi.org/10.1007/978-1-4471-4309-3/COVER>
- Ewing, D. J., Campbell, I. W., ve Clarke, B. F. (1980). The Natural History of Diabetic Autonomic Neuropathy. *QJM: An International Journal of Medicine*, 49(1), 95–108. <https://doi.org/10.1093/OXFORDJOURNALS.QJMED.A067610>
- Farrell, T. G., Bashir, Y., Cripps, T., Malik, M., Poloniecki, J., Bennett, E. D., Ward, D. E., ve Camm, A. J. (1991). Risk stratification for arrhythmic events in postinfarction patients based on heart rate variability, ambulatory electrocardiographic variables and the signal-averaged electrocardiogram. *Journal of the American College of Cardiology*, 18(3), 687–697. [https://doi.org/10.1016/0735-1097\(91\)90791-7](https://doi.org/10.1016/0735-1097(91)90791-7)
- Galen S. Wagner, D. G. S. (2013). *Marriott's Practical Electrocardiography*. Lippincott Williams and Wilkins.
- Galiatsatos, P., Win, T. T., Monti, J., Johnston, P. V., Herzog, W., Trost, J. C., Hwang, C. W., Fridman, G. Y., Wang, N. Y., ve Silber, H. A. (2017). Usefulness of a Noninvasive Device to Identify Elevated Left Ventricular Filling Pressure Using Finger Photoplethysmography During a Valsalva Maneuver. *The American journal of cardiology*, 119(7), 1053–1060. <https://doi.org/10.1016/J.AMJCARD.2016.11.063>

- García-Escobar, A., Vera-Vera, S., Jurado-Román, A., Santiago Jiménez-Valero, J., Galeote, G., ve Moreno, R. (2022). Subtle QRS changes are associated with reduced ejection fraction, diastolic dysfunction, and heart failure development and therapy responsiveness: Applications for artificial intelligence to ECG. *Annals of Noninvasive Electrocardiology*, 00, e12998. <https://doi.org/10.1111/ANEC.12998>
- Gilotra, N. A., Tedford, R. J., Wittstein, I. S., Yenokyan, G., Sharma, K., Russell, S. D., ve Silber, H. A. (2017). Usefulness of Pulse Amplitude Changes During the Valsalva Maneuver Measured Using Finger Photoplethysmography to Identify Elevated Pulmonary Capillary Wedge Pressure in Patients With Heart Failure. *The American journal of cardiology*, 120(6), 966–972. <https://doi.org/10.1016/J.AMJCARD.2017.06.029>
- Gilotra, N. A., Wanamaker, B. L., Rahim, H., Kunkel, K., Yenokyan, G., Schulman, S. P., Tedford, R. J., Russell, S. D., ve Silber, H. A. (2020). Usefulness of Noninvasively Measured Pulse Amplitude Changes During the Valsalva Maneuver to Identify Hospitalized Heart Failure Patients at Risk of 30-Day Heart Failure Events (from the PRESSURE-HF Study). *American Journal of Cardiology*, 125(6), 916–923. <https://doi.org/10.1016/J.AMJCARD.2019.12.027>
- Grandini, M., Bagli, E., ve Visani, G. (2020). *Metrics for Multi-Class Classification: an Overview*. <https://doi.org/10.48550/arxiv.2008.05756>
- Guzzetti, S., Magatelli, R., Borroni, E., ve Mezzetti, S. (2001). Heart rate variability in chronic heart failure. *Autonomic Neuroscience*, 90(1–2), 102–105. [https://doi.org/10.1016/S1566-0702\(01\)00274-0](https://doi.org/10.1016/S1566-0702(01)00274-0)
- Haigh, K. Z., Mackay, A. M., Cook, M. R., ve Lin, L. G. (2015). Machine Learning for Embedded Systems: A Case Study. *Raytheon BBN Technologies*.
- Harini, H., Krithika, L. S., Shalini, M., Swaminathan, S., ve Mohan Madhu, N. (2014). Design and Implementation of a Calibration - Free Pulse Oximeter. *IFMBE Proceedings*, 43, 100–103. https://doi.org/10.1007/978-3-319-02913-9_26
- Hasumi, E., Fujiu, K., Chen, Y., Shimizu, Y., Oshima, T., Matsunaga, H., Matsuda, J., Matsubara, T. J., Fukuma, N., Yuxiang, L., Sugita, J., Nakayama, Y., Saga, A., Oguri, G., Kojima, T., Maru, Y., Shoda, M., ve Komuro, I. (2020). Heart failure grading using single-lead electrocardiography. *medRxiv*, 2020.10.08.20209700. <https://doi.org/10.1101/2020.10.08.20209700>
- Haynes, W. (2013). Bonferroni Correction. *Encyclopedia of Systems Biology*, 154–154. https://doi.org/10.1007/978-1-4419-9863-7_1213
- Hebert, J. L., Lecarpentier, Y., Zamani, K., Coirault, C., Daccache, G., Chemla, D., Wuilliez, N., ve Larssonneur, L. (1995). Relation between aortic diastolic pressure and mean aortic pressure in adults. *The American Journal of Cardiology*, 76(4), 301–306. [https://doi.org/10.1016/S0002-9149\(99\)80086-1](https://doi.org/10.1016/S0002-9149(99)80086-1)
- Heidenreich, P. A., Bozkurt, B., Aguilar, D., Allen, L. A., Byun, J. J., Colvin, M. M., Deswal, A., Drazner, M. H., Dunlay, S. M., Evers, L. R., Fang, J. C., Fedson, S. E., Fonarow, G. C., Hayek, S. S., Hernandez, A. F., Khazanie, P., Kittleson, M. M., Lee, C. S., Link, M. S., ... Woo, Y. J. (2022). 2022 ACC/AHA/HFSA Guideline for the Management of Heart Failure. *Journal of Cardiac Failure*, 28(5), e1–e167. <https://doi.org/10.1016/J.CARDFAIL.2022.02.010>

- Herman, R., Vanderheyden, M., Vavrik, B., Beles, M., Palus, T., Nelis, O., Goethals, M., Verstreken, S., Dierckx, R., Penicka, M., Heggermont, W., ve Bartunek, J. (2022). Utilizing longitudinal data in assessing all-cause mortality in patients hospitalized with heart failure. *ESC Heart Failure*. <https://doi.org/10.1002/EHF2.14011>
- Ho, J. E., Lyass, A., Lee, D. S., Vasan, R. S., Kannel, W. B., Larson, M. G., ve Levy, D. (2013). Predictors of new-onset heart failure differences in preserved versus reduced ejection fraction. *Circulation: Heart Failure*, 6(2), 279–286. <https://doi.org/10.1161/CIRCHEARTFAILURE.112.972828>
- Işler, Y., ve Kuntalp, M. (2007). Combining classical HRV indices with wavelet entropy measures improves to performance in diagnosing congestive heart failure. *Computers in Biology and Medicine*, 37(10), 1502–1510. <https://doi.org/10.1016/J.COMPBIOMED.2007.01.012>
- Jeyhani, V., Mahdiani, S., Peltokangas, M., ve Vehkaoja, A. (2015). Comparison of HRV parameters derived from photoplethysmography and electrocardiography signals. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference*, 2015, 5952–5955. <https://doi.org/10.1109/EMBC.2015.7319747>
- Jin, X., Nauta, J. F., Hung, C. L., Ouwerkerk, W., Teng, T. H. K., Voors, A. A., Lam, C. S., ve van Melle, J. P. (2022). Left atrial structure and function in heart failure with reduced (HFrEF) versus preserved ejection fraction (HFpEF): systematic review and meta-analysis. *Heart Failure Reviews*, 1, 1–23. <https://doi.org/10.1007/S10741-021-10204-8/FIGURES/2>
- Kalp Yetersizliği Çalışma Grubu - Türk Kardiyoloji Derneği. (2022), https://tkd.org.tr/kalp-yetersizligi-calisma-grubu/sayfa/toplum_icin_bilgiler#a3 adresinden 21 Ekim 2022 tarihinde alınmıştır.
- Karabayir, I., Butler, L., Kitzman, D., Alonso, A., Tison, G., Chen, L. Y., Clifford, G., Soliman, E. Z., & Akbilgic, O. (2022). PO-703-04 ECG-AI CAN PREDICT RISK FOR HEART FAILURE WITH BOTH PRESERVED AND REDUCED EJECTION FRACTION. *Heart Rhythm*, 19(5), S447. <https://doi.org/10.1016/j.hrthm.2022.03.1058>
- Kavsaoglu, A. R. (2014). *PPG (Fotoplethysmografi) Sinyalleri ile Biyometrik Tanıma Sistemi* [Doktora Tezi]. Sakarya University.
- Kier, C., ve Aach, T. (2006). Predicting the benefit of sample size extension in multiclass k-NN classification. *Proceedings - International Conference on Pattern Recognition*, 3, 332–335. <https://doi.org/10.1109/ICPR.2006.942>
- Kim, H.-Y. (2013). Statistical notes for clinical researchers: assessing normal distribution (2) using skewness and kurtosis. *Restorative Dentistry ve Endodontics*, 38(1), 52–54. <https://doi.org/10.5395/RDE.2013.38.1.52>
- Kleiger, R. E., Miller, J. P., Bigger, J. T., ve Moss, A. J. (1987). Decreased heart rate variability and its association with increased mortality after acute myocardial infarction. *The American Journal of Cardiology*, 59(4), 256–262. [https://doi.org/10.1016/0002-9149\(87\)90795-8](https://doi.org/10.1016/0002-9149(87)90795-8)

- Kolukisa, B., Hacilar, H., Goy, G., Kus, M., Bakir-Gungor, B., Aral, A., Gungor, V. C., İşlem, K. B., Sistemleri, T., ve Ankara, A. Ş. (2019). *Diagnosis of Coronary Heart Disease via Classification Algorithms and a New Feature Selection Methodology*. 1(1).
- Kota, P., Madenahalli, A., Guturi, R., Nukala, B., Nagaraj, S., Kota, S., ve Chandra Neeli, P. (2021). Heart disease classification comparison among patients and normal subjects using machine learning and artificial neural network techniques. *International Journal of Biosensors ve Bioelectronics*, Volume 7(Issue 3). <https://doi.org/10.15406/IJBSBE.2021.07.00216>
- Kulkarni, T. R., ve Dushyanth, N. D. (2021). Performance evaluation of deep learning models in detection of different types of arrhythmia using photo plethysmography signals. *International Journal of Information Technology (Singapore)*, 13(6), 2209–2214. <https://doi.org/10.1007/S41870-021-00795-8/FIGURES/3>
- Kwon, J., Kim, K.-H., Eisen, H. J., Cho, Y., Jeon, K.-H., Lee, S. Y., Park, J., ve Oh, B.-H. (2021). Artificial intelligence assessment for early detection of heart failure with preserved ejection fraction based on electrocardiographic features. *European Heart Journal - Digital Health*, 2(1), 106–116. <https://doi.org/10.1093/EHJDH/ZTAA015>
- Kwon, J. M., Lee, S. Y., Jeon, K. H., Lee, Y., Kim, K. H., Park, J., Oh, B. H., ve Lee, M. M. (2020). Deep learning–based algorithm for detecting aortic stenosis using electrocardiography. *Journal of the American Heart Association*, 9(7), 14717. <https://doi.org/10.1161/JAHA.119.014717>
- Laghari, W. M., Baloch, M. U., Mengal, M. A., ve Shah, S. J. (2014). Performance Analysis of Analog Butterworth Low Pass Filter as Compared to Chebyshev Type-I Filter, Chebyshev Type-II Filter and Elliptical Filter. *Circuits and Systems*, 2014(09), 209–216. <https://doi.org/10.4236/CS.2014.59023>
- Liang, J., Qin, Z., Xue, L., Lin, X., ve Shen, X. (2021). Efficient and Privacy-Preserving Decision Tree Classification for Health Monitoring Systems. *IEEE Internet of Things Journal*, 8(16), 12528–12539. <https://doi.org/10.1109/JIOT.2021.3066307>
- Lim, G. B. (2021). AI identifies distinct subgroups of HFpEF. *Nature Reviews Cardiology* 2021 18:6, 18(6), 387–387. <https://doi.org/10.1038/s41569-021-00545-0>
- Lin, Z., Gao, Y., Chen, Y., Ge, Q., Mahara, G., ve Zhang, J. (2020). Automated detection of myocardial infarction using robust features extracted from 12-lead ECG. *Signal, Image and Video Processing*, 14(5), 857–865. <https://doi.org/10.1007/S11760-019-01617-Y/TABLES/4>
- Malliani, A., Lombardi, F., Pagani, M., ve Cerutti, S. (1994). Power spectral analysis of cardiovascular variability in patients at risk for sudden cardiac death. *Journal of cardiovascular electrophysiology*, 5(3), 274–286. <https://doi.org/10.1111/J.1540-8167.1994.TB01164.X>
- Masetic, Z., ve Subasi, A. (2016). Congestive heart failure detection using random forest classifier. *Computer Methods and Programs in Biomedicine*, 130, 54–64. <https://doi.org/10.1016/J.CMPB.2016.03.020>

- McDonagh, T. A., Metra, M., Adamo, M., Gardner, R. S., Baumbach, A., Böhm, M., Burri, H., Butler, J., Čelutkienė, J., Chioncel, O., Cleland, J. G. F., Coats, A. J. S., Crespo-Leiro, M. G., Farmakis, D., Gilard, M., Heymans, S., Hoes, A. W., Jaarsma, T., Jankowska, E. A., ... Skibelund, A. K. (2021). 2021 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure Developed by the Task Force for the diagnosis and treatment of acute and chronic heart failure of the European Society of Cardiology (ESC) With the special contribution of the Heart Failure Association (HFA) of the ESC. *European Heart Journal*, 42(36), 3599–3726. <https://doi.org/10.1093/EURHEARTJ/EHAB368>
- McKnight, P. E., ve Najab, J. (2010). Kruskal-Wallis Test. *The Corsini Encyclopedia of Psychology*, 1–1. <https://doi.org/10.1002/9780470479216.CORPSY0491>
- McKnight, P. E., ve Najab, J. (2010). Mann-Whitney U Test. *The Corsini Encyclopedia of Psychology*, 1–1. <https://doi.org/10.1002/9780470479216.CORPSY0524>
- Mukala, V., Traille, A. N., Lakafošis, V., ve Tentzeris, M. M. (2010). Design and development of a novel wireless EKG system utilizing the low-power Zigbee standard. *2010 IEEE International Symposium on Antennas and Propagation and CNC-USNC/URSI Radio Science Meeting - Leading the Wave, AP-S/URSI 2010*. <https://doi.org/10.1109/APS.2010.5562030>
- Musialik-Łydka, A., Średniawa, B., ve Pasyk, S. (2003). Heart rate variability in heart failure. *Kardiologia Polska (Polish Heart Journal)*, 58(1), 14–16. https://journals.viamedica.pl/kardiologia_polska/article/view/82267
- Muthunayagam, M., ve Ganesan, K. (2022). Identification of systolic and diastolic heart failure progression with Krawtchouk moment feature-aided Harris hawks optimized support vector machine. *Signal, Image and Video Processing*, 16(1), 127–135. <https://doi.org/10.1007/S11760-021-01978-3/FIGURES/7>
- Nagueh, S. F., Appleton, C. P., Gillebert, T. C., Marino, P. N., Oh, J. K., Smiseth, O. A., Waggoner, A. D., Flachskampf, F. A., Pellikka, P. A., ve Evangelista, A. (2009). Recommendations for the Evaluation of Left Ventricular Diastolic Function by Echocardiography. *Journal of the American Society of Echocardiography*, 22(2), 107–133. <https://doi.org/10.1016/J.ECHO.2008.11.023>
- Nagueh, S. F., Middleton, K. J., Kopelen, H. A., Zoghbi, W. A., ve Quiñones, M. A. (1997). Doppler Tissue Imaging: A Noninvasive Technique for Evaluation of Left Ventricular Relaxation and Estimation of Filling Pressures. *Journal of the American College of Cardiology*, 30(6), 1527–1533. [https://doi.org/10.1016/S0735-1097\(97\)00344-6](https://doi.org/10.1016/S0735-1097(97)00344-6)
- Orea-Tejeda, A., José orozco-Gutiérrez, J., Castillo-Martínez, L., Keirns-Davies, C., Montañó-Hernández, P., Vázquez-Díaz, O., Valdespino-Trejo, A., Infante, O., ve Martínez-Memije, R. (2010). The effect of L-arginine and citrulline on endothelial function in patients in heart failure with preserved ejection fraction. *Cardiology journal*, 17(5), 464–470. <https://pubmed.ncbi.nlm.nih.gov/20865676/>

- Özen Kavas, P., Recep Bozkurt, M., Kocayiğit, İ., ve Bilgin, C. (2022). A New Medical Decision Support System for Diagnosing HF_rEF and HF_pEF using ECG and Machine Learning Techniques. IEEE Access. <https://doi.org/10.1109/ACCESS.2022.3213065>
- Özen Kavas, P., Recep Bozkurt, M., Kocayiğit, İ., ve Bilgin, C. (2023). Machine learning-based medical decision support system for diagnosing HF_pEF and HF_rEF using PPG. *Biomedical Signal Processing and Control*, 79, 104164. <https://doi.org/10.1016/J.BSPC.2022.104164>
- Pandey, A., Omar, W., Ayers, C., LaMonte, M., Klein, L., Allen, N. B., Kuller, L. H., Greenland, P., Eaton, C. B., Gottdiener, J. S., Lloyd-Jones, D. M., ve Berry, J. D. (2018). Sex and race differences in lifetime risk of heart failure with preserved ejection fraction and heart failure with reduced ejection fraction. *Circulation*, 137(17), 1814–1823. <https://doi.org/10.1161/CIRCULATIONAHA.117.031622/-/DC1>
- Pandey, V., ve Giri, V. K. (2016). High frequency noise removal from ECG using moving average filters. *International Conference on Emerging Trends in Electrical, Electronics and Sustainable Energy Systems, ICETEESES 2016*, 191–195. <https://doi.org/10.1109/ICETEESES.2016.7581383>
- Paulus, W. J., Tschöpe, C., Sanderson, J. E., Rusconi, C., Flachskampf, F. A., Rademakers, F. E., Marino, P., Smiseth, O. A., De Keulenaer, G., Leite-Moreira, A. F., Borbély, A., Édes, I., Handoko, M. L., Heymans, S., Pezzali, N., Pieske, B., Dickstein, K., Fraser, A. G., ve Brutsaert, D. L. (2007). How to diagnose diastolic heart failure: a consensus statement on the diagnosis of heart failure with normal left ventricular ejection fraction by the Heart Failure and Echocardiography Associations of the European Society of Cardiology. *European Heart Journal*, 28(20), 2539–2550. <https://doi.org/10.1093/EURHEARTJ/EHM037>
- Plati, D. K., Tripoliti, E. E., Karanasiou, G. S., Rammos, A., Bechlioulis, A., Watson, C. J., McDonald, K., Ledwidge, M., Goletsis, Y., Naka, K. K., ve Fotiadis, D. I. (2022). Machine Learning Techniques for Predicting and Managing Heart Failure. *Predicting Heart Failure*, 189–226. <https://doi.org/10.1002/9781119813040.CH9>
- Ponikowski, P., Voors, A. A., Anker, S. D., Bueno, H., Cleland, J. G. F., Coats, A. J. S., Falk, V., González-Juanatey, J. R., Harjola, V. P., Jankowska, E. A., Jessup, M., Linde, C., Nihoyannopoulos, P., Parissis, J. T., Pieske, B., Riley, J. P., Rosano, G. M. C., Ruilope, L. M., Ruschitzka, F., ... Davies, C. (2016). 2016 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure: The Task Force for the diagnosis and treatment of acute and chronic heart failure of the European Society of Cardiology (ESC) Developed with the special contribution of. *European heart journal*, 37(27), 2129–2200m. <https://doi.org/10.1093/EURHEARTJ/EHW128>
- Ranganathan, P., Pramesh, C., ve Aggarwal, R. (2017). Common pitfalls in statistical analysis: Measures of agreement. *Perspectives in Clinical Research*, 8(4), 187. https://doi.org/10.4103/PICR.PICR_123_17

- Rich, J. D., Burns, J., Freed, B. H., Maurer, M. S., Burkhoff, D., ve Shah, S. J. (2018). Meta-Analysis Global Group in Chronic (MAGGIC) Heart Failure Risk Score: Validation of a Simple Tool for the Prediction of Morbidity and Mortality in Heart Failure With Preserved Ejection Fraction. *Journal of the American Heart Association*, 7(20). <https://doi.org/10.1161/JAHA.118.009594>
- Rubins, U., Grabovskis, A., Grube, J., ve Kukulis, I. (2008). Photoplethysmography Analysis of Artery Properties in Patients with Cardiovascular Diseases. *IFMBE Proceedings*, 20 *IFMBE*, 319–322. https://doi.org/10.1007/978-3-540-69367-3_85
- Salinet, J. L., ve Luppi Silva, O. (2018). ECG signal acquisition systems. *Developments and Applications for ECG Signal Processing: Modeling, Segmentation, and Pattern Recognition*, 29–51. <https://doi.org/10.1016/B978-0-12-814035-2.00008-6>
- Sandhu, M., ve Kaur, S. (2016). A Study on Design and Implementation of Butterworth, Chebyshev and Elliptic Filter with MatLab. *International Journal of Emerging Technologies in Engineering Research (IJETER)*, 4(6). www.ijeter.everscience.org
- Savji, N., Meijers, W. C., Bartz, T. M., Bhambhani, V., Cushman, M., Naylor, M., Kizer, J. R., Sarma, A., Blaha, M. J., Gansevoort, R. T., Gardin, J. M., Hillege, H. L., Ji, F., Kop, W. J., Lau, E. S., Lee, D. S., Sadreyev, R., van Gilst, W. H., Wang, T. J., ... Ho, J. E. (2018). The Association of Obesity and Cardiometabolic Traits With Incident HFpEF and HFrEF. *JACC: Heart Failure*, 6(8), 701–709. <https://doi.org/10.1016/J.JCHF.2018.05.018>
- Sbrollini, A., De Jongh, M. C., Ter Haar, C. C., Treskes, R. W., Man, S., Burattini, L., ve Swenne, C. A. (2019). Serial electrocardiography to detect newly emerging or aggravating cardiac pathology: A deep-learning approach. *BioMedical Engineering Online*, 18(15), 1–17. <https://doi.org/10.1186/S12938-019-0630-9/FIGURES/6>
- Schack, T., Safi Harb, Y., Muma, M., ve Zoubir, A. M. (2017). Computationally efficient algorithm for photoplethysmography-based atrial fibrillation detection using smartphones. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 104–108. <https://doi.org/10.1109/EMBC.2017.8036773>
- Selvaraj, S., Myhre, P. L., Vaduganathan, M., Claggett, B. L., Matsushita, K., Kitzman, D. W., Borlaug, B. A., Shah, A. M., ve Solomon, S. D. (2020). Application of Diagnostic Algorithms for Heart Failure With Preserved Ejection Fraction to the Community. *JACC: Heart Failure*, 8(8), 640–653. <https://doi.org/10.1016/J.JCHF.2020.03.013>
- Shah, A. J., Isakadze, N., Levantsevych, O., Vest, A., Clifford, G., ve Nemati, S. (2020). Detecting heart failure using wearables: a pilot study. *Physiological Measurement*, 41(4), 044001. <https://doi.org/10.1088/1361-6579/AB7F93>
- Sharma, S., Mather, P., Efird, J. T., Kahn, D., Cheema, M., Rubin, S., Reeves, G., Bonita, R., Malloy, R., ve Whellan, D. J. (2015). Photoplethysmographic Signal to Screen Sleep-Disordered Breathing in Hospitalized Heart Failure Patients: Feasibility of a Prospective Clinical Pathway. *JACC: Heart Failure*, 3(9), 725–731. <https://doi.org/10.1016/J.JCHF.2015.04.015>

- Silber, H. A., Trost, J. C., Johnston, P. V., Lowell Maughan, W., Wang, N. Y., Kasper, E. K., Aversano, T. R., ve Bush, D. E. (2012). Finger photoplethysmography during the Valsalva maneuver reflects left ventricular filling pressure. *American journal of physiology. Heart and circulatory physiology*, 302(10). <https://doi.org/10.1152/AJPHEART.00609.2011>
- Stein, P. K., Bosner, M. S., Kleiger, R. E., ve Conger, B. M. (1994). Heart rate variability: a measure of cardiac autonomic tone. *American heart journal*, 127(5), 1376–1381. [https://doi.org/10.1016/0002-8703\(94\)90059-0](https://doi.org/10.1016/0002-8703(94)90059-0)
- Tamura, T., Maeda, Y., Sekine, M., ve Yoshida, M. (2014). Wearable Photoplethysmographic Sensors—Past and Present. *Electronics 2014*, Vol. 3, Pages 282-302, 3(2), 282–302. <https://doi.org/10.3390/ELECTRONICS3020282>
- Tanveer, M., Rajani, T., Rastogi, R., Shao, Y. H., ve Ganaie, M. A. (2022). Comprehensive review on twin support vector machines. *Annals of Operations Research*, 1–46. <https://doi.org/10.1007/S10479-022-04575-W/TABLES/8>
- Taunk, K., De, S., Verma, S., ve Swetapadma, A. (2019). A brief review of nearest neighbor algorithm for learning and classification. *2019 International Conference on Intelligent Computing and Control Systems, ICCS 2019*, 1255–1260. <https://doi.org/10.1109/ICCS45141.2019.9065747>
- Toinga, S., Carabali, C., ve Ortega, L. (2018). Development of a didactic platform for teaching the Einthoven's Triangle. *2017 IEEE 2nd Ecuador Technical Chapters Meeting, ETCM 2017, 2017-Janua*, 1–6. <https://doi.org/10.1109/ETCM.2017.8247542>
- Uçar, M. K., Bozkurt, M. R., Bilgin, C., ve Polat, K. (2018). Automatic sleep staging in obstructive sleep apnea patients using photoplethysmography, heart rate variability signal and machine learning techniques. *Neural Computing and Applications*, 29(8), 1–16. <https://doi.org/10.1007/S00521-016-2365-X/FIGURES/10>
- Uçar, M. K., Moran, İ., Turgay Altılar, D., Bilgin, C., ve Bozkurt, M. R. (2018). Kronik Obstrüktif Akciğer Hastalığı ile Elektrokardiyogram Sinyali Arasındaki İlişkinin İstatistiksel Olarak İncelenmesi. *Journal of Human Rhythm*, 4(3), 142–149.
- Uçar, M. K. (2017). *Obstrüktif Uyku Apne Teşhisi için Makine Öğrenmesi Tabanlı Yeni Bir Yöntem Geliştirilmesi* [Doktora Tezi]. Sakarya Üniversitesi.
- Vidya, M. J., ve Sadasiv, S. (2013). A Comparative Study on Removal of Noise in ECG Signal Using Different Filters. *International Journal of Innovative Research and Development*, 2(4), 915–927. http://internationaljournalcorner.com/index.php/ijird_ojs/article/view/133358
- Waller, A. D. (1889). IV. On the electromotive changes connected with the beat of the mammalian heart, and of the human heart in particular. *Philosophical Transactions of the Royal Society of London. (B.)*, 180, 169–194. <https://doi.org/10.1098/RSTB.1889.0004>

- Yavuz, O., Can Bayram, M., Yıldırım, T., ve Haberleşme Mühendisliği Bölümü, E., ve Teknik Üniversitesi, Y. (2007). *Chebyshev Filtre Parametrelerinin Yapay Sinir Ağları Kullanılarak Hesaplanması. EMO Elektrik-Elektronik-Bilgisayar Mühendisliği 12. Ulusal Kongresi.*
- Zhang, Y., ve Xia, M. (2020). Application of Deep Neural Network for Congestive Heart Failure Detection Using ECG Signals. *Journal of Physics: Conference Series*, 1642(1), 012021. <https://doi.org/10.1088/1742-6596/1642/1/012021>



ÖZGEÇMİŞ

Ad-Soyad : Pınar ÖZEN

ÖĞRENİM DURUMU:

- **Lisans** : 2008, İstanbul Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü
- **Yüksek Lisans** : 2012, Dumlupınar Üniversitesi, Elektrik-Elektronik Mühendisliği

TEZDEN TÜRETİLEN ESERLER:

- Özen Kavas, P., Bozkurt ,M.R., Kocayığit İ. ve Bilgin C. 2022. A New Medical Decision Support System for Diagnosing HFrEF and HFpEF using ECG and Machine Learning Techniques. *IEEE Access*, 10, 107283-107292.
- Özen Kavas, P., Bozkurt ,M.R., Kocayığit İ. ve Bilgin C. 2023. Machine learning-based medical decision support system for diagnosing HFpEF and HFrEF using PPG. *Biomedical Signal Processing and Control*, 79, 104164.
- Özen Kavas, P., Bozkurt ,M.R., (2023). DETECTION OF HFrEF AND HFpEF USING PPG-DERIVED HRV WITH MACHINE LEARNING METHODS. *Journal of Scientific Reports-A*.

DİĞER ESERLER: