



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



**MOBİL UYGULAMADA DVM  
ALGORİTMASI KULLANILARAK  
KARDİYAK SORUNLARIN TESPİT  
EDİLMESİ**  
**Mustafa Hasan Najm ALGBURI**

**YÜKSEK LİSANS TEZİ**

**Bilgisayar Mühendisliği Anabilim Dalı**

**EKİM-2019**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Mustafa Hasan Najm ALGBURI tarafından hazırlanan “**MOBİL UYGULAMADA DVM ALGORİTMASI KULLANILARAK KARDİYAK SORUNLARIN TESPİT EDİLMESİ**” adlı tez çalışması 03/10/2019 tarihinde aşağıdaki jüri tarafından oy birliği ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Dr.Öğr.Üyesi Nurdan BAYKAN

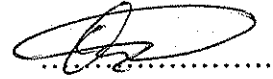
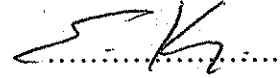
#### Danışman

Dr.Öğr.Üyesi Ersin KAYA

#### Üye

Dr.Öğr.Üyesi Ahmet ÖZKİŞ

### İmza



Yukarıdaki sonucu onaylarım.

Prof. Dr. Mustafa YILMAZ  
FBE Müdürü

## TEZ BİLDİRİMİ

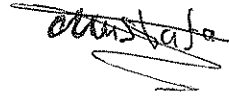
Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Mustafa Hasan Najm ALGBURI

Tarih: 03/10/2019



**ÖZET****YÜKSEK LİSANS TEZİ****MOBİL UYGULAMADA DVM ALGORİTMASI KULLANILARAK  
KARDİYAK SORUNLARIN TESPİT EDİLMESİ****Mustafa Hasan Najm ALGBURİ****Selçuk Üniversitesi Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı****Danışman: Dr.Öğr. Üyesi Ersin KAYA****2019, 67 Sayfa****Jüri****Dr.Öğr. Üyesi Ersin KAYA  
Dr.Öğr. Üyesi Nurdan BAYKAN  
Dr.Öğr. Üyesi Ahmet ÖZKİŞ**

Kalp hastalıkları, dünya çapında ölümlerin önde gelen nedenlerinden biridir. Amerika Birleşik Devletleri'nde her yıl yaklaşık 610.000 insan kalp hastalığından ölmektedir. Bu her dört ölümden biri demektir. EKG aritmi sınıflandırması, kalp hastalığı tanısında önemli bir yöntemdir. Son yıllarda, EKG özellik çıkarma teknikleri dünyadaki araştırmacıların ilgisini çekmiş ve EKG sinyal analizi için sayısız yaklaşımlar geliştirilmiştir. Önerilen yöntemler çoğunlukla yapay sinir ağlarına dayanmaktadır. Bu tezde, KNN (K-en yakın komşu) ve DVM (Destek vektör makineleri) algoritmaları kullanılarak aritmi sınıflandırması yapılmıştır. Tezde ventriküler bigemine, ventriküler taşikardi ve ventriküler trigemine olmak üzere üç aritmi üzerinde durulmuştur. MIT-BIH veri seti ile öncelikle KNN ve DVM sınıflandırıcılarının sınıflandırma başarısı test edilmiştir. Test için KNN, 3 ve 5 komşuluk için test edilirken; DVM ise doğrusal çekirdekli ve RBF çekirdekli olarak test edilmiştir. Elde edilen sonuçlara göre RBF tabanlı DVM en iyi sonucu vermiştir. Daha sonra tez kapsamında, CardioChip (BMD101) kullanılarak giyilebilir bir EKG cihazı tasarımı yapılmıştır. EKG cihazı, geliştirilen Android tabanlı bir akıllı telefon uygulamasına Bluetooth bağlantısı ile bağlanmıştır. Geliştirilen uygulama ile RBF çekirdekli DVM kullanılarak online EKG sınıflandırması yapılmıştır.

**Anahtar Kelimeler:** Aritmiler, EKG, KNN, DVM, Ventriküler Bigemine, Ventriküler taşikardi, Ventriküler Trigemine.

**ABSTRACT****MS THESIS****DETERMINATION OF CARDIAC PROBLEMS USING SVM ALGORITHM IN  
MOBILE APPLICATION****Mustafa Hasan Najm ALGBURİ****THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF  
SELCUK UNIVERSITY  
THE DEGREE OF MASTER OF SCIENCE  
IN COMPUTER ENGINEERING****Advisor: Assist. Prof. Dr. Ersin KAYA  
2019, 67 Pages****Jury****Assist. Prof. Dr. Ersin KAYA  
Assist. Prof. Dr. Nurdan BAYKAN  
Assist. Prof. Dr. Ahmet ÖZKIŞ**

Heart diseases are one of the leading causes of death worldwide. In the United States, approximately 610,000 people die of heart disease each year. That means one in four deaths. ECG arrhythmia classification is an important method in the diagnosis of heart disease. In recent years, ECG feature extraction techniques have attracted the attention of researchers around the world and numerous approaches have been developed for ECG signal analysis. The proposed methods are mostly based on artificial neural networks. In this thesis, arrhythmia classification is made by using KNN (K-Nearest Neighbor) and SVM (Support Vector Machines) algorithms. Three arrhythmias, ventricular bigeminy, ventricular tachycardia and ventricular trigeminy, are discussed. With the MIT-BIH dataset, firstly the classification success of KNN and SVM classifiers was tested. For testing, the KNN is tested for 3 and 5 neighborhoods; SVM was tested with linear kernel and RBF kernel. According to the results, RBF-based SVM gave the best results. Later on, a wearable ECG device was designed using CardioChip (BMD101). The ECG device is connected to a developed Android-based smartphone application via Bluetooth connection. With the developed application, online ECG classification was made by using SVM with RBF kernel.

**Anahtar Kelimeler:** Arrhythmias, ECG, KNN, SVM, Ventricular bigeminy, Ventricular tachycardia, Ventricular trigeminy.

## ÖNSÖZ

Bu tez çalışmasında, mobil uygulamada DVM kullanılarak aritmiye dayanan kardiyak sorunların tespit edilmesi için bir uygulama gerçekleştirilmiştir. Bu çalışmada kullandığımız CardioChip (BMD101) cihazı hastanın kalp sinyallerini almak ve MIT-BIH verisetine göre teşhis etmek için programlanmıştır.

Çalışmamda bana her türlü yardımcı olan, bilgilerinden faydalandığım, seçtiğim konu hakkında bana desteğini esirgemeyen değerli danışman hocam Sayın Dr. Öğr. Üyesi Ersin KAYA'ya teşekkürlerimi sunarım. Tüm bu çalışmalar süresinde bana yardımcı olan, her türlü destek ve moral veren aileme ve özellikle canım anneme MAJIDA ABDULJABBAR, beni her zaman ve her konuda desteklediği için teşekkürlerimi sunuyorum.

Mustafa Hasan Najm ALGBURI

KONYA-2019

## İÇİNDEKİLER

<b>ÖZET .....</b>	<b>i</b>
<b>ABSTRACT.....</b>	<b>ii</b>
<b>ÖNSÖZ .....</b>	<b>iii</b>
<b>İÇİNDEKİLER .....</b>	<b>iv</b>
<b>KISALTMALAR .....</b>	<b>v</b>
<b>1. GİRİŞ .....</b>	<b>1</b>
1.1. Tezin Amacı:.....	2
1.2. Tezin Önemi: .....	3
<b>2. KAYNAK ARAŞTIRMASI .....</b>	<b>4</b>
2.1 Bulanık Tabanlı Teknikler .....	5
2.2 Kaba Küme Teorisi ve Gizli Markov Modelleri.....	6
2.3 Yapay Sinir Ağlarına Dayalı Yaklaşımlar .....	8
2.4 Destek Vektör Makineleri Kullanılan Yaklaşımlar .....	9
2.5 Genetik Algoritmaları Kullanan Yaklaşımlar .....	11
2.6 Hibrit Algoritmalar .....	11
<b>3. MATERYAL VE YÖNTEM.....</b>	<b>13</b>
3.1 Materyal .....	13
3.1.1. Elektrokardiyografi (EKG) .....	13
3.1.2 MIT-BIH VeriKümesi .....	15
3.1.3 MIT-BIH Ön İşlemler ve Gürültü Giderme.....	17
3.1.3.1 Ayrık Dalgacık Dönüşümü ile Gürültü Giderme.....	17
3.1.3.2 K-Kez Çapraz Doğrulama Yöntemi: .....	20
3.1.4. Analog Ön Uç (AFE).....	21
3.1.5. CardioChip (BMD101) .....	22
3.2. Yöntem.....	25
3.2.1 KNN (K-En Yakın Komşu) .....	25
3.2.2 DVM (Destek Vektör Makinesi) .....	26
3.2.3 Çekirdek Fonksiyonları ile Oluşturulan DVM .....	31
3.2.4 Karmaşıklık Matrisi .....	32
3.2.5 MIT-BIH Veri Setini Kullanarak DVM Algoritmasının Eğitimi .....	35
3.2.6 Akıllı Telefon Uygulaması .....	36
<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>	<b>41</b>
<b>5. SONUÇLAR VE ÖNERİLER .....</b>	<b>60</b>
5.1 Sonuçlar .....	60
5.2 Öneriler .....	61
<b>KAYNAKLAR .....</b>	<b>63</b>

## KISALTMALAR

### Kısaltmalar

$F_{HCO}$ : Yüksek kesme frekansı (High cutoff frequency)

$F_{LCO}$ : Düşük kesme frekansı (Low cutoff frequency)

$G_{notch}$  : Çentik filtresi kazancı (50 Hz ve 60 Hz) (Notch filter gain (50 Hz and 60 Hz))

$I_{standby}$ : Bekleme akımı (CS pimi düşük bağlı) (Standby current (CS pin tied low))

$V_{sense}$  : Analog giriş çalışma voltajı (Analog input operating voltage)

$V_{IH}$  : Dijital “1” giriş voltajı (Digital “1” input voltage)

$V_{IL}$  : Dijital “0” giriş voltajı (Digital “0” input voltage)

$V_{OH}$  : Dijital çıkış gerilimi (Digital output voltage)

$V_{OL}$  : Dijital çıkış gerilimi (Digital output voltage)

$T_{op}$  : Çalışma sıcaklığı (Operating temperature<sup>5</sup>)

ADC: Analog Dijital Dönüştürücü (Analog Digital Converter)

AFE: Analog Ön Uç (Analog Front-End)

ANN: Yapay Sinir Ağları (Artificial Neural Networks)

AUC: Eğrinin altındaki alan (area under the curve)

BSPMs: Vücut Yüzey Potansiyel Haritaları (Body Surface Potential Maps)

CAD: Koroner Arter Hastalıkları (Coronary Artery Diseases)

CMRR: Ortak mod reddetme oranı (Common mode rejection ratio)

DSP: Dijital sinyal işleme (Digital signal processing)

ECG: Elektrokardiyografi (Electrocardiography)

FCA: Resmi Konsept Analizi (Formal Concept Analysis)

HBM: Analog giriş EDS gerilimi (Analog Input EDS voltage)

HMMs: Gizli Markov Modelleri (Hidden Markov Models)

IDD: Giriş işletme gücü akımı (Input operating power current)

KNN: K- En Yakın Komşu (k-nearest neighbors)

LAD: Sol Ön Azalan (Left Anterior Descending)

LCx: Sol Circumflex (left Circumflex)

LNA: Düşük Gürültü Yükselteci (Low-Noise-Amplifier)

- MHR: Maksimum kalp atış hızı (Maximum Heart Rate)
- MI: Miyokardiyal enfarktüs (Myocardial Infarction)
- MLP: Çok Katmanlı Perceptron modeli (Multilayer Perceptron model)
- N/A: UART baud hızı (UART baud rate)
- NSR: Normal sinüs ritmi (Normal Sinus Rhythm)
- PCA: Temel bileşenler Analizi (Principal Component Analysis)
- PSRR: Güç kaynağı reddetme oranı (Power supply rejection ratio)
- PTCA: Perkütan Transluminal Koroner Anjiyoplasti (Percutaneous Transluminal Coronary Angioplasty)
- RCA: Sağ Koroner Arter (Right Coronary Artery)
- ROC: Alıcı çalışma özellikleri (Receiver Operating Characteristics)
- RST: Kaba Küme Teorisi (Rough Set Theory)
- SNR: Sinyal gürültü oranı (Signal to noise ratio)
- SoC: Çip Üzerine Sistem (System-on-Chip)
- SPP: Seri Port Profili (Serial Port Profile)
- STEMI: Segment Yükselmesi Miyokard Enfarktüsü (Segment Elevation Myocardial Infarction)
- SVM: Destek Vektör Makinesi (Support Vector Machine)
- TIFF: Etiketli Resim Dosyası Biçimi (Tagged Image File Format)
- UART: Evrensel Asenkron Alıcı / Verici (Universal asynchronous receiver-transmitter)
- VDD: Giriş işletme voltajı (Input operating power voltage)
- WT: Dalgacık dönüşümü (Wavelet Transform)

## 1. GİRİŞ

Büyüyen, gelişen ve sınırların ortadan kalktığı çağımızda, insan hayatının kolaylaştırılması adına bilim ve teknolojide birçok gelişmeler olmaktadır. Bu gelişmelerin temelinde insan hayatını daha kaliteli, daha sağlıklı ve daha uzun ömürlü hale getirebilmek yatmaktadır. Bu amaçla, diğer sektörlerde olduğu gibi sağlık sektöründe de birçok yeni uygulama hayata geçirilmektedir.

Nüfusun hızla artmasına karşılık sağlık alanındaki fiziki koşullar da gün geçtikçe yetersiz kalmaktadır. Çoğu zaman hastanelerde, polikliniklerde ve sağlık kurumlarında yüksek yoğunluk yaşanmaktadır. Ayrıca doktor sayısının yetersiz hale gelmesi de hastaların tedavilerinde kesintilere ve aksamalara yol açmaktadır (Yücel ve ark., 2010). Yaşanan tüm bu problemlerin çözülebilmesi için son yıllarda yeni arayışlara gidilmiştir. Bunlardan bazıları da tele-tıp ve tele-sağlık konularıdır. Tele-tıp ve tele-sağlık, günümüzde sağlık sektörünün çok ilgi gören alanlarından olmuştur. Bu iki terim birbirine çok karıştırılsa da aslında farklı amaçları içermektedir. Tele-tıp, farklı yerlerde bulunan doktorların ve hastaların iletişim teknolojileri ve özel tıbbi donanımlar ile bir araya getirilmesidir. Tele-sağlık ise daha çok toplumun ya da belirli bir hasta grubunun sağlık bilincinin ve korunma önlemlerinin arttırıldığı alandır. Yani tele-tıp, tele-sağlık hizmetlerinin klinik uygulamalarını ve ayrıca hasta takibini ve tedavisini içerir. Örneğin doktor farklı bir ülkedeki hastasına rahatlıkla bulunduğu yerden konsültasyonda bulunabilmektedir (Aktürk, 2009).

Tele-tıp uygulamaları özellikle kronik ve uzun süreli takip gerektiren hastalıklarda çok iyi sonuçlar vermektedir. Bununla birlikte “Home-Care” olarak bilinen evde bakım hizmetlerinde de tele-tıp uygulamaları her yaş grubundan insanın hastane ortamından uzak, kendi sosyal alanları içinde hastalıklarının takibini ve tedavisini sağlamaktadır. Bu noktada ise giyilebilir sistemler, evde bakım hizmetlerinin sağlanmasında oldukça önemli bir yere sahip olmuştur. Çünkü giyilebilir sistemler, hastane ortamı gerektirmeden hastalıkların doğru ve sürekli olarak teşhisini ve takibini sağlamaktadır. Giyilebilir EKG cihazı da bu sistemlerin önemli bir parçası olmuştur (Garshnek ve Burkle Jr, 1999).

Elektrokardiyografi (EKG), kalbin elektriksel aktivitesinin elektrotlar yardımıyla ölçülmesi ve kaydedilmesi işlemidir. Aynı zamanda çeşitli kalp hastalıklarını belirlemek için invaziv olmayan en basit teşhis yöntemlerinden biridir. EKG dalgalarının özellikleri doktorlar tarafından incelenir, yorumlanır ve kalp atışının normal sinüs ritmine mi

yoksa aritmi sınıfına mı ait olduğuna karar verilir. Bilgisayarlı elektrokardiyografi, insana ait kardiyak problemlerin teşhisi için kullanılan köklü bir uygulamadır. Elektrokardiyografik sinyalleri zamanında ve doğru bir şekilde sınıflandırmak ve buna yönelik otomatik sistemler geliştirmek için bu zamana kadar birçok algoritma önerilmiştir.

EKG, atrium ve ventriküllerin depolarizasyonu ve repolarizasyonu ile oluşan elektriksel aktivitenin yönü ve büyüklüğünün gerçek bir kayıdır. Kardiyak sinyaller, P-QRS-T dalgalarından oluşur (Pan ve Tompkins, 1985).

EKG, doktorun hastanın durumunu takip etmesine yardımcı olur. Bu nedenle EKG sinyalinden elde edilen özellikler, kalp rahatsızlığının teşhisinde hayati bir öneme sahiptir (Li ve ark., 1995; Martínez ve ark., 2004). Günümüzde EKG sinyallerini analiz etmek ve sınıflandırmak için çeşitli araştırma ve algoritmalar önerilmiştir (Gaamouri ve ark., 2018). Son on yılda önerilen sınıflandırma süreci; Dijital Sinyal Analizi, Bulanık Mantık Yöntemleri (Goel ve ark., 2016), Yapay Sinir Ağı (Jadhav ve ark., 2012), Gizli Markov Modeli, Genetik Algoritmalar, Destek Vektör Makineleri (DVM), Kendi Kendini Düzenleyen Harita, Bayes ve diğer yöntemlerle gerçekleştirilmiştir (Schukat ve ark., 2004).

Bu tezde, MIT-BIH veri tabanı kullanılarak DVM algoritması eğitilmiştir. Eğitilmiş olan DVM algoritması MIT-BIH veri tabanına göre, giyilebilir EKG cihazıyla alınan kalp sinyallerinin vaka türünü sınıflandırmak için kullanılmıştır. Buna göre üç kardiyak problem tespit edilmiştir. Bunlar; ventriküler bigemine, ventriküler taşikardi ve ventriküler trigeminedir. Bu işlemler bir mobil uygulama üzerinde yapılmıştır.

### **1.1. Tezin Amacı:**

Dijital devrim ve akıllı telefonların hızlı gelişimi, mobil bağlantı ve sosyal ağlar ile birlikte yaşam şeklimizi değiştirdi. Ortalama olarak Amerikanların %90'ı yüksek bant genişliğiyle, geniş bir veri ağına ve gelişmiş dijital platformlara erişebilen cep telefonlarına sahipken, Amerikan yetişkinlerinin %55'inden fazlası ise akıllı telefonlara sahiptir. Dijital devrim, neredeyse tüm endüstrileri ve kişisel yaşamımızın her yönünü değiştirdi. Ancak tıp dünyasında yeteri kadar yer edinmemiştir. Doktorlar ve sağlık ağları, elektronik tıbbi kayıtları kabul etmekte ve tıbbi verileri her yerde bulunan mobil cihazla entegre etmekte yavaş kalmıştır. Son zamanlarda, kablosuz izleme için yeni cihazlar ortaya çıkmış ve kalp hastalarının bakımıyla entegre olmaya başlamıştır. Bu

kablosuz kardiyak izleme cihazlarının evriminin tıpta yeni bir çağa ve nüfus düzeyindeki sağlık hizmetlerinden bireyselleştirilmiş tıbbi geçebilmesine ve uygun hastaların gelişmiş biyosensörler ile donatılmasına ve bu sayede verilerin karmaşık algoritmalarla işlenebileceğine inanılmaktadır. Bu algoritmaların doğru şekilde işlenebilmesi sonucunda erken teşhis için elektrokardiyogram ile uyum içerisinde çalışabilecek sistemler geliştirilebilir. Elektrokardiyogram (EKG), kardiyak aritmi tanısı için en kritik noninvaziv araçlardan biridir. EKG'de otomatik atım sınıflandırması devam eden bir araştırma konusudur. Bu tezde, çeşitli algoritmalar kullanılarak otomatik atım sınıflandırması için bir mobil uygulama geliştirilmiştir. Proje, donanım ve yazılım parçalarından oluşmaktadır. Donanım giyilebilir EKG cihazıdır. Yazılım ise Bluetooth kullanılarak donanım bölümüne bağlanan bir akıllı telefon uygulamasıdır.

## **1.2. Tezin Önemi:**

Kalp hastalıkları, dünyanın dört bir yanındaki insanlar için önde gelen ölüm nedenlerinden biridir. Günümüz modern yaşam döngüsü içerisinde insanların sağlıklı yaşam tarzından uzaklaşması kalp hastalıklarını önemli ölçüde arttırmaktadır. Buna bağlı olarak da sağlık sektöründe kalp aritmilerinin erken teşhisi ve yakından takibi kaçınılmaz olmuştur. Bu tez çalışmasında, erken tanı için yardımcı olabilecek, kalp aritmilerini tespit etmek amacıyla giyilebilir bir cihaz ve kontrolü için bir uygulama önerilmiştir. Kalp aritmisinin tespiti için önerilen cihazın minyatür tasarımı ve düşük güç tüketimi, kalp ritminin uzun süreli izlenebilmesine imkân verecektir. Bu tarz bir yaklaşım ise kalp rahatsızlıklarının erken tespitine imkân sağlayacağından dolayı yaşam süresini ve kalitesini doğrudan artıracaktır.

## 2. KAYNAK ARAŞTIRMASI

Kalbi etkileyen hastalıklar gün geçtikçe yaygınlaşmıştır. Hareketsiz yaşam, yanlış beslenme ve tütün içimi gibi günümüz sağlıksız yaşam tarzı artışı nedeniyle hipertansiyon, diyabet gibi kalbi etkileyen hastalıklar da artmaktadır. En önemli kalp hastalıklarından biri de “İskemik kalp hastalığı”dır. İskemik kalp hastalığı, koroner arterlerdeki (kalbin beslenmesini sağlayan atardamarlar) tıkanıklıklar nedeniyle oluşur ve bu tıkanıklıklar da miyokardiyal (kalp kası) hücrelerin beslenme bozukluğuna neden olur. Kalbe kan sağlayan üç ana arter vardır. Bu kan damarlarının bir veya daha fazlasındaki tıkanıklık, Miyokard İnfarktüsüne (kalp krizi) neden olabilir. Bu durum ölüm gibi ciddi sonuçlara yol açabilir. Yukarıdaki durumun erken teşhis edilmesi ve acil tedavi edilmesi, hayatta kalma şansını ve yaşam kalitesini artırmaktadır. Kalbi etkileyen diğer önemli bir hastalık ise “aritmî”dir. Aritmî, iletim sistemini (kalp atım varyasyonu) etkileyen bir bozukluktur. Tedavisi kalp atımını yavaşlatmak veya sabitlemek şeklinde olabilir. Erkenden teşhis ile tedavi edilmezse tehlikelidir ve ölüme yol açabilir. Kalbi etkileyebilecek diğer durumlar konjenital kalp hastalığı (doğuştan kalp hastalığı), valvüler kalp hastalığı (kalp kapaklarını etkileyen hastalıklar), enfeksiyonlar ve enflamasyonlardır. Yukarıda belirtilen durumların teşhisi veya şüphe edilmesine yardımcı olan araştırmalar, Elektrokardiyografi (EKG) yoluyla gerçekleştirilir. EKG, en az altyapıya sahip kırsal alanlar da dahil olmak üzere her yerde mevcut olan basit, kolay ulaşılabilir, ucuz, hızlı yapılabilen, invaziv olmayan uygulamalardan biridir. EKG kardiyak (kalple ilgili) sorunların uygun şekilde teşhis edilmesinde önemlidir. Bu tıbbi durumlar sırasında, zaman çok kıymetlidir. Hastaları tedavi etmede gecikilen her dakika, kalp kasında daha fazla hasara yol açarak olumsuz sonuçlara neden olur. Bu nedenle kalp hastalıklarının erken ve doğru teşhisi çok önemlidir. Hastaları düşük ve yüksek riskli olarak ayırmak gereklidir. Düşük riskli hastalar, aynı hastanede asgari altyapı ile yerel olarak tedavi edilebilir. Yüksek riskli hastaların, kalp üzerinde özelleşmiş hastanelere erken başvurusu gerekir. EKG, miyokard infarktüsü, aritmiler ve diğer durumların tanısını doğrular veya bunlardan şüphelenilmesini sağlar. Tanı konulduktan sonra hasta, hastalığına ve mevcut olanaklara bağlı olarak ilaçlarla veya uygun prosedürlerle (ameliyatlar) tedavi edilir.

EKG, çeşitli kalp hastalıklarının hem teşhisini koymak hem de seyrini izlemek için yaygın olarak kullanılmaktadır. Buna göre EKG, miyokard infarktüsünü (kalp krizi) ve aritmileri (kalp atım varyasyonunu) teşhis ve ayırt edebilir, mevcut algoritmayı

kullanarak kalbin büyümesinin engellenmesi sağlanır ve buna göre erken önlemler alınabilir. Ancak doğruluk, kullanılan algoritmaya göre değişebilir.

Daha önce EKG analizi için kullanılan teknikler veya yaklaşımlar: bulanık tabanlı teknikler, kaba küme teorisi ve gizli markov modelleri, yapay sinir ağlarına dayalı yaklaşımlar, destek vektör makineleri kullanılan yaklaşımlar, genetik algoritmaları kullanan yaklaşımlar ve Hibrit algoritmalar'dır.

## 2.1 Bulanık Tabanlı Teknikler

Bulanık tabanlı makine öğrenmesi, etkili EKG analizi için yaygın olarak kullanılan bir yaklaşımdır. Bu teknikler, EKG analizini yapılarak hastalıkların teşhisinde anlamlı özellikler kullanılmıştır (Lei ve ark., 2007). Dahası, koroner arter gibi kalp hastalıklarında EKG'yi analiz etmek için farklı sınıflandırıcılar kullanılmış ve çok miktarda veriler işlenmiştir (Pal ve ark., 2012). Bu amaçla Behadada ve Chikh tarafından 2013 yılında; kardiyak aritmileri sınıflandırmak, anormallikleri saptamak ve kardiyak sorunları değerlendirmek için bir çalışma yürütmüşlerdir (Behadada ve Chikh, 2013). Araştırmacılar, bulanık karar ağacını kardiyak anormallikleri teşhis etmek için bir metodoloji olarak kullanmışlardır. Buna bağlı olarak MIT-BIH veritabanından kalp atışıyla ilgili verileri kullanmışlardır. Önerilen bulanık karar ağacıyla, ventriküler kasılma anomalileri saptanmakta ve hata oranı %19,76'ya indirilmektedir, doğru sınıflandırma oranı ise %71'dir (Behadada ve Chikh, 2013). Bununla birlikte, sinir ağları ve diğer tekniklerle karşılaştırıldığında, sonuç tatmin edici değildir. Lei ve ark., tarafından yapılan çalışmaya göre, geleneksel sınıflandırıcıların performansını arttırmak için uyarlamalı bir bulanık EKG sınıflandırıcı geliştirmiştir (Lei ve ark., 2007). Sınıflandırıcı, değerlendirme için MIT-BIH veritabanını kullanmıştır. Geliştirilen sınıflandırıcı, EKG sinyalinin özelliklerine göre analiz yapma açısından etkilidir. Ortalama doğruluk oranı %88,2 olarak bulunmuştur. Ayrıca, hesaplama etkinliği de anlamlı derecede yüksektir (Lei ve ark., 2007). Bununla birlikte, her iki yaklaşım da farklı kalp atışlarını anlama açısından yetersiz kalmaktadır.

Bulanık çıkarım sistemleri kullanılarak etkili analizlerin yapılabildiği elektrokardiyografi, kalp hastalıklarının tanısında yaygın olarak kullanılmaktadır (Goel ve ark., 2016). Bulanık tabanlı teknikler üzerinde yapılan araştırmalar, bulanık çıkarım ağları (Lei ve ark., 2007) gibi nöral ağların dahil edilmesiyle daha da geliştirilmiştir (Güler ve Übeyli, 2004). Ceylan ve ark tarafından yapılan benzer bir çalışmada, EKG

analizinde sınıflandırma yapmak için bulanık kümeleme sınır ağı algoritmasını kullanmışlardır (Ceylan ve ark., 2009). Araştırmacılar, 92 hasta kaydının MIT-BIH veri tabanının uygulandığı EKG sinyallerinin doğruluk oranını arttırmayı amaçladı. Ayrıca, 2 bulanık ortalama kümeleme algoritması kullanılmıştır. Önerilen sistem, yüksek kümeleme performansının elde edilmesiyle %99'luk bir doğruluk sağlamıştır. İncelemelere göre, eğitim süresinin bu durumda büyük etkisinin olduğu sonucuna varılmıştır. Ayrıca, gelecekteki araştırmalar için daha büyük bir örnek alınabilir. Bu nedenle, bulanık kümelerin, belirsizlik içindeki verileri göstermek için en iyi şekilde kullanıldığı sonucuna varılabilir ki bu mantıksal bir çıkarım mekanizmasının sağlanmasında etkilidir. Bulanık mantıktan elde edilen çıktı, EKG analizinde bilgi tabanlı sistemlere uygulanabilir (Jeyalakshmi ve Robin, 2016).

Bulanık karar ağacı, karmaşık veya eksik değerler ve çok değişkenli verilerle başa çıkmak için belirli bir çıkarım ve bilgi edinme aracı sağlar (Chen ve ark., 2009). Yukarıdaki amaçlara açıklık getirmek hedefiyle uzman sistemler yaygın bir şekilde kullanılmaktadır. Tıp biliminde, koroner arter hastalıklarının doğru tespit edilmesi ve tıbbi verilerden ortaya çıkan belirsizliklerin giderilmesi için bulanık bir uzman sistem geliştirilmiştir (Pal ve ark., 2012). Araştırmacılar, koroner arter hastalıkları ile ilgili veri tabanından verimli aramalar elde etmek için ağaç temsilindeki kural organizasyonu üzerinde durulmuştur. Bu nedenle, bulanık tabanlı tekniklerin bilgisayarlı EKG analizinde etkili olduğu, ancak özellikle ST yükselmesine eşlik eden miyokard infarktüsünden sorumlu koroner arterin lokalizasyonuna ilişkin daha yüksek bir doğruluk düzeyi elde etmek için daha fazla araştırmayı gerektirdiği sonucuna varılmıştır.

## **2.2 Kaba Küme Teorisi ve Gizli Markov Modelleri**

Kaba set teorisi (RST), 1980'lerin başında ortaya çıkmış ve verilerden gelen belirsizlikleri azaltmak için kullanılacak bir strateji olarak geliştirilmiştir (Senthilkumaran ve Rajesh, 2010). RST ile giderilen sorunlar, gereksiz verilerin azaltılması, veri bağımlılıklarının tespiti, verilerin sınıflandırılması ve veri modellerinin değerlendirilmesi ile ilişkilidir (Wakulicz-Deja ve Peszek, 2003). Dahası, EKG analizinde RST kullanmanın avantajı, kolay, anlaşılabilen veya karmaşık veri tabanlarından değerli bilgilerin doğru şekilde çıkarılmasını sağlayan kuralların formüle edilmesinde yardımcı olmasıdır (Tripathy ve ark., 2013). Kaba küme teorisi sağlam bir

sınıflandırma modeli oluşturmak için kullanılır (Barman ve ark., 2016). Mevcut literatürdeki bazı araştırmacılar, maksimum fayda elde etme umuduyla bilgisayarlı EKG analizinde kaba set teorisini kullanmışlardır. Mitra ve ark. tarafından yapılan bu türden bir araştırma, etkili tanı için, kural tabanlı kaba setin optimize edilmiş bir yaklaşımını göstermiştir (Mitra ve ark., 2006). Çalışmada, bir TIFF formatlı görüntü veritabanı kullanılmıştır. Araştırmacılar, otomatik EKG özelliği çıkarma sisteminin ve EKG yorumuna ilişkin bilgi tabanının geliştirildiği, farklılaştırma teknikleri ve sözdizimsel yaklaşımlar kullanmıştır. Hastalıkların tespiti için kural tabanlı bir kaba küme karar sistemi geliştirilmiştir. Buna göre miyokard infarktüsü (MI) için %100 doğruluk elde edilmiştir. Sonuçlar eğitim seti için uygun ve etkilidir, ancak eğitilmeyen veri setleri ile ilgili doğruluktan yoksundur. Ayrıca, çalışma için alınan örnek büyüklüğü MI'nın sadece 27 hasta kaydından oluşmaktadır.

Barman ve ark. kaba set teorisi ve farklı sınıflandırma yöntemlerini kullanarak MIT-BIT veri tabanından doğru bilgileri elde etmek için bir çalışma yürütmüştür (Barman ve ark., 2016). Veriler önce MATLAB aracı kullanılarak ön işlemden geçirilir ve sonra RST sınıflandırma için uygulanır. Araştırmacılar ayrıca ön işleme için filtreleme yöntemleri kullanmışlardır. Setiawan ve ark. Tarafından bildirilen başka bir çalışma, Koroner Arter Hastalığı (KAH) tanısı için bir kural seçim yöntemi geliştirmiştir (Setiawan ve ark., 2009). Toplam 920 KAH olan hasta örneği farklı hastanelerden toplanmıştır. Kaba set teorisi (RST), destek filtrelemesinin hibrit yaklaşımı ve RST kuralı önem seçimi kullanılarak uygulanır. Önerilen teknik, sınıflandırma kalitesini düşürmeden, çok sayıda kuralın seçilmesi ve çıkartılmasında etkilidir. Bulanık akıl yürütme, gelecekteki çalışma için önerilen mekanizmaya, doğruluğu arttırmak amacıyla dahil edilebilir.

Huang ve Zhang tarafından yapılan bir çalışma, EKG'de gerekli olan verilerin belirlenmesine yönelik tanıma kurallarının, RST'nin uygulanmasıyla yoğunlaştırıldığını ortaya koymuştur (Huang ve Zhang, 2003). Aynı doğrultuda, kalp hastalıklarını belirleyen EKG, kan basıncı ve maksimum kalp hızı gibi özellikleri tanımlamayı amaçlayan bir araştırma yürütmüştür (Tripathy ve ark., 2013). Farklı kalp hastalıklarına göre 5 gruba ayrılan 250 hastanın test verileri alınmıştır. Araştırmada, kaba kümeler, karar kuralları ve Formal Kavram Analizi (FCA) kullanılmıştır. Kalp hastalıklarının karakteristiğini belirlenmesinde yüksek doğruluk elde edilmiştir.

EKG sinyali, bilgi edinimi için Gizli Markov modelleri yardımıyla yapılabilecek EKG dalga formuna göre değerlendirilir. EKG sinyalinin dalga formlarına bölünmesi ve

uygulamasında, HMM yaygın olarak kullanılmaktadır (Frénay ve ark., 2009). Andreao ve ark., tarafından yapılan bir çalışmada, kalp atışı tespiti ve segmentasyonunun işlevselliğini yerine getirirken, EKG'yi sınıflandırmada HMM'nin kullanımı araştırılmıştır (Andreao ve ark., 2006). Araştırmacılar, dalga şekli modelleme, sınıflandırma, denetimsiz adaptasyon ve segmentasyon gibi çeşitli yönleri ele almıştır. Çalışma, %99,79 duyarlılık ile kalp atımlarının etkili ve doğru tespit edilmesi ile sonuçlanmıştır.

### 2.3 Yapay Sinir Ağlarına Dayalı Yaklaşımlar

Son zamanlarda, Genetik Algoritmalar; Bulanık Mantık, Kendini Organize Eden Harita, Bayes, Gizli Markov Modelleri ve DVM'ler gibi etkili bir aritmi sınıflandırması için çeşitli yöntemler kullanılmıştır (Gupta ve Chatur, 2012). Teşhiste EKG sinyal paternlerinin incelenmesi göz önüne alındığında, çok geniş ve zaman alıcıdır. Bu nedenle kardiyak hastalıkların etkin teşhisi için bilgisayarlı araçlar gerekir (Sao ve ark., 2015). Sinir ağları, EKG sinyalinden ön işleme, tespit ve özellik çıkarıldıktan sonra sınıflandırma için kullanılır. Geo ve ark., kardiyak aritmiler için yapay sinir ağ sınıflandırıcısı kullanarak bir tanı sistemi geliştirmişlerdir (Gao ve ark., 2004). Sınıflandırıcı, geri yayılım algoritmasının (GYA) (BPA-Back Propagation Algorithm) uygulanmasıyla formüle edilen bir Bayes çerçevesine dayanmaktadır. Önerilen sistem, iyileştirme için daha fazla kapsamı olan %90'lık bir tahmin doğruluğu sunmaktadır. Ayrıca, sistem pratikte uygun değildir ve değişiklik yapılması gerekmektedir. Benzer şekilde, Vishwa ve ark., çok kanallı EKG kayıtları kullanarak kardiyak aritmi için otomatik Yapay Sinir Ağı (YSA) tabanlı bir sınıflandırma sistemi geliştirmiştir (Vishwa ve ark., 2011). 1975 ve 1979 yıllarında 48 kayıttan oluşan bir MIT-BIH aritmi veritabanı kullanılmışlardır. Ayrıca, yöntemin doğrulanması için bir Normal Sinüs Ritmi (NSR) veritabanı kullanmışlardır. Tahmini ileri besleme için YSA ve geri yayılım öğrenme algoritmaları kullanılır. Yaklaşım MIT-BIH veritabanında %96.77 ve NSR veritabanında %96,21 doğruluğu göstermektedir. Bununla birlikte, araştırma 16 aritmi sınıfının tümünü sınıflandıramamaktadır.

Sao ve ark., 2015'te yaptıkları çalışmada kalp hastalıklarını en etkili şekilde teşhis etmek için EKG'de ANN kullanmışlardır (Sao ve ark., 2015). Araştırmacılar, aynı zamanda bir Spektral Entropi, En Büyük Lyapunov Üssü ve Poincare Arsa Geometrisi

gibi parametrelerin geri yayılım algoritmasının kullanımı ile birlikte değerlendirildiği bir YSA sınıflandırıcısı önermiştir.

Anuradha ve Reddy'e göre, nöral ağlar EKG sinyallerinin sınıflandırmasını optimize etmek için yaygın olarak kullanılabilir (Anuradha ve Reddy, 2008). Araştırmacılar kardiyak aritmi için YSA temelli bir sınıflandırıcı geliştirmişlerdir. EKG verilerini almak için MIT-BIH veri tabanı kullanılmıştır. EKG sinyallerinden kardiyak aritmilerin sınıflandırılması için de yapay sinir ağı (YSA) kullanılmaktadır. Sınıflandırıcı dalgacık Geri Yayılım Algoritmalarının bir kombinasyonunu kullanmaktadır. %90.56'lık bir doğruluk elde edilir ve sınıflandırıcı anormal aktiviteleri etkin bir şekilde tespit edebilmektedir.

Jadhav ve ark. tarafından yapılan bir başka araştırmada da, kalp hastalıklarının teşhisi için bir ANN modeli geliştirmeyi amaçlamıştır (Jadhav ve ark., 2012). Bu amaçla, araştırmacılar UCI makine öğrenme veri havuzlarından 12 hastanın EKG sinyal kayıt verilerini kullanmışlardır. Statik geri yayılım algoritması ve momentum öğrenme kuralı sınıflandırma için kullanılmaktadır. Ortalama kare hatası (MSE), ROC analizi ve ROC eğrisi altındaki alan (AUC) önerilen modelin performansını değerlendirmek için kullanılan ölçülerdir. Sınıflandırma doğruluğu %86.67, duyarlılık %93.75 olarak elde edilmiştir. Geliştirilen model, farklı performans ölçümleri kullanılarak iyi bir şekilde onaylanmıştır, ancak pratik uygulamalar için daha da geliştirilebilir.

Gupta ve Chatur'a göre, EKG analizi kalp hastalıklarının teşhisi için oldukça faydalıdır. Araştırmacılar, EKG sınıflandırması için denetimli yapay sinir ağları ve veri madenciliği tekniklerini uygulamışlardır (Gupta ve Chatur, 2012). De Gaetano ve ark tarafından yapılan bir başka araştırmada, EKG sinyallerindeki normal atımlarla, iskemik atımları ayırt etmek için denetlenen nöral ağa dayalı bir algoritma geliştirilmiştir (De Gaetano ve ark., 2009). Araştırmacılar, iki tür ritmi tanımlamak için radyal temel fonksiyonlarını ve R-dalga segmentlerini (RR aralığı) kullanmışlardır. Daha sonra sistem Avrupa ST-T veritabanında doğrulandı. Önerilen sınıflandırıcı, EKG verisinden anormal atımları tanımlarken güvenilir olarak değerlendirilmiştir.

## **2.4 Destek Vektör Makineleri Kullanılan Yaklaşımlar**

İstatistiksel öğrenme teorisine dayanan destek vektör sınıflandırıcılar, görüntü bölümlendirme, EKG sinyal sınıflandırması ve tanı vb. gibi çeşitli uygulamalarda yaygın olarak kullanılmaktadır (Guler ve Ubeyli, 2007). Kampouraki ve ark., tarafından

yapılan bir çalışmada, kalp atışlarının zaman serileri, Destek Vektör Makineleri (DVM) kullanılarak sınıflandırılmıştır (Kampouraki ve ark., 2009). Araştırmacılar, DVM sınıflandırıcısının, EKG sinyallerini minimum sinyal / gürültü oranına göre sınıflandırdığından, sinir ağlarına dayalı olanlardan daha iyi bir işlev sunduğunu ortaya koymuştur. Polat ve ark tarafından yapılan benzer bir çalışmada, EKG veri setinden aritmiyi sınıflandırmak için bir teknik geliştirmişlerdir (Polat ve ark., 2008). En küçük kare destek vektör makinesi (LSDVM), doğru sınıflandırma için sağlam bir teknik olarak araştırmacılar tarafından kullanılmıştır. Teknik, sınıflandırma doğruluğu, duyarlılık ve ROC eğrileri ile doğrulanmıştır. Değerlendirmede, önerilen teknik %100 doğruluk elde etmiştir. Bununla birlikte, elde edilen doğruluk sadece ateroskleroz hastalığına uygulanabilir ve diğerleri için doğruluk çok daha azdır. Batra ve Jawa tarafından, EKG kullanarak aritmi tespitinin doğruluğunu optimize etmeyi amaçlamışlardır (Batra ve Jawa, 1975). Veri seti (452 kayıt) UCI Makine Öğrenim Deposu'ndan alınmıştır. Aritmi ile ilgili bilgiler çıkarılmıştır. Araştırmacılar, makine öğrenmesi algoritmalarını ve EKG tanı ölçütlerini kullanmışlardır. Deneyler için sinir ağları, karar ağaçları, rasgele orman, gradyan artırma ve destek vektör makineleri gibi makine öğrenme algoritmalarını kullanmışlardır. Ancak DVM'ye daha fazla vurgu yapılmıştır. Gradyan artışı ve DVMkombinasyonu ile %83.04'lük bir doğruluk elde edilmiştir. EKG kriterlerini uyguladıktan sonra doğruluk %84.82'ye çıkarılmıştır. Bununla birlikte, bu çalışmada birkaç teknik belirlenmiştir, bunlar gradyan artırma ve DVM'nin kombinasyonu olmuştur.

DVM, EKG sınıflandırmasında etkinlik elde etmek için diğer yöntemlerin entegrasyonu ile büyük oranda kullanılmıştır. Wang ve Chiang tarafından, kardiyak aritmilerin etkili sınıflandırılması ve tanısı için DVM ve parçacık sürüsü optimizasyonuna dayalı yeni bir yaklaşım kullanmışlardır (Wang ve Chiang, 2007). Diğer taraftan, kardiyak aritmi hastalığı için özellik çıkartma ve EKG sınıflandırması için yeni bir yaklaşım önermiştir (Wang ve Chiang, 2007). DVM sınıflandırıcı, sinyalin en uygun sınıflandırmasını sağlayan en iyi özellik alt kümesini algılayarak, yaklaşımı optimize etmek için kullanılmaktadır. Araştırmacılar, DVM sınıflandırıcısının genelleme performansını geliştirmek için Genetik Algoritma (GA) ile DVM'yi kullanmışlardır. Bu araştırmacılar tarafından önerilen teknik %93'lük bir doğruluk elde etmiştir.

## 2.5 Genetik Algoritmaları Kullanan Yaklaşımlar

EKG analizi, Genetik Algoritmalar (GA) kullanılarak daha az zaman kullanarak daha yüksek hesaplama yetenekleri elde etmek için yaygın bir şekilde kullanılmaktadır (Omran ve ark., 2009). Ancak bu yaklaşım, maksimum fayda sağlamak için diğerleriyle entegre edilmiştir. Birkaç araştırmacı, GA'yı ANN, DVM ve diğer tekniklerle kullanmıştır. Öte yandan, sadece EKG analizinde GA kullanımı ile ilgili teknikler azdır. Priyadharshini ve Kumar tarafından yapılan 2015 yılında, EKG sinyallerinden aritmi sınıflandırmasını geliştirmek için bir araştırma yürütmüştür (Priyadharshini ve Kumar, 2015). Bu amaçla MIT-BIH aritmi veri tabanı kullanılmaktadır. Doğaçlama Genetik Algoritma (GA) geliştirilmiş ve araştırmada C4.5 ve Naïve Bayes sınıflandırma algoritması kullanılmıştır. Araştırma GA'nın C4.5 ve Naïve Bayes'e kıyasla en istikrarlı doğruluğa sahip olduğunu ortaya koymuştur. Araştırmanın kapsamı, en verimli yöntemi sunmak için DVM gibi diğer makine öğrenme algoritmalarına genişletilebilir.

EKG analizi ve kalp hastalıkları tanısı için ANN ile GA kullanmıştır (Omran ve ark., 2009). ANN, EKG sinyalindeki bağlantı noktalarını tespit etmek için kullanılır ve GA, bu noktalara en iyi değerleri seçmek için kullanılır. Genetik algoritmalar, hata değerlerini en aza indirmek ve bağlantı noktalarını iyileştirmek için kullanılan en iyi yöntemdir. Bu çalışmada, ANN algılama ve sınıflandırma modelinde GA uygulandıktan sonra, hata 100 nesilde  $5.9487e-28$ 'den  $2.3116e-29$ 'a düşürülmüştür. ayrıca EKG analizinde daha yüksek verimlilik elde etmek için başka bir yaklaşımla genetik algoritma kullanmıştır (El-Dahshan, 2011). Araştırmacı, GA'nın, uygun dalgacık dengesi için en iyi parametreleri belirlemek için kullanıldığı, EKG sinyallerini denatüre etmek için dalgacık dönüşümü (WT) ile birleştirmiştir. Yüzde ortalama karekök ve sinyal gürültü oranı (SNR), yaklaşımın performansını kavramak için kullanılır. Sadece GA kullanımı göz önüne alındığında, analizinde EKG sinyalinin bozulmasını en aza indirmek için genetik algoritma kullanarak bir sıkıştırma yöntemi geliştirmiştir (Silveira ve ark., 2007). Deneyde MIT-BIH sıkıştırma veritabanı kullanılmıştır. GA ile sıkıştırma, klasik dalgacık Db3 yönteminden daha düşük değerler sağlamıştır.

## 2.6 Hibrit Algoritmalar

EKG sinyallerinin analizi için hibrit teknikler, geliştirilmiş performans arayışında kapsamlı bir şekilde araştırılmıştır. (Dalal ve Birok, 2016), Temel Bileşen Analizi

(PCA) ve Neuro-Fuzzy sınıflandırıcı kullanarak bir hibrid sınıflandırıcı geliştirmiştir. MIT-BIH veri tabanının kullanıldığı hibrit yaklaşımın kullanımı ile farklı kalp aktiviteleri saptanmıştır. PCA yaklaşımı, gerekli bilgileri veritabanından almak için kullanılır ve daha sonra çıkartılan bilgiyi analiz etmek ve işlemek için YSA ve Bulanık mantık tabanlı sınıflandırıcı kullanılır. Hibrit yaklaşımın doğruluğu %96 olarak gerçekleştirilmiştir. Bensujin ve Hubert tarafından yapılan bir başka çalışma, bir kişinin EKG sinyalinde ST segment yükselmesi Miyokard İnfarktüsünü (STEMI) incelemiş ve belirlemiştir (Bensujin ve Hubert, 2014). İki gruba ayrılan MIT BIH veri tabanından 480 hastanın kayıtları çıkarılmıştır. Çin Kalp Hastalığı veritabanı, yöntemin doğrulanması için kullanılmıştır. Kalp atış hızı, iskemik ve STEMI çıkarılması için hibrit tespit yöntemleri kullanılmıştır. K-özellik kümeleme algoritması özellik çıkarma için kullanılmıştır. EKG sinyallerinden STEMI tanımlamak için Bakteriyel Toplayıcı Optimizasyon Algoritması (BFOA) kullanılmıştır. Analizler, kümelenmiş veriler üzerindeki STEMI'nin %89 ile tespit edildiğini ve yakınsama oranının %91 olduğunu ortaya koymuştur. Önerilen metodolojinin etkinliği yüksektir.

Daha yüksek doğruluk elde etmek için (Finlay ve ark., 2015), elektrot yerleştirmesinin koroner arter tıkanıklığını belirlemede doğruluğu üzerindeki etkisini göstermişlerdir. Perkütan Transluminal Koroner Anjiyoplasti (PTCA) yapılan ve 120 vakadan Vücut Yüzey Potansiyeli Haritası (BSPM) kaydı olan 45 hasta alınmıştır. Elektrot yerleştirmenin hastalara etkisini incelemek için BSPM'ler kullanılmıştır. STEMI ve STEMI olmayanlar için bir bilgisayar algoritması geliştirilmiştir. Araştırmacılar, kurşun elektrot yerleşiminin STEMI ve 12 uçlu EKG'yi tespit etmede önemli etkiye sahip olduğunu tespit etmişlerdir. Bununla birlikte, önerilen metodolojinin pratik uygulamasının zayıf olduğu görülmektedir. Ayrıca, sonuçların güvenilemediği hasta sayısı daha azdır.

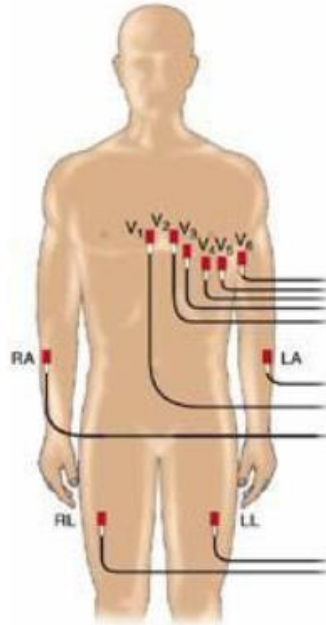
Ghosh ve ark tarafından, akut STEMI'de sorumlu damar tıkanıklığının EKG lokalizasyonunun doğruluğunu incelemiştir (Ghosh ve ark., 2013). Çalışmaya akut miyokard infarktüsü olan 21 hasta seçilmiştir. Sol ön inen (LAD), Sağ Koroner Arter (RCA) ve sol sirkumfleks (LCx) koroner arterlerde sorumlu damar tıkanıklığının lokalizasyonu, hastalara 3 gruba ayrılarak yapılmıştır. Sonuçlar, LAD için, EKG lokalizasyonunun doğruluğunun %90.91 olduğunu; RCA için %100 olduğunu; LCx koroner arterler için % 90 olduğunu göstermiştir. Bununla birlikte, çalışmada alınan örneklem büyüklüğü küçüktür. Ayrıca, anjiyografi hemen gerçekleştirilememiştir, bu da sonuçsuz kalmıştır.

### 3. MATERYAL VE YÖNTEM

#### 3.1 Materyal

##### 3.1.1. Elektrokardiyografi (EKG)


Elektrik akımları, yayılma eylem potansiyellerinden üretilir. Bu elektrik akımları vücut yüzeyinde tespit edilebilir ve ölçülebilir. Kalpteki elektriksel potansiyel değişimleri kaydetme yöntemine “elektrokardiyografi” (EKG) denir. Bu sinyalleri kaydetmek için kullanılan alete ise “elektrokardiyograf” denir. EKG'nin temeli, cilt yüzeyindeki iki nokta arasındaki elektriksel potansiyel farkı ölçmektir. Aksiyon potansiyellerinden oluşturulan elektrik alanı 3 boyutludur, dolayısıyla EKG sinyali, potansiyelin hangi iki nokta arasında ölçüleceğine bağlı olarak farklı görünüme sahip olacaktır. En standart EKG 10 elektrottan oluşur ve bu elektrotlarla 12 derivasyon elde edilir. Derivasyon, yerleştirilen elektrotlar arasındaki elektriksel potansiyel farkı gösterir. Elektrotların 6'sı kalbin etrafına, 2'si sağ ve sol el bileklerine, diğer 2'si de sağ ve sol ayak bileklerine olacak şekilde yerleştirilir. Şekil 3.1. EKG ölçümü için elektrotların yerleşimini göstermektedir.



Şekil 3.1. Standart EKG ölçümü için elektrotların yerleşimini gösteren şekil (Andersson, 2017).

12 derivasyonlu EKG, göğsün üzerindeki iki merkezi yatay nokta arasındaki potansiyel farkı ölçen bir derivasyonlu EKG'ye kıyasla kalbin birçok özel bölümünün

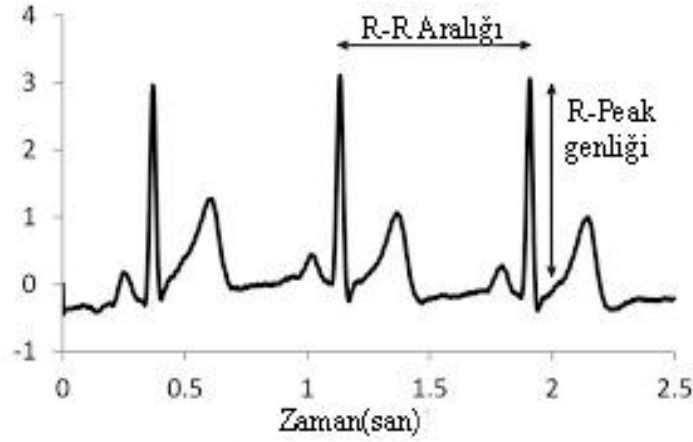
izlenmesini sağlar. Ancak yine de, bir derivasyonlu EKG, bu tez için ihtiyacımız olan tüm bilgileri vermektedir. Şekil 3.2, bir derivasyonlu EKG sinyalinin tipik bir görünümüdür. Her bir kalp atışı için, üç farklı tanınabilir dalga vardır. Birincisi, aksiyon potansiyelinin SA (sinoatriyal) düğümünden her iki atriyumdaki liflerden yayıldığı atriyumun depolarizasyonunu temsil eden P dalgasıdır. P dalgasını takiben ventriküler depolarizasyon ve atriyal repolarizasyonun sonucu olan QRS kompleksi vardır. Burada, aksiyon potansiyeli, ventriküllerin etrafındaki liflerden yayılır. Repolarizasyon, membran potansiyeli, bir aksiyon potansiyelinin depolarizasyon fazından sonra negatif bir değere döndüğünde, depolarizasyonun tam tersidir. Son göze çarpan dalga, ventriküler repolarizasyonu gösteren T dalgasıdır. Üç farklı dalgaya ek olarak, EKG'de farklı zaman dilimlerini analiz etmek de yaygındır. Dalgalarda sıklıkla analiz edilen üç ana aralık vardır. Bunlardan ilki P-Q aralığıdır. Bu, P dalgasının başlangıcı ile QRS kompleksinin başlangıcı arasındaki süreye tekabül eder ve hareket potansiyelinin atriyum, AV düğümü ve iletim sisteminde kalan liflerden geçmesi için iletim süresini temsil eder. İkinci ilgi alanı S-T segmentidir. Bu segment, QRS kompleksinin sonu ile T dalgasının başlangıcı arasındaki süreyi içerir ve her iki ventrikülün tamamen depolarize edildiği zamanı temsil eder. Son olarak, Q-T aralığı da analiz etmekte kullanılabilir. Bu aralık, QRS kompleksinin başlangıcı ile T dalgasının sonu arasında değişmektedir ve hem ventriküler depolarizasyonun hem de repolarizasyonun gerçekleşmesi için gereken süreyi temsil etmektedir. Başka bir deyişle, kabaca ortalama bir ventrikül aksiyon potansiyeli süresini temsil eder (Andersson, 2017).



**Şekil 3.2.** Normal ve tipik bir EKG sinyalinin farklı dizilerini gösteren şekil (Liang ve ark., 2014).

Bu tez çalışmasında, EKG kayıtlarında incelenecek iki ana parametre R-R aralığı ve R-pik genliğidir. R-R aralığı, R-tepe noktaları arasındaki süreye karşılık gelirken, R-

tepe genliđi, R-tepe noktaları arasındaki büyüklüğü ifade eder. R-R aralıđını ve R-tepe genliđini gösteren tipik bir EKG sinyali, Şekil 3.3'te görülebilir.



Şekil 3.3 R-R aralıđını ve R-pik genliđini gösteren tipik bir EKG kaydının bir kısmını gösteren şekil (Andersson, 2017).

### 3.1.2 MIT-BIH VeriKümesi

1975'ten bu yana, Boston'daki Beth Israel Hastanesi'ndeki (şu anda Beth Israel Deaconess Tıp Merkezi) ve MIT'deki laboratuvarlar, aritmi analizi ve ilgili konulardaki arařtırmaları destekleyen çalışmalar yapmıřtır. 1980 yılında tamamlanıp dağıtılmaya bařlanan MIT-BIH aritmi veri tabanı bu çalışmalardan biridir. MIT-BIH veri tabanı, aritmi dedektörlerinin deđerlendirilmesi için genellikle mevcut olan ilk standart test materyali olmuř ve bunun için kullanılmıřtır. Amaç, dünya çapında 500'den fazla bölgede kalp dinamiđi ile ilgili temel arařtırmaların yapılmasıdır.

MIT-BIH aritmi veri tabanı, 1975-1979 yılları arasında BIH Aritmi Laboratuvarı tarafından incelenmiřtir. Bu aritmi veri tabanı 48 kayıt içermektedir. Her bir kayıt, iki kanallı (EKG cihazlarının izlenebilirlik açısından 1, 2, 3, 6 ve 12 kanallı olarak çeřitleri vardır) EKG kayıtlarının 30 dakikalık alıntıları için test edilmiřtir. Testten sonra BIH Aritmi Labatuvarı, %60'ının normal ve %40'ının kalp aritmisi olan hastalar olduđunu bulmuřtur. Kayıtları, kanal başına saniyede 360 örnek, 10 mV aralıđında 11 bit çözünürlükte sayısallařtırmıřtır. Kardiyologlar tarafından her bir kayda bađımsız olarak tümü yaklaşık 110.000'i bulan açıklama yapılmıřtır (Moody ve Mark, 2001).

MIT-BIH veri tabanı; ventriküler aritmi verileri, gürültü stres testi verileri, ventriküler tařikardi verileri, ST deđişim verileri, malign ventriküler aritmi verileri, atriyal fibrilasyon / flutter verileri gibi bazı hastalıkların çeřitli veri tabanlarını içerir.

MIT-BIH aritmi veri tabanının içermiş olduğu 48 kayıt ve test sonucu belirlenen hastalık türleri Çizelge 3.1’de verilmiştir.

**Çizelge 3.1.** Kayıtlarda bulunan hastalıklar

Kayıt No.	Hastalık Türü	Kayıt No.	Hastalık Türü
100	Normal Sinüs	200	Ventriküler Taşikardi
101	Normal Sinüs	201	Ventriküler Trigemine
102	Pacemaker Ritim	202	Atriyal Fibrilasyon
103	Normal Sinüs	203	Ventriküler Taşikardi
104	Pacemaker Ritim	205	Ventriküler Taşikardi
105	Normal Sinüs	207	Ventriküler Taşikardi
106	Ventriküler Bigemine	208	Ventriküler Trigemine
107	Pacemaker Ritim	209	Supraventriküler Taşikardi
108	Normal Sinüs	210	Atriyal Fibrilasyon
109	Normal Sinüs	212	Normal Sinüs
111	Normal Sinüs	213	Ventriküler Taşikardi
112	Normal Sinüs	214	Ventriküler Taşikardi
113	Normal Sinüs	215	Ventriküler Taşikardi
114	Supraventriküler Taşikardi	217	Atriyal Fibrilasyon
115	Normal Sinüs	219	Atriyal Fibrilasyon
116	Normal Sinüs	220	Supraventriküler Taşikardi
117	Normal Sinüs	221	Ventriküler Taşikardi
118	Normal Sinüs	222	Supraventriküler Taşikardi Atriyal Flutter
119	Ventriküler Bigemine Ventriküler Trigemine	223	Ventriküler Taşikardi
121	Normal Sinüs	228	Ventriküler Bigemine
122	Normal Sinüs	230	Pre-Eksitasyon
123	Normal Sinüs	231	Kalp Bloğu
124	Nodal Ritim	232	Sinüs Bradikardi
233	Ventriküler Taşikardi	234	Supraventriküler Taşikardi

Bu çalışmanın odağı, kalp atımının ventriküllerde ortaya çıkan aritmileridir, örneğin: ventriküler taşikardi (VT), ventriküler bigemine (B) ve ventriküler trigemine (T) aritmileridir.

### 3.1.3 MIT-BIH Ön İşlemler ve Gürültü Giderme

#### 3.1.3.1 Ayırık Dalgacık Dönüşümü ile Gürültü Giderme

EKG sinyallerinin zaman uzayına ait öznitelikleri bulunabileceği gibi, frekans uzayına ait öznitelikleri de bulunup sınıflandırmadakullanılabilir. Fourier dönüşümü ile durağan sinyallerde çok iyi frekans çözünürlüğü elde edilirken,zaman çözünürlüğü ortadan kalkmaktadır. Yani hangi zaman aralığında hangi frekans bileşenlerinin yer aldığı tespit edilememektedir.

Kısa zamanlı Fourier dönüşümünde hassasiyet pencere seçimine bağlıdır. Bazı durumlarda bu pencerelerin değişmesi gerekebilir. Bu yöntemde pencere sabit olduğundan pencerenin sürekli değiştirilebildiği Dalgacık Dönüşümü yöntemi geliştirilmiştir.

Dalgacık dönüşümü; veriyi farklı frekans bileşenlerine ayıran ve her bir bileşeni o ölçekteki çözünürlüğüyle inceleyen bir dönüşüm tekniğidir. Zamanın fonksiyonu olan bir işaretin dalgacık dönüşümü, frekans ve zaman değişkenlerine bağlıdır. Dalgacıklar, zaman frekans analizi için iyi bir araç sağlarlar.

Sürekli dalgacık dönüşümde çok fazla hesaplama olduğu için bu hesap yükünü azaltmak amacıyla ayırık dalgacık dönüşümü kullanılmaktadır. EKG sinyali gibi süreklilik gösteren sinyallerde hem zaman hem de frekans verilerine ihtiyaç duyulmaktadır. Bu tez çalışmasında ise frekans öznitelik çıkarımı için ayırık dalgacık dönüşümü yöntemi kullanılmıştır.

Ayırık dalgacık dönüşümü, gürültü temizleme ve sıkıştırma gibi sinyal işleme uygulamaları için kullanılan ve çok iyi sonuçlar veren bir sinyal dönüşüm tekniğidir. Ayırık dalgacık dönüşümü sinyali analiz etmek için bileşenlerine ayırır. Bunun yanı sıra ayırık dalgacık dönüşümünde sinyal, ana dalgacığın ölçeklendirilmiş şekli olan kendi dalgacıklarına ayrılır. En yaygın formunda, ayırık dalgacık dönüşümünde Denklem 3.1'deki gibi a ve b olmak üzere iki ölçek kullanılır.

$$\psi_{m,n}(t) = \frac{1}{\sqrt{a_0^m}} \psi\left(\frac{t - n \cdot b_0 \cdot a_0^m}{a_0^m}\right) \quad (3.1)$$

Denklem 3.1’de  $m$  ve  $n$  tam sayı olarak dalgacığın sırası ile ölçek ve zaman eksenindeki öteleme parametreleridir.  $a_0$  sabit bir öteleme adımını ifade eder ve bu tez çalışmasında 2 olarak alınmıştır.  $b_0$  zaman eksenindeki öteleme aralığı değerini verir ve değeri 1 olarak alınmıştır. Bu değerler literatürde en çok kullanılan değerlerine göre alınmıştır. İkinci katları kullanılarak oluşturulan dalgacık fonksiyonu aşağıdaki şekilde tanımlanabilir (Partal ve ark., 2011).

$$\psi_{m,n}(t) = 2^{-\frac{m}{2}} \psi(2^{-m} \cdot t - n) \quad (3.2)$$

Denklem 3.2, denklem 3.1’de verilen genel sürekli dalgacık gösterimi ile aynıdır. Burada  $\psi_{m,n}(t)$  sadece  $a_0=2$  ve  $b_0=1$  ile ölçeklenmiştir. Bu, genellikle ayrık dalgacıkların ortonormal olması için seçilir. Bu dalgacık aynı zamanda hem ortogondur, hem de birim enerjiye olması için Denklem 3.3’teki gibi normalize edilir.

$$\int_{-\infty}^{\infty} \psi_{m,n}(t) \psi_{m',n'}(t) dt = \begin{cases} 1 & \text{eğer } m = m' \text{ ve } n = n' \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.3)$$

$T_{m,n}$  dalgacık katsayısında depolanan bilgi, orijinal sinyalin yeniden üretimini sağlar ve başka yerde tekrar edilemez. Denklem (3.2)’nin ayrık dalgacık dönüşümü Denklem 3.4’teki gibi yazılabilmektedir:

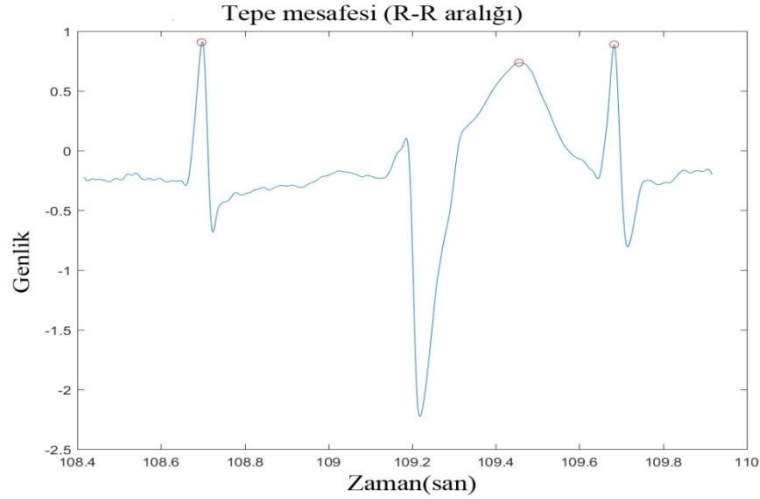
$$T_{m,n} = \int_{-\infty}^{\infty} x(t) \psi_{m,n}(t) dt \quad (3.4)$$

$T_{m,n}(m,n)$  konumlu ve ölçekli dalgacık katsayısı olarak bilinir. Ortonormal ikili ayrık dalgacıklar, ölçekleme fonksiyonu ve onların genişleme denklemleri ile bağlantılıdır. Ölçekleme fonksiyonu, sinyalin düzgünleştirilmesi ile ilişkilidir (Addison, 2005; Legarreta ve ark., 2005).

Bu tez çalışmasında MIT-BIH'den elde edilen veri tabanının normalize edilmesi ve istenilen parametrelerin elde edilmesi amacıyla MATLAB paket programı kullanılmıştır. Bu adım, sinyali analiz edebilmek ve verileri doğru sınıflandırabilen bir algoritma kullanmak için gereklidir.

Aritmi türünü belirlemek için MIT-BIH veri tabanının içeriğini anlamak oldukça önemlidir. MIT-BIH veri tabanı, farklı aritmi türlerinden oluşan 48 kayıt örneği içerir. Her örnek için, kayıtlara ait bilgilerin analiz edildiği dört dosya türü bulunmaktadır. Öncelikle .mat dosyasından sinyaller alınmıştır. Sonra .info dosyasından hastanın bilgileri, header dosyasından ise hastanın temel sağlık bilgileri (hastalık türü) alınmıştır. Tüm sinyallerin ayrıntıları .txt dosyasından aritmi türleriyle birlikte elde edilmiştir.

İlk olarak MIT-BIH veritabanı dosyasından EKG sinyali MATLAB programı kullanılarak alınmıştır. Veri tabanından sinyal zaman vektörü, sinyal frekansı, sinyal örneklerinin boyutu ve sinyal zaman boyutu (saniye olarak) gibi sinyale ait özellikler çıkarılmıştır. Bu çıkarımlardan sonra Ayrık Dalgacık Dönüşümü kullanılarak gürültüden ayıklanmış olan QRS dalgası, tepe yüksekliği (genliği) ve tepe mesafesi (R-R aralığı) Şekil 3.4'de gösterildiği gibi bulunmuştur.



Şekil 3.4 Kayıt 200'den R tepeleri ile çıkarılmış Ventriküler taşikardi sinyali

R-R aralığı ve genlik bulunduktan sonra .info dosyasından hastanın bilgileri yüklenmiştir. Bu bilgiler yaş, cinsiyet ve ilaç kullanımı olarak belirlenmiştir. Yapılan bu işlemler 48 kayıt örneği için de kullanılmıştır. Bu tez çalışmasının odağı olan hastalıklar (ventriküler bigemine, ventriküler trigemine, ventriküler taşikardi) 15 kaydın içinde bulunmuştur. Bu tezde kullanılan veriler toplam 16 kayıttan alınmıştır. Bu kayıtlardan ise 6 nitelik seçilmiştir. Bu nitelikler; R-R aralığı, genlik, kalp atım hızı, yaş, ilaç

kullanımı ve cisiyettir. Bu kayıtlar normal sinüs ritmiyle beraber ventriküler bigemine, ventriküler trigemine ve ventriküler taşikardiyi içermektedir. Çizelge 3.2 bu kayıtları göstermektedir.

**Çizelge 3.2** Seçilen 16 kayıt

Kayıt no.	Hastalık türü	Örnek sayısı	Kayıt no.	Hastalık türü	Örnek sayısı
101	Normal sinüs	1263	208	Ventriküler trigemine	24
106	Ventriküler bigemine	17	213	Ventriküler taşikardi	1
119	Ventriküler bigemine Ventriküler trigemine	36 16	214	Ventriküler taşikardi	1
200	Ventriküler taşikardi	6	215	Ventriküler taşikardi	1
201	Ventriküler trigemine	11	221	Ventriküler taşikardi	1
203	Ventriküler taşikardi	20	223	Ventriküler taşikardi	3
205	Ventriküler taşikardi	3	210	Ventriküler bigemine	1
207	Ventriküler taşikardi	1	233	Ventriküler taşikardi	5

### 3.1.3.2 K-Kez Çapraz Doğrulama Yöntemi:

Bir sınıflandırıcının başarısı çoğunlukla tahmin hatası ile ölçülmektedir. Bazı problemlerde, hata tam olarak hesaplanamamaktadır ve bunun tahmin edilmesi gerekmektedir. Bu nedenle makul bir hata tahmin edici kullanılması önemlidir. K-kez çapraz doğrulamada veri seti k adet eşit parçaya ayrılmakta, sınıflandırıcı k-1 parça ile eğitilmektedir ve geri kalan parçada sınıflandırıcı test edilerek bir hata değeri hesaplanmaktadır. Şekil 3.5'de örnek olarak 5 kat çapraz doğrulama modeli gösterilmiştir. K-kez çapraz doğrulamada hata tahmini, her parçadaki ulaşılan hatanın ortalama değeri olarak elde edilmektedir. Bundan dolayı k-kez çapraz doğrulama hata tahmin edici, eğitim seti ve bölünen parçalar olmak üzere iki etkene bağlıdır (Rodriguez ve ark., 2009).

Test	Train	Train	Train	Train
Train	Test	Train	Train	Train
Train	Train	Test	Train	Train
Train	Train	Train	Test	Train
Train	Train	Train	Train	Test

Şekil 3.5 K-Kat Çapraz Doğrulama Yöntemi

Uygun modellerin başarısını hesaplamak için kestirim hatasının tahmini gerekmektedir. Kestirim hatasının tahmininde genellikle çapraz doğrulama kullanılmaktadır. Çoğu araştırmada birini dışarıda bırakan çapraz doğrulama çalışılmasına rağmen, k-kat çapraz doğrulama, k değeri küçük olduğunda gerçek veri analizinde bir sorun olabilmektedir (Fushiki, 2011).

Bu tez çalışmasında Stratified Shuffle Split yöntemi kullanılmıştır. Stratified Shuffle Split yönteminde çapraz doğrulama, tabakalı k-katlama ve randomizasyon aşamalarından oluşur. Her bir kat için test setlerine ve eğitim setlerine ayrılmış olan veri sayıları eşittir. Çizelge 3.3'te test ve eğitim setlerindeki veri sayıları verilmiştir.

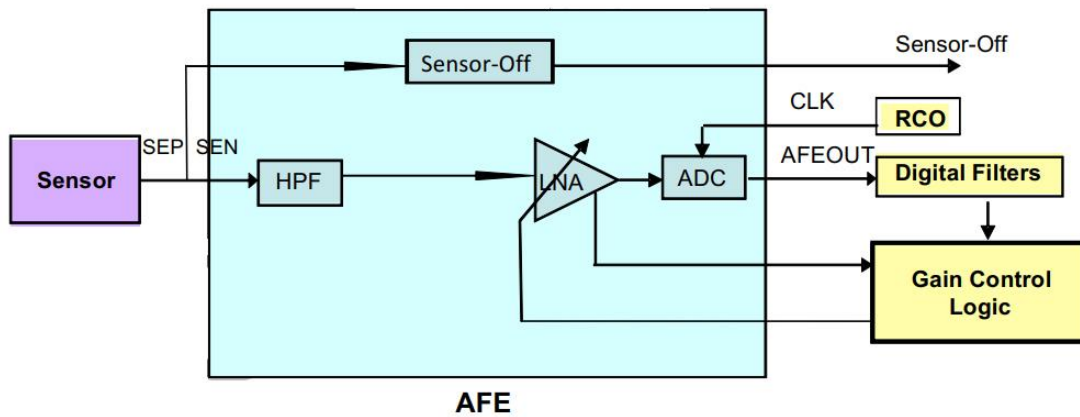
Çizelge 3.3 Verilerin eğitim ve test setlerine ayrılması

Hastalık türleri	Eğitim seti	Test seti
Normal sinüs	1010	253
Ventriküler bigemine	43	11
Ventriküler taşikardi	34	8
Ventriküler trigemine	41	10

### 3.1.4. Analog Ön Uç (AFE)

Analog ön uç (AFE) EKG sinyali elektrotlardan alır ve sinyali büyütür. Ayrıca sinyali, ADC tarafından örneklenmeden önce filtreler. AFE, sinyal zincirinde kullanılan

herhangi bir analog devre ile birlikte elektrotların kendisinden oluşur (Delano, 2012). AFE, düşük genlikli diferansiyel analog giriş sinyallerini alır. Bu sinyalin büyük, yavaş değişen değişken DC bileşenleri içermesi durumunda, DC tamamen yüksek geçiren bir filtre (HPF) ile çıkarılır. Ardından sinyaller, düşük gürültü yükselticisi (LNA) tarafından yükseltilir. LNA'dan çıkan sinyaller, 16 bitlik ADC (Analog-Dijital Dönüştürücüler) tarafından dijital bir bit akışına dönüştürülür. Şekil 3.6. AFE blok diyagramını göstermektedir (Lo ve ark., 2018).



Şekil 3.6. AFE blok diyagramı (Lo ve ark., 2018).

### 3.1.5. CardioChip (BMD101)

Elektrokardiyografi (EKG), klinik tanı ve risk sınıflandırmalarında tıpta en sık kullanılan yöntemlerden biridir. Standart 10 elektrotlu EKG, herhangi bir semptomatik kişide gerçek zamanlı veri iletimi yapma açısından bir sınırlamaya sahiptir. Taşınabilir veya mobil EKG kayıtları, kardiyak aritmi tespit etme gücünü artırmak için önemlidir. Bu nedenle iyi mobiliteye sahip cihazların geliştirilmesi, Teletıp'ın geleceğinin bir dayanağıdır. Önde gelen bir biyosensör firması olan NeuroSkyInc, CardioChip (BMD101) adlı küçük boyutlu, düşük enerji tüketen bir SoC (Çip üzerine sistem) cihazı geliştirdi. Bu yüzden, CardioChip (BMD101) NeuroSky'nin 3. nesil biyo-sinyal algılama ve işleme cihazıdır. BMD101 gelişmiş bir analog ön uç devresi esnek, güçlü bir dijital sinyal işleme yapısı ile tasarlanmıştır. LNA ve ADC, BMD101 analog ön ucunun ana bileşenleridir. BMD101'in son derece düşük sistem gürültüsü ve programlanabilir kazancı sayesinde, 16-bit yüksek çözünürlüklü bir ADC kullanarak biyolojik sinyalleri algılayabilir ve bunları dijital kelimelere dönüştürebilir. AFE ayrıca bir sensör kapatma devresi içerir. BMD101 dijital devresinin kalbi güçlü bir sistem

yönetim birimidir. Genel sistem konfigürasyonundan, operasyon yönetiminden, iç / dış iletişimden, özel algoritma hesaplamasından ve güç yönetiminden sorumludur. BMD101 ayrıca, sistem yönetimi biriminin denetiminde çeşitli dijital filtreleme gibi hesaplamaları hızlandırmak için kablolu DSP bloklarıyla birlikte bulunmaktadır. Şekil 3.7, CardioChip'i göstermektedir (BMD101) (Lo ve ark., 2018).



Şekil 3.7 CardioChip (BMD101)(Lo ve ark., 2018)..

CardioChip'in (BMD101) ana kısımları:

- BMD101 Chip: EKG gibi biyoelektrik sinyalleri insan derisi yüzeyine bağlı elektrotlar ile doğru bir şekilde ölçmek, işlemek ve tespit etmek için tasarlanmış tek bir çip çözümdür. 3 mm x 3 mm x 0.6 mm boyutlu CardioChip'in minyatürleştirilmesi, çipi kolaylıkla birçok mobil cihaza yerleştirmeyi mümkün kılıyor, bu nedenle hem düşük maliyetli ve hem de kullanışlı olması sağlanıyor.
- Elektriksel Özellikler: Cihazın elektriksel özelliklerini gösteren iki tablo bulunmaktadır. Çizelge 3.4, BMD101 mutlak maksimum değerlerini gösterirken, Çizelge 3.5, normal çalışma koşullarında BMD101 özelliklerini göstermektedir.

**Çizelge 3.4** BMD101 Mutlak Maksimum Derecelendirmeler.

Sembol	Parametre	Min	Max	Birim
VDD	Giriş voltajı	-0.1	3.6	V
Vsense	Analog giriş voltajı	-1.0	1.0	V
$T_{OP}$	Çalışma sıcaklığı	0	70	deg.C

Listelenen mutlak maksimum değerler, cihazda kalıcı hasar görebileceği veya oluşabileceği sınırlardır. Mutlak maksimum seviyelerin aşılması durumunda devam eden normal çalışma performansı garanti edilmez. Aksi belirtilmedikçe, listelenen tüm mutlak maksimum değerler normal BMD101 çalışma sıcaklığında yani 25°C derecede geçerlidir. Çizelge 3.5 BMD101 özelliklerini göstermektedir.

**Çizelge 3.5** BMD101 Özellikleri (Ön Hazırlık)

Sembol	Parametre	Min	Tipik	Max	Birim
VDD	Giriş işletme voltajı	2.5	3.3	3.6	V
IDD	Giriş işletme gücü akımı	700	870	1100	uA
Istandby	Bekleme akımı (CS pimi düşük bağlı)	190	225	255	uA
$V_{OH}$	Dijital yüksek çıkış voltajı	2.4		3.6	V
$V_{OL}$	Dijital düşük çıkış voltajı	-0.1		0.4	V
$V_{IH}$	Dijital "1" giriş voltajı	1.6		3.6	V
$V_{IL}$	Dijital "0" giriş voltajı	0		0.8	V
N/A	UART baud rate		57600		Bits/sec.
Vsense	Analog giriş çalışma voltajı	-8		8	mV
Gnotch	Çentik filtresi kazancı	-62	-69.6	N/A	Db
$F_{LCO}$	Düşük kesme frekansı		0.5		Hz
$F_{HCO}$	Yüksek kesme frekansı		103		Hz
CMRR	Ortak mod reddetme oranı		82	N/A	dB
SNR	Sinyal gürültü oranı		68.2	N/A	dB
PSRR	Güç kaynağı reddetme oranı		82	N/A	dB
$T_{op}$	Çalışma sıcaklığı	0	25	70	deg.C
HBM	Analog giriş EDS voltajı	-2000		2000	V

## 3.2. Yöntem

### 3.2.1 KNN (K-En Yakın Komşu)

K-En Yakın Komşu algoritması, bir verinin önceki verilerden K adet en yakın komşularının özelliklerine bakılarak sınıflandırması için kullanılan, istatistiksel sınıflandırma algoritmalarından biridir. Sınıf olarak bilinen örnekler, arama alanı örneğini doldurmak için kullanılır, bu nedenle bu algoritma tembel öğrenim algoritması olarak da bilinir. Bu, eğitim veri noktalarının, herhangi bir genelleme yapmak için kullanılmadığı ve tüm eğitim verilerine test aşamasında ihtiyaç duyulduğu anlamına gelir. Sınıfı bilinmeyen bir örnek değerlendirme için sunulduğunda, algoritma K en yakın komşularını hesaplar ve sınıf bu komşular arasından belirlenir. Algoritmanın detaylandırılmasından önce, bazı tanımlamalar önemlidir:

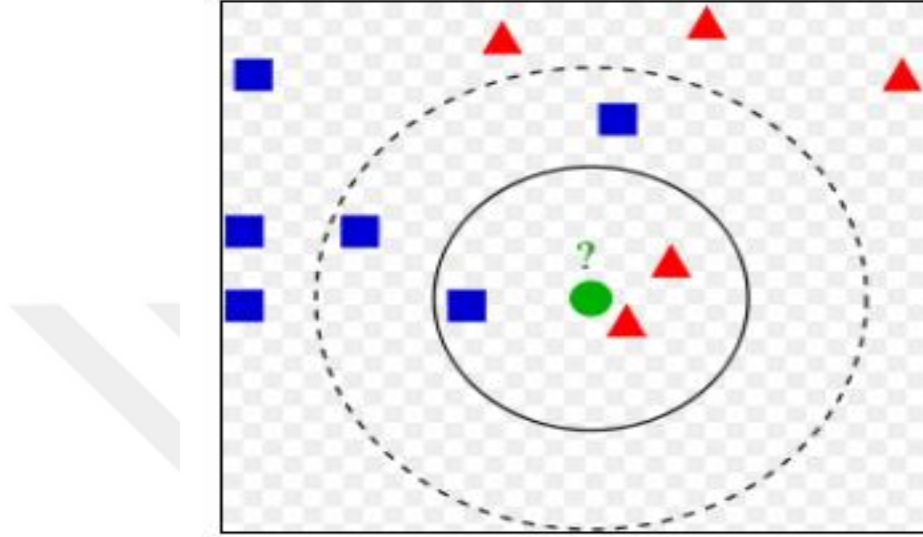
İki nesne arasındaki “mesafe”, aralarındaki Öklid mesafesi olarak alınır. Bazı durumlarda, Manhattan veya Mahalanobis mesafesi de kullanılabilir. Bu mesafeyi hesaplamak için, her nesnenin çok boyutlu bir özellik alanında bir pozisyon vektörüyle temsil edilmesi gerekir. X ve Y vektörleri p özellikli  $(x_1, x_2, \dots, x_p)$  iki giriş örneği (nesne) olsun. Örnek X ile Y örnek arasındaki Öklid mesafesi Denklem 3.5'deki gibi tanımlanmıştır.

$$d(\vec{X}, \vec{Y}) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_p - y_p)^2} \quad (3.5)$$

KNN algoritması iki aşamadan oluşur. Bunlar eğitim aşaması ve test aşamasıdır. Eğitim aşamasında, eğitim örnekleri çok boyutlu bir özellik alanındaki vektörlerdir (her biri sınıf etiketli). Bu aşamada, eğitim vektörlerinin özellik vektörleri ve sınıf etiketleri saklanır. Test aşamasında ise K, kullanıcı tarafından tanımlanan bir sabittir. Bir test noktası (etiketsiz vektör), bu test noktasına en yakın K eğitim örnekleri arasında en çok tekrarlayan bir etiket belirlenerek sınıflandırılır.

Nesnelerin sınıflandırılmasında KNN yönteminin avantajlarından biri, sadece birkaç parametre gerektirmesidir. Bunlar K ve yüksek sınıflandırma doğruluğu elde etmek için kullanılan mesafe ölçüsüdür. Bu nedenle, KNN tabanlı uygulamalarda, en yakın mesafeyi hesaplamak için en iyi K ve mesafe ölçüsü seçimi kritik bir süreçtir. Genel olarak, daha büyük K değerleri, gürültünün sınıflandırma üzerindeki etkisini

azaltır, ancak sınıflar arasındaki sınırları daha az belirginleştirir. İkili sınıflandırma problemlerinde,  $K$ 'yı tek sayı olarak seçmek gereklidir. Bu nedenle,  $K$  değeri en yüksek doğru sınıflandırma oranını üretecek şekilde tanımlanır. Bu çalışmada test edilen  $K$ 'nın farklı değerleri 1, 3, 5, 7 ve 9'dur (Rajaguru ve Prabhakar, 2017).



Şekil 3.8 KNN sınıflandırma örneği (Rajaguru ve Prabhakar, 2017)


Şekil 3.8'de verilen örnekte, test örneği (yeşil daire) ya “mavi kare” sınıfına ya da “kırmızı üçgen” sınıfına sınıflandırılmalıdır.  $K=3$  ise “kırmızı üçgen” olarak sınıflandırılır, çünkü iç çember içerisinde sadece 2 üçgen ve 1 kare vardır. Eğer  $K=5$  ise “mavi kare” olarak sınıflandırılır (dış dairenin içinde 3 kare, 2 üçgen vs.).

### 3.2.2 DVM (Destek Vektör Makinesi)

Destek Vektör Makinesi (DVM), gürültülü ve yüksek boyutlu verileri sınıflandırabilmesi nedeniyle popülerlik kazanmıştır. DVM, sınıflandırma ve regresyon analizi için geliştirilen istatistiksel bir sınıflandırma yöntemidir. DVM sınıflandırıcısının arkasındaki fikir temel olarak iki sınıfa ait verileri birbirinden en uygun şekilde ayırmaktır. DVM’de sınıflandırma yapılırken eğitim verileri kullanılarak en uygun hiper düzlem çizgisi bulunur ve test verileri sınır çizgisinin hangi tarafında kalıyorsa o bölgeye göre sınıflandırma yapılır. En uygun hiper-düzlem çizgisinin bulunabilmesi için sınırları oluşturan ve hiper düzleme paralel iki düzlem çizgisi belirlenir. Bu paralel

düzlemleri oluşturan noktalar “destek vektörleri” olarak adlandırılmıştır. DVM çalışması Şekil 3.9’da gösterilmiştir.

Şekil 3.9’da, dairesel veri noktaları bir sınıfa, kare noktaları başka bir sınıfa aittir. DVM, verileri ayıran bir hiper düzlem ( $H_1$  veya  $H_2$ ) bulmaya çalışır. Şekil 3.9’da gösterildiği gibi, verileri ayırabilecek birçok hiper düzlem olabilir. “Maksimum marj hiper düzlemi” konseptine dayanan DVM, verileri ayıran en iyi karar sınırını seçer. Her bir hiper düzlem ( $H_i$ ), karar sınırına ( $H_i$ ) paralel olan ve en yakın veri noktasından geçen bir çift destek hiper düzlemi ( $h_{i1}$  ve  $h_{i2}$ ) ile ilişkilidir. Bu destek hiper düzlemleri arasındaki mesafeye “marj” denir. Şekil 3.9’de, her iki hiper düzlem ( $H_1$  ve  $H_2$ ) veri noktalarını bölse de,  $H_1$  daha büyük bir marja sahiptir ve bilinmeyen numunelerin sınıflandırılması için  $H_2$ ’den daha iyi performans gösterme eğilimindedir. Dolayısıyla, sınır ne kadar büyükse, bilinmeyen numunelerin sınıflandırılması için genelleme hatası o kadar az olur. Bu nedenle  $H_1$  hiper düzlemi,  $H_2$  hiper düzlemine göre tercih edilir.



Şekil 3.9. Karar sınırı ve DVM sınıflandırıcısının marjı

Temel olarak, iki DVM tipi vardır, İlki lineer karar sınırı kullanarak veri noktalarını ayıran doğrusal DVM ve ikincisi ise  $H_2-H_1-h_{22}-h_{21}-h_{12}-h_{11}$  verilerini ayıran doğrusal olmayan DVM’dir. Şekil 3.9, karar sınırı ve marjlı DVM sınıflandırıcısının doğrusal olmayan bir karar sınırı kullanmasını göstermektedir. Doğrusal bir DVM için karar sınırının denklemi, Denklem 3.6’da verilmiştir.

$$w \cdot x + b = 0 \quad (3.6)$$

Burada  $w$  ve  $x$  vektörlerdir ve  $w$  yönü doğrusal karar sınırına diktir. Vektör  $w$ , eğitim veri seti kullanılarak belirlenir. Karar sınırının üstünde kalan herhangi bir veri noktası ( $x_i$ ) için denklem, Denklem 3.7’de verilmiştir.

$$w \cdot x_i + b = y, \quad \text{ise } y > 0, \quad (3.7)$$

ve karar sınırının altında kalan veri noktaları ( $x_j$ ) için denklem, Denklem 3.8’de verilmiştir.

$$w \cdot x_j + b = y', \quad \text{ise } y' < 0. \quad (3.8)$$

$W$  ve  $b$  değerlerini yeniden ölçeklendirmek suretiyle, iki destekleyici hiper düzlemin ( $h_{11}$  ve  $h_{12}$ ) denklemleri, Denklem 3.9 ve 3.10’deki gibi verilmiştir.

$$h_{11} : w * x + b = 1 \quad (3.9)$$

$$h_{12} : w * x + b = -1 \quad (3.10)$$

İki hiper düzlem arasındaki mesafeye “ $d$ ” marjı” denir. Bu, Denklem 3.11 ve 3.12’de verilmiştir.

$$w \cdot (x_1 - x_2) = 2 \quad (3.11)$$

$$d = 2/\|w\| \quad (3.12)$$

DVM sınıflandırıcısının amacı  $d$  değerini maksimize etmektir. Bu amaç  $\|w\|^2/2$  değerinin minimuma indirilmesine eşdeğerdir.  $W$  ve  $b$  değerleri, bu ikinci dereceden optimizasyon probleminin kısıtlamalar altında çözülmesiyle elde edilir. Bu, Denklem 3.13 ve 3.14’te verilmiştir.

$$w * x_i + b \geq 1 \text{ if } y_i = 1 \quad (3.13)$$

$$w * x_i + b \leq -1 \text{ if } y_i = -1 \quad (3.14)$$

$y_i$ ,  $x_i$  için sınıf değişkenidir. Bu kısıtlamaları uygulamak DVM’yi hiper düzleminin  $h_{11}$  üstüne  $y_i = 1$  olan eğitim örneklerini ve hiper düzleminin  $h_{12}$  altına  $y_i = -1$  olan eğitim örneklerini yerleştirir. Optimizasyon problemi, Lagrange çarpanı yöntemi

kullanılarak çözülebilir. Lagrange formunda küçültülecek nesnel işlevi Denklem 3.15'deki gibi yazılır.

$$L_P = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n a_i (N_i = 1 (y_i (w \cdot x_i + b) - 1)) \quad (3.15)$$

$\alpha_i$ , Lagrange çarpanları ve  $N$ , örnek sayısıdır. Lagrange çarpanları negatif olmamalıdır ( $\alpha_i \geq 0$ ). Lagrange formunu en aza indirmek için, kısmi türevler  $w$  ve  $b$ 'ye göre elde edilir ve sıfıra eşittir. Bu, Denklem 3.16 ve 3.17'de verilmiştir.

$$\frac{\partial L_P}{\partial W} = 0 \Rightarrow W = \sum_{i=1}^n a_i y_i x_i \quad (3.16)$$

$$\frac{\partial L_P}{\partial b} = 0 \Rightarrow \sum_{i=1}^n a_i y_i \quad (3.17)$$

Lagrange formu 3.15'deki Denklem 3.16 ve 3.17'den elde edilen değerlerle değiştirilerek ikili formuna (Denklem 3.18'deki gibi) dönüştürülür.

$$L_D = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1}^n a_i a_j y_i y_j x_i x_j \quad (3.18)$$

$a_i \geq 0$  değerinin,  $h_{11}$  veya  $h_{12}$  hiper düzleminde bulunduğu eğitim durumlarına “destek vektörleri” denir. Sadece bu eğitim durumları,  $w$  ve  $b$  karar sınır parametrelerini elde etmek için kullanılır. Bu nedenle, bilinmeyen numunelerin sınıflandırılması, destek vektörlerine dayanmaktadır.

Bazı durumlarda, karar sınırı düzlemini maksimum marjla elde etmek için bazı eğitim örneklerinin yanlış sınıflandırılması (eğitim hataları) tercih edilir. Eğitim hatası olmayan ancak daha küçük bir marj olan karar sınırı yanlışlara neden olabilir ve bilinmeyen örnekleri doğru şekilde sınıflandıramaz. Öte yandan, birkaç eğitim hatası ve daha yüksek bir marjla karar kararı, bilinmeyen örnekleri daha doğru şekilde sınıflandırabilir. Dolayısıyla, sınır ile eğitim hatalarının sayısı arasında bir denge olması gerekir. Bu şekilde elde edilen karar sınırı “yumuşak marj” olarak adlandırılmaktadır. Optimizasyon problemi için kısıtlamalar yeterlidir, ancak yumuşak marjı oluşturan

esnek parametrelerin ( $\xi$ ) eklenmesi gerekir. Bu esneklik parametreleri, karar sınırındaki hataya karşılık gelir. Ayrıca, marj değerini ve eğitim hatalarının sayısını dengelemek için objektif fonksiyonda eğitim hatası için bir ceza verilmelidir. Optimizasyon problemi için amaç, fonksiyonu minimize etmek olacaktır. Denklem 3.19 yumuşak marjı oluşturan esnek parametrelerin denklemidir.

$$\frac{\|w\|^2}{2} + C \left( \sum (\xi_i)^k \right) \quad (3.19)$$

C ve k kullanıcı tarafından belirlenir ve veri setine bağlı olarak değişebilir. w ve  $\xi$  üzerinden sınırlı optimizasyon problemleri Denklem 3.20 ve Denklem 3.21'deki gibi formüle edilmiştir.

$$w \cdot x_i + b \geq 1 - \xi_i \quad \text{if } y_i = 1, \quad (3.20)$$

$$w \cdot x_i + b \leq -1 + \xi_i \quad \text{if } y_i = -1, \quad (3.21)$$

Yumuşak marj için Lagrange çarpanı, doğrusal karar sınırındaki Lagrange çarpanlarından farklıdır.  $\alpha_i$  değerleri negatif olmamalı ve ayrıca C'ye eşit veya daha küçük olmalıdır. Bu nedenle, C parametresi karar sınırındaki hata için üst sınır görevi görür.

Doğrusal DVM, bir hiper düzlemlerle kolayca iki parçaya ayrılabilen veri setlerinde iyi performans gösterir. Ancak bazen veri kümeleri karmaşıktır ve doğrusal bir çekirdek kullanarak sınıflandırılması zordur. Doğrusal olmayan DVM sınıflandırıcıları bu tür karmaşık veri kümeleri için kullanılabilir. Doğrusal olmayan DVM sınıflandırıcısının arkasındaki kavram, veri kümesini, doğrusal bir karar sınırı kullanarak verilerin ayrılabilir olduğu yüksek boyutlu bir alana dönüştürmektir. Gerçekten bu alanda karar sınırı doğrusal değildir. Veri setini daha yüksek boyuta dönüştürmede asıl sorun, sınıflandırıcının karmaşıklığının artmasıdır. Ayrıca, verileri daha yüksek boyutlu uzayda doğrusal olarak ayırabilen kesin haritalama işlevi bilinmemektedir. Bunun üstesinden gelmek için, verileri daha yüksek boyutlu uzaya dönüştürmek amacıyla “çekirdek numarası” olarak adlandırılan bir kavram kullanılır. Eğer  $\emptyset$  haritalama fonksiyonu ise, daha yüksek boyutlu bir alanda doğrusal karar sınırını bulmak için, Denklem 3.22'deki  $x$  özniteliği  $\emptyset(x)$  ile değiştirilir. Dönüştürülmüş Lagrange ikili formu Denklem 3.22'deki gibidir.

$$L_D = \sum_{i=1}^n a_i a_j y_i y_j \phi(X_i) \phi(X_j) \quad (3.22)$$

Nokta ürün, iki vektör arasındaki benzerliğin bir ölçüsüdür. Çekirdek numarasının ardındaki temel fikir, nokta ürünü orijinal ve dönüştürülmüş alanda benzer olarak görmesidir. Orijinal alandaki iki giriş örneği vektörü  $x_i$  ve  $x_j$  düşünülün. Daha yüksek bir boyuta değiştirildiğinde, sırasıyla  $\phi(X_i)$  ve  $\phi(X_j)$  'ye dönüştürülürler. Benzer şekilde, orijinal alandaki benzerlik ölçüsü, yüksek boyuttaki alanda  $x_i \cdot x_j$ 'den,  $\phi(X_i) \cdot \phi(X_j)$  'e dönüştürülür.  $\phi(X_i)$  ve  $\phi(X_j)$  nokta ürününe “çekirdek işlevi” denir ve  $K(x_i, x_j)$  ile temsil edilir. Çekirdek numarası, nokta ürünlerinin her iki alanda da benzer olduğunu varsaydığından, orijinal öznitelik kümesini kullanarak, dönüştürülen alanda çekirdek işlevinin hesaplanmasına yardımcı olur. Bu nedenle, alt boyut uzayındaki orijinal doğrusal olmayan karar sınır denklemi, (Abdul ve Basha, 2011) Denklem 3.23 tarafından verilen yüksek boyut uzayındaki doğrusal karar sınır denklemine dönüştürülür.

$$w \cdot \phi(X) + b = 0 \quad (3.23)$$

### 3.2.3 Çekirdek Fonksiyonları ile Oluşturulan DVM

Çekirdek yöntemleri, en iyi bilinen ögesi Destek Vektör Makinesi (DVM) olan, örüntü analizi veya tanıma için kullanılan bir algoritma sınıfıdır. Örüntü analizinin genel görevi, bazı verilerdeki (diziler, metin belgeleri, nokta kümeleri, vektörler, görüntüler gibi) ilişki türlerini (kümeler, sıralamalar, temel bileşenler, korelasyonlar, sınıflandırmalar) bulmak ve incelemektir. Çekirdek yöntemleri, yüksek boyutlu alanda verilerin daha kolay ayrılabilir veya daha iyi yapılandırılmış olmasını sağlar.

Çekirdek fonksiyonları çok ilginç ve güçlü bir araçtır çünkü doğrusal ve doğrusal olmayan iki vektör arasındaki iç çarpımla ifade edilebilen herhangi bir algoritmaya köprü sağlar. Girdi verileri ilk önce daha yüksek boyutlu bir alana eşlenirse, bu alandaki doğrusal bir algoritmanın girdi alanında doğrusal olmayan bir şekilde davranması söz konusudur.

DVM algoritmaları, çekirdek olarak tanımlanan bir dizi matematiksel işlev kullanır. Çekirdeğin işlevi, veriyi girdi olarak almak ve gerekli forma dönüştürmektir. Farklı DVM algoritmaları farklı çekirdek fonksiyonları kullanır. Bu fonksiyonlar

doğrusal, doğrusal olmayan, polinom, radyal temel işlevi (RBF) ve sigmoid gibi farklı tiplerde olabilir. Çizelge 3.6 çekirdek tipleri ve fonksiyonları göstermektedir.

Çizelge 3.6 Çekirdek tipleri ve fonksiyonları

Çekirdek tipi	Fonksiyon	Optimizasyon Parametreleri
Doğrusal	$k(x, y) = x^T * y + c$	C
ANOVA RBF	$k(x, y) = \sum_{k=1}^n \exp(-\sigma(x^k - y^k)^2)^d$	C, sigma, derece
RBF	$k(x, y) = \exp(-\gamma \ x - y\ ^2)$	C, gamma
Laplace	$K(x, y) = \exp(-\frac{\ x - y\ }{\sigma})$	C, sigma

C (maliyet) parametresi, hiperdüzlemin düzgünlüğü ile eğitim verilerinin yanlış sınıflandırılması arasındaki dengeyi sağlar. C parametresi küçük seçildiği takdirde, bazı eğitim verilerinin yanlış sınıflandırılması pahasına da olsa düzgün ve geniş aralıklı bir hiperdüzlem seçilir. C parametresinin büyük seçildiği durumlarda ise eğitim verilerinin doğru bir şekilde sınıflandırılabilmesi için daha karmaşık ve daha küçük aralıklı bir hiperdüzlem seçilir (Cortes ve Vapnik, 1995).

C parametresinin aksine  $\sigma$  (sigma),  $\gamma$  (gamma) ve d (derece) parametreleri çekirdek fonksiyonu parametreleridir. Sigma, Laplace ve ANOVA RBF çekirdek fonksiyonlarının parametresi; d (derece), ANOVA RBF çekirdek fonksiyonlarının parametresi ve gamma, RBF çekirdek fonksiyonunun parametresidir. Sigma, gamma, derece parametreleri sınıflandırma performansına doğrudan etki eden parametreler olup değer aralıkları dikkatle seçilmelidir (Güldoğan ve ark., 2017).

### 3.2.4 Karmaşıklık Matrisi

Karmaşıklık matrisi, farklı tahminleri ve test sonuçlarını özetleyen ve bunları gerçek dünya değerleri ile karşılaştıran bir tablodur. Karmaşıklık matrisleri istatistiklerde, veri madenciliğinde, makine öğrenim modellerinde ve diğer yapay zekâ

(YZ) uygulamalarında kullanılmaktadır. Karmaşıklık matrisi "hata matrisi" olarak da adlandırılabilir.

Karmaşıklık matrisleri, istatistiksel verilerin derinlemesine analizini daha hızlı yapmak ve sonuçların net veri görselleştirmesi yoluyla okunmasını kolaylaştırmak için kullanılır. Tablolar istatistik, veri madenciliği, adli tıp ve tıbbi testlerdeki hataları analiz etmeye yardımcı olur. Kapsamlı bir analiz, kullanıcıların sadece performansı değerlendirmek yerine hangi sonuçların nasıl yapıldığını gösterdiğine karar vermesine de yardımcı olur.

Karmaşıklık matrisleri tahminleri kaydetmek için basit bir format kullanır. Bir makine öğrenme modeli için bir karmaşıklık matrisinin satırlarında, olası tahminler sağ tarafta ve üst kısımdaki gerçeklerle aynı hizadadır. Gerçeklerin altındaki satırlara, tahminler veya sonuçlar kaydedilir. Sonuçlar, doğru pozitif olarak doğru bir pozitif veya doğru negatif olarak negatif bir belirtinin yanı sıra yanlış pozitif olarak yanlış bir pozitif veya yanlış negatif olarak yanlış bir negatif içerebilir. İkili bir sınıflandırıcı için örnek bir karmaşıklık matrisi Çizelge 3.7'de verilmiştir.

Çizelge 3.7 Karmaşıklık matrisi örneği

N=165	Öngörülen:	Öngörülen:
	Hayır	Evet
Gerçek:		
Hayır	<b>50</b>	10
Gerçek:		
Yes	5	<b>100</b>

Çizelge 3.7'deki Karmaşıklık Matrisi'ne göre:

- İki olası öngörülen sınıf vardır: Bunlar "evet" ve "hayır"dır. Bir hastalığın varlığını tahmin ediyor olsaydık; örneğin, "evet" kişilerin hastalığa sahip olduğu anlamına gelirken, "hayır" hastalığın olmadığı anlamına gelirdi.
- Sınıflandırıcı toplam 165 tahmin yapmıştır (örneğin, 165 kişi bu hastalığın varlığı için test edilmiştir).
- Bu 165 durumdan, sınıflandırıcı 110 kez "evet" ve 55 kez "hayır" öngörmüştür.

- Gerçekte, deneydeki 105 kişide bu hastalık varken, 60 kişide hastalık yoktur.
- Gerçek pozitifler (GP): “Evet” öngörülen (hastalıkları var) ve gerçekte hastalığı olan kişilerin sayısıdır.
- Gerçek negatifler (GN): “Hayır” öngörülen ve gerçekte hastalığı olmayan kişilerdir.
- Yanlış pozitifler (YP): “Evet” öngörülen ancak gerçekte hastalığı olmayan kişilerdir, (Ayrıca "Tür I hatası" olarak da bilinir).
- Yanlış negatifler (YN): “Hayır” öngörülen, ancak gerçekte hastalığı olan kişilerdir, ("Tip II hatası" olarak da bilinir).

Bu terimlerin karmaşıklık matrisinde gösterimi Çizelge 3.8’de verilmiştir.

Çizelge 3.8 Karmaşıklık matrisinin terimler eklenmiş hali.

N=165	Öngörülen:	Öngörülen:	
	Hayır	Evet	
Gerçek:			
Hayır	<b>TN=50</b>	FP=10	60
Gerçek:			
Evet	FN=5	<b>TP=100</b>	105
	55	110	

Herhangi bir ikili sınıflandırıcı için genellikle karmaşıklık matrisinden hesaplanan istatistiksel oranlar şöyledir:

- Doğruluk: Sınıflandırıcının doğruluk oranı nedir?  
 $(GP+GN)/\text{toplam kişi sayısı} = (100+50)/165 = 0.91$
- Yanlış Sınıflandırma Oranı: Sınıflandırıcının yanlışlık oranı nedir?  
 $(YP+YN)/\text{toplam kişi sayısı} = (10+5)/165 = 0.09$   
“Hata oranı” olarak da bilinir.
- Gerçek Pozitif Oran: Sınıflandırıcının gerçek “evet” oranı nedir?  
 $GP/\text{gerçek evet} = 100/105 = 0.95$   
“Sensitivite ve Duyarlılık” olarak da bilinir.
- Yanlış Pozitif Oran: Sınıflandırıcının gerçek “hayır” oranı nedir?  
 $YP/\text{gerçek hayır} = 10/60 = 0.17$

- Gerçek Negatif Oran: Gerçekte “hayır” olduğunda, “hayır” olarak öngörülenlerin oranı nedir?  
GN/gerçek hayır = 50/60 = 0.83  
"Spesifite" olarak da bilinir.
- Hassasiyet: “Evet” olarak öngördüğünde ne sıklıkta doğrudur?  
GP/öngörülen evet = 100/110 = 0.91
- Prevalans: “Evet” şartı ne kadar sıklıkla örnekte ortaya çıkıyor?  
gerçek evet / toplamkişi sayısı = 105/165 = 0.64

### 3.2.5 MIT-BIH Veri Setini Kullanarak DVM Algoritmasının Eğitimi

Bir Destek Vektör Makinesi (DVM), bir tür denetimli makine öğrenme sınıflandırma algoritmasıdır. DVM'ler ilk olarak 1960'larda tanıtılmış ve daha sonra 1990'larda geliştirilmiştir. Doğru sonuçlar elde etme kabiliyetleri sayesinde, son derece popüler hale gelmişlerdir. DVM'ler, diğer makine öğrenme algoritmalarına kıyasla benzersiz bir şekilde uygulanmaktadırlar.

Bu tezde EKG sinyallerine göre dört tip sınıflandırma yapılmıştır: Normal sinüs ritmi, ventriküler bigemine, ventriküler taşikardi ve ventriküler trigeminedir. Bunun için RBF çekirdekli DVM kullanılmıştır. Python kullanarak yapılan sınıflandırma işlemi için parametre değerleri Şekil 3.10'da verilmiştir.

```
import numpy as np
from sklearn import svm
import pandas as pd
import csv
from sklearn.svm import SVC
from sklearn.metrics import classification_report
from sklearn.metrics import accuracy_score
```

Şekil 3.10 Python 'da DVM'nin kodu.

Bir model üzerinde çalışmak ve onu eğitmek için bir eğitim veri kümesinin olması gerekmektedir. Eğitimden sonra model, test veri kümeleri üzerinde test edilmelidir. Gerçekte, finansal veriler veya müşteri verileri gibi her türlü veriler mevcuttur. Bu çalışmada, hastanın aritmi türünü belirlemek için MIT-BIH aritmi veri

kümesi temel alınarak DVM algoritması eğitilmiştir. Bunun için Python kullanılmış ve sonra DVM algoritması için Şekil 3.11’de gösterildiği gibi kod yazılmıştır.

```
#test rbf svm
clf = SVC(kernel = 'rbf',gamma=1000,C=1000)
clf.fit(X_test,y_test)

#Predict the dataset

predicted =clf.predict(X_test)
cnf_matrix = confusion_matrix(y_test, predicted)
plt.figure()
plot_confusion_matrix(cnf_matrix,
                      classes=['Normal','VentBig','VentTach','VentTri'],
                      title='Confusion matrix, without normalization')
plt.show()
print("accurecy=rbf test GAMMA =1000 C=1000")
predicted =clf.predict(X_test)
print(accuracy_score(y_test,predicted))
p=classification_report(y_test, predicted, target_names=None)
print(p)
```

Şekil 3.11 Python’da veri setinde DVM eğitimi

### 3.2.6 Akıllı Telefon Uygulaması


Android Studio, IntelliJ IDEA'ya dayanan, Android uygulama geliştirme için resmi Entegre Geliştirme Ortamı’dır (IDE). IntelliJ’in güçlü kod editörü ve geliştirici araçlarında, Android uygulamaları Java dilinde yazılmış ve dx dönüştürücü kullanılarak bir .dex dosyasına (Dalvik çalıştırılabilir dosya) dönüştürülecek bayt kodlarına derlenmiştir. Bu, Android cihazlara yüklenebilecek olan Android paket dosyasına (Apk dosyası) yüklenmiştir.

Android uygulama mağazaları, uygulamaların açıklamalarına göre çeşitli kategorilerde el ile sınıflandırılan çok sayıda uygulama içerir. Bununla birlikte, önceden tanımlanmış kategorilerin veya uygulamaların açıklamaları genellikle uygulamaların gerçek işlevlerini yansıtacak kadar doğru değildir. Bu nedenle uygulamaların yanlış sınıflandırılmasına neden olur, bu da uygulama mağazasında ciddi güvenlik sorunlarına neden olabilir. Bundan dolayı, otomatik uygulama sınıflandırması, güvenilir ve gezinmesi kolay bir uygulama mağazası oluşturmak için önemlidir. Bu uygulamada BMD101 çipi, cihazı giyen kişinin kalbinden elektrik sinyallerini alır. DVM

algoritmasını kullanarak bu sinyallerin; normal sinüs ritmi, ventriküler bigemine, ventriküler taşikardi veya ventriküler trigemine olup olmadığını belirtir. Bu işlem birkaç adımdan oluşmaktadır:

- Adım 1: Tasarım:

Bir Android stüdyosunda bir uygulama oluşturmak istenildiğinde, önceden belirli bir tasarım için plan olmalıdır. Bu uygulamada üç buton ve birkaç textview seçilmiştir. Buttons: connect, disconnect ve dataset olarak üçe ayrılmaktadır. “Connect” butonu, mobil cihaz ile EKG cihazı arasındaki iletişimden sorumludur. “Disconnect” butonu, cep telefonu ile EKG cihazı arasındaki bağlantıyı kesmekten sorumludur. “Dataset” butonu ise EKG sinyallerini veri tabanına kaydetmekten sorumludur. Şekil 3.12 uygulamanın tasarım arayüzünü göstermektedir.



Şekil 3.12 Mobil uygulamanın arayüz tasarımı

- Adım 2: Telefon ile BMD101 çipi arasındaki iletişim:

BMD101, iletişim için UART arayüzünü kullanır. UART arayüzü 57600-baud hızında çalışır ve 64 byte TX FIFO'ya sahiptir. UART arayüzü, bilgisayar veya

akıllı telefonun EKG verilerini işlemesini ve görüntülemesini sağlayan USB'den UART'a herhangi bir tıklama ile kullanılabilir. Sensör tarafından kaydedilen sinyal, Bluetooth ile akıllı telefona iletilmiştir. Bu yüzden Android stüdyosundan bluetooth Adaptör kütüphanesi içe aktarılmıştır ve Şekil 3.13'teki kod yazılmıştır.

```

if (bluetoothAdapter== null) //
// Alert user that Bluetooth is not available
Toast.makeText(this, "Bluetooth not available",
Toast.LENGTH_LONG).show();
///finish();
return;
}
else {
// create the TGDevice
tgDevice= new TGDevice (bluetoothAdapter, handler);
}

```

Şekil 3.13 Telefon ile BMD101 çipi arasındaki iletişimin kodu

- Adım 3: DVM algoritması için yeni bir aktivite oluşturmak:

Bu adımda DVM algoritması için yeni bir işlem yapılmıştır. Python kullanılarak DVM algoritması MIT-BIH veri kümesinde daha önce eğitilmiştir ve bunu Sklearn'den yapmak için Porter kullanılmıştır. Porter, sklearn kütüphanesi içindeki bir araçtır ve çıktıların Android stüdyosunda kullanılmış dil olan Java dilinde basılmasına yardımcı olur. Bu adımda ise, eğitimden sonra Android Stüdyosunda Java dilinde basılmış olan DVM algoritmasının kodu yazılmıştır.

- Adım 4: Uygulamanın çalışması:

Bu adımda BMD101 çipi, cihazı kullanan kişinin kalbinden elektrik sinyallerini alır ve bunları DVM algoritmasını kullanarak; normal sinüs ritmi, ventriküler bigemine, ventriküler taşikardi ve ventriküler trigemineden oluşan dört vakayı MIT-BIH veri setine göre sınıflandırır. İlk önce cep telefonuna Bluetooth ile bağlanılır ve sonra cihazı kullanan kişinin yaşı girilir. Cep telefonuna bağlandıktan sonra, EKG sinyalleri görünene kadar biraz beklenir ve yaklaşık 10 saniye sonra, algoritma, kalp sinyallerinden kaynaklanan R-R aralığını esas

olarak durumları sınıflandırır. BMD101, EKG sinyalleri alır ve bu sinyalleri Denklem 3.24'e göre R-R aralığı'na dönüştürür.

$$RR \text{ [milisaniye]} = 60 \text{ saniye} * 1000RR \text{ [milisaniye]} = (60 \text{ saniye} * 1000 / \text{BPM}) / 1000 \quad (3.24)$$

DVM algoritması, EKG sinyallerini R-R aralıklarına dönüştürdükten sonra sinyali MIT-BIH veri seti ile karşılaştırır. Sonuç 1 ise durum normaldir. Sonuç 2 ise durum ventriküler bigeminedir. Sonuç 3 ise durum ventriküler taşikardidir. Sonuç 4 ise durum ventriküler trigeminedir. Şekil 3.14 sınıflandırmayı yapan kodu vermektedir.

```
public void onFinish() {
    int result = clf.predict(features);
    if (result == 1) {
        //Toast.makeText(MainActivity.this, "Normal",
        Toast.LENGTH_LONG).show();
        myDb.insertData("Classification : Normal"+"\\n");
    }
    if (result == 2) {
        myDb.insertData("Classification : Ventricular bigeminy"+"\\n");
    }
    if (result == 3) {
        myDb.insertData("Classification : Ventricular tachycardia"+"\\n");
    }
    if (result == 4) {
        myDb.insertData("Classification : Ventricular trigeminy"+"\\n");
    }
}
```

Şekil 3.14 Sonuçların sınıflandırılması

Bu uygulamanın amacı, kalp hastalığı riski olan kişilerin doktora gitmeden önce durumunun erken teşhisini yapmasına yardımcı olmaktır. Bu şekilde, hastalıkların ilerlemeden ve geç olmadan farkına varılması ve doktora başvurup durumun kontrol altına alınması amaçlanmıştır. Şekil 3.15 mobil uygulamanın çalışma ekranını göstermektedir.



Şekil 3.15 Mobil EKG uygulaması

#### 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu tezde en iyi sonuçları elde etmek için iki algoritma kullanılmıştır. Bu algoritmalar KNN algoritması ve DVM algoritmasıdır. Önerilen algoritmalar 4 nitelikli ve 6 nitelikli MIT-BIH veri tabanı üzerinde değerlendirilmiştir. 4 nitelikli MIT-BIH veri tabanı üzerinde yapılan çalışma akıllı telefon uygulamasında kullanılmıştır. 6 nitelikli MIT-BIH veri tabanı ise literatürdeki çalışmalar ile karşılaştırmak üzere kullanılmıştır. Her iki çalışmada KNN algoritmasının ve DVM algoritmasının sonuçları karşılaştırılmaktadır.

1. KNN Algoritması: Bilgisayar destekli EKG analizinin performansı, QRS komplekslerinin kesin ve doğru tanımlanmasına bağlıdır. Bu tez, EKG'de QRS kompleksinin tespiti için bir sınıflandırıcı olarak K-En Yakın Komşu (KNN) algoritmasının bir uygulamasını sunmaktadır. Önerilen algoritma, MIT-BIH aritmi veri tabanı (4 nitelikli ve 6 nitelikli) gibi standart veri tabanları üzerinde değerlendirilmiştir. KNN sınıflandırıcısının doğruluğu, büyük ölçüde K'nin değerine ve mesafe ölçüm türüne bağlıdır. KNN sınıflandırıcısı için K=3 ve K=5 değeri ve Öklid uzaklığı ölçümü önerilmiştir. Önerilen algoritma ile MIT-BIH aritmi veri tabanları kullanılarak yayınlanan diğer çalışmalar arasında da bir karşılaştırma yapılmaktadır. Bu sonuçlar açıkça güvenilir ve doğru QRS tespiti için KNN algoritmasını belirlemektedir. 4 nitelikli MIT-BIH veri tabanında KNN algoritması kullanılarak elde edilen sonuçlar, Çizelge 4.1, 4.2, 4.3 ve Çizelge 4.4'de sunulmaktadır. 6 nitelikli MIT-BIH veri tabanında KNN algoritması kullanılarak elde edilen sonuçlar ise Çizelge 4.5, 4.6, 4.7 ve Çizelge 4.8'de sunulmaktadır.

**Çizelge 4.1.** K = 3 için KNN Sınıflandırıcı Doğruluk oranı (4 nitelik)

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	99%	100%	100%	253
Ventriküler Bigemine	100%	69%	100%	81%	11
Ventriküler Taşikardi	62.5%	100%	62%	77%	8
Ventriküler Trigemine	60%	100%	60%	75%	10
Ortalama	97.51%	98%	98%	97%	282

**Çizelge 4.2.** K = 3 için KNN sınıflandırıcısı Karmaşıklık Matrisi(4 nitelik)

		<b>Tahmin Sınıfı</b>				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
<b>Gerçek Sınıfı</b>	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>11</b>	0	0	11
	Ventriküler Taşikardi	2	1	<b>5</b>	0	8
	Ventriküler Trigemine	0	4	0	<b>6</b>	10
	Toplam	255	16	5	6	<b>275</b>

**Çizelge 4.3.** K = 5 için KNN Sınıflandırıcı Doğruluk oranı(4 nitelik)

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	98%	100%	99%	253
Ventriküler Bigemine	81.8%	60%	82%	69%	11
Ventriküler Taşikardi	50%	100%	50%	67%	8
Ventriküler Trigemine	40%	67%	40%	50%	10
Ortalama	95.74%	96%	96%	95%	282

**Çizelge 4.4.** K = 5 için KNN sınıflandırıcısı Karmaşıklık Matrisi (4 nitelik)

		<b>Tahmin Sınıfı</b>				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
<b>Gerçek Sınıfı</b>	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>9</b>	0	2	11
	Ventriküler Taşikardi	2	2	<b>4</b>	0	8
	Ventriküler Trigemine	2	4	0	<b>4</b>	10
	Toplam	257	15	4	6	<b>270</b>

**Çizelge 4.5.** K = 3 için KNN Sınıflandırıcı Doğruluk oranı(6 nitelik)

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	99%	100%	100%	253
Ventriküler Bigemine	72.7%	73%	73%	73%	11
Ventriküler Taşikardi	62.5%	100%	62%	77%	8
Ventriküler Trigemine	80%	73%	80%	76%	10
Ortalama	97.16%	97%	97%	97%	282

**Çizelge 4.6.** K = 3 için KNN sınıflandırıcısı Karmaşıklık Matrisi (6 nitelik)

		Tahmin Sınıfı					
		Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
Gerçek Sınıfı	Normal	253	0	0	0	253	
	Ventriküler Bigemine	0	8	0	3	11	
	Ventriküler Taşikardi	2	1	5	0	8	
	Ventriküler Trigemine	0	2	0	8	10	
Toplam		255	11	5	11	<b>274</b>	

**Çizelge 4.7.** K = 5 için KNN Sınıflandırıcı Doğruluk oranı(6 nitelik)

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	98%	100%	99%	253
Ventriküler Bigemine	63.6%	78%	64%	70%	11
Ventriküler Taşikardi	62.5%	100%	62%	77%	8
Ventriküler Trigemine	70%	64%	70%	67%	10
Ortalama	96.45%	96%	96%	96%	282

**Çizelge 4.8.** K = 5 için KNN sınıflandırıcısı Karmaşıklık Matrisi (6 nitelik)

		<b>Tahmin Sınıfı</b>				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
<b>Gerçek Sınıfı</b>	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>7</b>	0	4	11
	Ventriküler Taşikardi	2	1	<b>5</b>	0	8
	Ventriküler Trigemine	2	1	0	<b>7</b>	10
	Toplam	257	9	5	11	<b>272</b>

2. DVM Algoritması: Bu tez, Destek Vektör Makinesine (DVM) dayanan QRS kompleks tespiti için bir algoritma sunmaktadır. Önerilen algoritma, MIT-BIH aritmi veritabanı gibi açıklamalı standart veritabanlarında değerlendirilmiştir. Bu algoritma, kalbin elektriksel aktivitesini teşhis etmek için yazılımın temeli olarak kullanılabilir. Bu tezde farklı parametreler ile doğrusal çekirdekli DVM ve RBF çekirdekli DVM kullanılmıştır. Doğrusal çekirdekli DVM’de C=0.1, C=10 ve C=100 değerleri önerilmiştir. 4 nitelikli MIT-BIH veri tabanında doğrusal çekirdekli DVM algoritması kullanılarak elde edilen sonuçlar, Çizelge 4.9, 4.10, 4.11,4.12, 4.13, ve Çizelge 4.14'de sunulmaktadır. 6 nitelikli MIT-BIH veri tabanında doğrusal çekirdekli DVM algoritmasını kullanarak elde edilen sonuçlar, Çizelge 4.15,4.16, 4.17, 4.18, 4.19 ve Çizelge 4.20'de mevcuttur.

**Çizelge 4.9.** C=0.1 için doğrusal çekirdekli DVM sınıflandırıcısı doğruluk oranı (4 nitelik).

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	98%	100%	99%	253
Ventriküler Bigemine	81.8%	69%	82%	75%	11
Ventriküler Taşikardi	75%	100%	75%	86%	8
Ventriküler Trigemine	40	67%	40%	50%	10
Ortalama	96.45%	96%	96%	96%	282

**Çizelge 4.10.** C=0.1 için doğrusal çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi (4 nitelik).

		<b>Tahmin Sınıfı</b>				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
<b>Gerçek Sınıfı</b>	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>9</b>	0	2	11
	Ventriküler Taşikardi	2	0	<b>6</b>	0	8
	Ventriküler Trigemine	2	4	0	<b>4</b>	10
	Toplam	257	13	6	6	<b>272</b>

**Çizelge 4.11.** C=10 için doğrusal çekirdekli DVM sınıflandırıcısı doğruluk oranı(4 nitelik).

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	100%	100%	100%	253
Ventriküler Bigemine	100%	73%	100%	85%	11
Ventriküler Taşikardi	100%	100%	100%	100%	8
Ventriküler Trigemine	60%	100%	60%	75%	10
Ortalama	98.58%	99%	99%	99%	282

**Çizelge 4.12.** C=10 için doğrusal çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi(4 nitelik).

		<b>Tahmin Sınıfı</b>				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
<b>Gerçek Sınıfı</b>	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>11</b>	0	0	11
	Ventriküler Taşikardi	0	0	<b>8</b>	0	8
	Ventriküler Trigemine	0	4	0	<b>6</b>	10
	Toplam	253	15	8	6	<b>278</b>

**Çizelge 4.13.** C=100 için doğrusal çekirdekli DVM sınıflandırıcısı doğruluk oranı (4 nitelik)

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	100%	100%	100%	253
Ventriküler Bigemine	100%	79%	100%	88%	11
Ventriküler Taşikardi	100%	100%	100%	100%	8
Ventriküler Trigemine	70.0%	100%	70%	82%	10
Ortalama	98.93%	99%	99%	99%	282

**Çizelge 4.14.** C=100 için doğrusal çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi(4 nitelik).

		Tahmin Sınıfı				
		Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
Gerçek Sınıfı	Normal	253	0	0	0	253
	Ventriküler Bigemine	0	11	0	0	11
	Ventriküler Taşikardi	0	0	8	0	8
	Ventriküler Trigemine	0	3	0	7	10
	Toplam	253	14	8	7	279

**Çizelge 4.15.** C=0.1 için doğrusal çekirdekli DVM sınıflandırıcısı doğruluk oranı(6 nitelik).

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	98%	100%	99%	253
Ventriküler Bigemine	81.8%	69%	82%	75%	11
Ventriküler Taşikardi	75%	100%	75%	86%	8
Ventriküler Trigemine	40	67%	40%	50%	10
Ortalama	96.45%	96%	96%	96%	282

**Çizelge 4.16.** C=0.1 için doğrusal çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi (6 nitelik).

		<b>Tahmin Sınıfı</b>				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
<b>Gerçek Sınıfı</b>	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>9</b>	0	2	11
	Ventriküler Taşikardi	2	0	<b>6</b>	0	8
	Ventriküler Trigemine	2	4	0	<b>4</b>	10
	Toplam	257	13	6	6	<b>272</b>

**Çizelge 4.17.** C=10 için doğrusal çekirdekli DVM sınıflandırıcısı doğruluk oranı(6 nitelik).

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	100%	100%	100%	253
Ventriküler Bigemine	100%	73%	100%	85%	11
Ventriküler Taşikardi	100%	100%	100%	100%	8
Ventriküler Trigemine	60%	100%	60%	75%	10
Ortalama	98.58%	99%	99%	99%	282

**Çizelge 4.18.** C=10 için doğrusal çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi(6 nitelik).

		<b>Tahmin Sınıfı</b>				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
<b>Gerçek Sınıfı</b>	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>11</b>	0	0	11
	Ventriküler Taşikardi	0	0	<b>8</b>	0	8
	Ventriküler Trigemine	0	4	0	<b>6</b>	10
	Toplam	253	15	8	6	<b>278</b>

**Çizelge 4.19.** C=100 için doğrusal çekirdekli DVM sınıflandırıcısı doğruluk oranı (6 nitelik).

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	100%	100%	100%	253
Ventriküler Bigemine	100%	79%	100%	88%	11
Ventriküler Taşikardi	100%	100%	100%	100%	8
Ventriküler Trigemine	70.0%	100%	70%	82%	10
Ortalama	98.93%	99%	99%	99%	282

**Çizelge 4.20.** C=100 için doğrusal çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi (6 nitelik).

		Tahmin Sınıfı				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
Gerçek Sınıfı	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>11</b>	0	0	11
	Ventriküler Taşikardi	0	0	<b>8</b>	0	8
	Ventriküler Trigemine	0	3	0	<b>7</b>	10
	Toplam	253	14	8	7	<b>279</b>

RBF çekirdekli DVM'de Gamma=0.1 ve C=0.1, Gamma=1 ve C=1, Gamma=10 ve C=10, Gamma=100 ve C=100, Gamma=1000 ve C=1000 değerleri önerilmiştir. 4 nitelikli MIT-BIH veri tabanında RBF çekirdekli DVM algoritması kullanılarak elde edilen sonuçlar Çizelge 4.21, 4.22, 4.23, 4.24, 4.25, 4.26, 4.27, 4.28, 4.29 ve Çizelge 4.30'de sunulmaktadır. 6 nitelikli MIT-BIH veri tabanında RBF çekirdekli DVM algoritması kullanılarak elde edilen sonuçlar Çizelge 4.31, 4.32, 4.33, 4.34, 4.35, 4.36, 4.37, 4.38, 4.39 ve Çizelge 4.40'da mevcuttur.

**Çizelge 4.21.** Gamma=0.1C=0.1 için RBF çekirdekli DVM sınıflandırıcısı doğruluk oranı (4 nitelik)

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	98%	100%	99%	253
Ventriküler Bigemine	100%	44%	100%	61%	11
Ventriküler Taşikardi	0%	0%	0%	0%	8
Ventriküler Trigemine	0%	0%	0%	0%	10
Ortalama	93.61%	90%	94%	91%	282

**Çizelge 4.22.** Gamma=0.1 ve C=0.1 için RBF çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi

		Tahmin Sınıfı				
		Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
Gerçek Sınıfı	Normal	253	0	0	0	253
	Ventriküler Bigemine	0	11	0	0	11
	Ventriküler Taşikardi	2	6	0	0	8
	Ventriküler Trigemine	2	8	0	0	10
Toplam		257	25	0	0	264

**Çizelge 4.23.** Gamma=1 ve C=1 için RBF çekirdekli DVM sınıflandırıcısı doğruluk oranı (4 nitelik)

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	100%	100%	100%	253
Ventriküler Bigemine	100%	73%	100%	85%	11
Ventriküler Taşikardi	100%	100%	100%	100%	8
Ventriküler Trigemine	60%	100%	60%	75%	10
Ortalama	98.58%	99%	99%	99%	282

**Çizelge 4.24.** Gamma=1 ve C=1 için RBF çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi

		<b>Tahmin Sınıfı</b>				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
<b>Gerçek Sınıfı</b>	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>11</b>	0	0	11
	Ventriküler Taşikardi	0	0	<b>8</b>	0	8
	Ventriküler Trigemine	0	4	0	<b>6</b>	10
	Toplam	257	25	0	0	<b>278</b>

**Çizelge 4.25.** Gamma=10 C=10 için RBF çekirdekli DVM sınıflandırıcısı doğruluk oranı (4 nitelik)

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	100%	100%	100%	253
Ventriküler Bigemine	100%	79%	100%	88%	11
Ventriküler Taşikardi	100%	100%	100%	100%	8
Ventriküler Trigemine	70%	70%	70%	82%	10
Ortalama	98.93%	99%	99%	99%	282

**Çizelge 4.26.** Gamma=10 ve C=10 için RBF çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi

		<b>Tahmin Sınıfı</b>				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
<b>Gerçek Sınıfı</b>	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>11</b>	0	0	11
	Ventriküler Taşikardi	0	0	<b>8</b>	0	8
	Ventriküler Trigemine	0	3	0	<b>7</b>	10
	Toplam	253	14	8	7	<b>279</b>

**Çizelge 4.27.** Gamma=100 C=100 için RBF çekirdekli DVM sınıflandırıcısı doğruluk oranı (4 nitelik)

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	100%	100%	100%	253
Ventriküler Bigemine	100%	79%	100%	88%	11
Ventriküler Taşikardi	100%	100%	100%	100%	8
Ventriküler Trigemine	70%	70%	70%	82%	10
Ortalama	98.93%	99%	99%	99%	282

**Çizelge 4.28.** Gamma=100 ve C=100 için RBF çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi (4 nitelik)

	Hastalık Türü	Tahmin Sınıfı				Toplam
		Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	
Gerçek Sınıfı	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>11</b>	0	0	11
	Ventriküler Taşikardi	0	0	<b>8</b>	0	8
	Ventriküler Trigemine	0	3	0	<b>7</b>	10
	Toplam	253	14	8	7	<b>279</b>

**Çizelge 4.29.** Gamma=1000 C=1000 için RBF çekirdekli DVM sınıflandırıcısı doğruluk oranı(4 nitelik).

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	100%	100%	100%	253
Ventriküler Bigemine	90.9%	91%	91%	91%	11
Ventriküler Taşikardi	100%	100%	100%	100%	8
Ventriküler Trigemine	90%	90%	90%	90%	10
Ortalama	99.29%	99%	99%	99%	282

Çizelge 4.30. Gamma=1000 ve C=1000 için RBF çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi.

		Tahmin Sınıfı				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
Gerçek Sınıfı	Normal	253	0	0	0	253
	Ventriküler Bigemine	0	10	0	1	11
	Ventriküler Taşikardi	0	0	8	0	8
	Ventriküler Trigemine	0	1	0	9	10
	Toplam	253	11	8	10	280

Çizelge 4.31 .Gamma=0.1 C=0.1 için RBF çekirdekli DVM sınıflandırıcısı doğruluk oranı (6 nitelik).

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	98%	100%	99%	253
Ventriküler Bigemine	100%	44%	100%	61%	11
Ventriküler Taşikardi	0%	0%	0%	0%	8
Ventriküler Trigemine	0%	0%	0%	0%	10
Ortalama	93.61%	90%	94%	91%	282

Çizelge 4.32. Gamma=0.1 ve C=0.1 için RBF çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi.

		Tahmin Sınıfı				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
Gerçek Sınıfı	Normal	253	0	0	0	253
	Ventriküler Bigemine	0	11	0	0	11
	Ventriküler Taşikardi	2	6	0	0	8
	Ventriküler Trigemine	2	8	0	0	10
	Toplam	257	25	0	0	264

**Çizelge 4.33.** Gamma=1 C=1 için RBF çekirdekli DVM sınıflandırıcısı doğruluk oranı (6 nitelik).

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	100%	100%	100%	253
Ventriküler Bigemine	100%	73%	100%	85%	11
Ventriküler Taşikardi	100%	100%	100%	100%	8
Ventriküler Trigemine	60%	100%	60%	75%	10
Ortalama	98.58%	99%	99%	99%	282

**Çizelge 4.34.** Gamma=1 ve C=1 için RBF çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi.

		Tahmin Sınıfı				Toplam
		Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	
Gerçek Sınıfı	Normal	253	0	0	0	253
	Ventriküler Bigemine	0	11	0	0	11
	Ventriküler Taşikardi	0	0	8	0	8
	Ventriküler Trigemine	0	4	0	6	10
	Toplam	253	14	8	7	278

**Çizelge 4.35.** Gamma=10 C=10 için RBF çekirdekli DVM sınıflandırıcısı doğruluk oranı (6 nitelik).

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	100%	100%	100%	253
Ventriküler Bigemine	99.9%	91%	91%	91%	11
Ventriküler Taşikardi	100%	100%	100%	100%	8
Ventriküler Trigemine	90%	90%	99%	90%	10
Ortalama	99.29%	99%	99%	99%	282

**Çizelge 4.36.** Gamma=10 ve C=10 için RBF çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi.

		<b>Tahmin Sınıfı</b>				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
<b>Gerçek Sınıfı</b>	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>10</b>	0	1	11
	Ventriküler Taşikardi	0	0	<b>8</b>	0	8
	Ventriküler Trigemine	0	1	0	<b>9</b>	10
	Toplam	253	11	8	10	<b>280</b>

**Çizelge 4.37.** Gamma=100 C=100 için RBF çekirdekli DVM sınıflandırıcısı doğruluk oranı (6 nitelik).

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	100%	100%	100%	253
Ventriküler Bigemine	90.9%	100%	91%	95%	11
Ventriküler Taşikardi	100%	100%	100%	100%	8
Ventriküler Trigemine	100%	91%	100%	95%	10
Ortalama	99.64%	99%	99%	99%	282

**Çizelge 4.38.** Gamma=100 ve C=100 için RBF çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi.

		<b>Tahmin Sınıfı</b>				
	Hastalık Türü	Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	Toplam
<b>Gerçek Sınıfı</b>	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>10</b>	0	1	11
	Ventriküler Taşikardi	0	0	<b>8</b>	0	8
	Ventriküler Trigemine	0	0	0	<b>10</b>	10
	Toplam	253	10	8	11	<b>281</b>

**Çizelge 4.39.** Gamma=1000 C=1000 için RBF çekirdekli DVM sınıflandırıcısı doğruluk oranı (6 nitelik).

Hastalık Türü	Doğruluk	Hassasiyet	Duyarlılık	F-skor	Örnek
Normal	100%	100%	100%	100%	253
Ventriküler Bigemine	100%	100%	100%	100%	11
Ventriküler Taşikardi	100%	100%	100%	100%	8
Ventriküler Trigemine	100%	100%	100%	100%	10
Ortalama	100%	100%	100%	100%	282

**Çizelge 4.40.** Gamma=1000 ve C=1000 için RBF çekirdekli DVM sınıflandırıcısı Karmaşıklık Matrisi (6 nitelik).

	Hastalık Türü	Tahmin Sınıfı				Toplam
		Normal	Ventriküler Bigemine	Ventriküler Taşikardi	Ventriküler Trigemine	
Gerçek Sınıfı	Normal	<b>253</b>	0	0	0	253
	Ventriküler Bigemine	0	<b>11</b>	0	0	11
	Ventriküler Taşikardi	0	0	<b>8</b>	0	8
	Ventriküler Trigemine	0	0	0	<b>10</b>	10
	Toplam	253	11	8	10	<b>282</b>

Bu tez çalışmasında KNN ve DVM algoritması (doğrusal çekirdekli DVM ve RBF çekirdekli DVM) olmak üzere iki algoritma kullanılmıştır. KNN algoritmasında K parametresi için 3 ve 5 değerleri kullanılmıştır. MIT-BIH veri tabanından (4 nitelikli ve 6 nitelikli) elde edilen sonuçlara göre KNN algoritması K=3 değeri için en yüksek performansı göstermiştir. Doğrusal çekirdekli DVM’de C=0.1, C=10 ve C=100 değerleri önerilmiştir. Elde edilen sonuçlara göre doğrusal çekirdekli DVM algoritması C=100 değeri için en yüksek performansı göstermiştir. RBF çekirdekli DVM’de ise Gamma=0.1 ve C=0.1, Gamma=1 ve C=1, Gamma=10 ve C=10, Gamma=100 ve C=100, Gamma=1000 ve C=1000 değerleri kullanılmıştır. Elde edilen sonuçlara göre ise RBF-DVM algoritması Gamma=1000 ve C=1000 değerleri için en yüksek performansı göstermiştir. Çizelge 4.41, 4 nitelikli MIT-BIH veri tabanında KNN algoritması ve DVM algoritmasından elde edilen sonuçların karşılaştırılmasını

sunmaktadır. Çizelge 4.42, 6 nitelikli MIT-BIH veri tabanında KNN algoritması ve DVM algoritmasından elde edilen sonuçların karşılaştırılmasını sunmaktadır.

**Çizelge 4.41.4** nitelik için DVM ve KNN algoritmasını karşılaştırma sonuçları.

Sınıflandırıcı	Doğruluk	Hassasiyet	Duyarlılık	F-skor
KNN, K=3	97.51%	98%	98%	97%
KNN, K=5	95.74%	96%	96%	95%
Doğrusal çekirdekli DVM, C=0.1	96.45%	96%	96%	96%
Doğrusal çekirdekli DVM, C=10	98.58%	99%	99%	99%
Doğrusal çekirdekli DVM, C=100	98.93%	99%	99%	99%
RBF çekirdekli DVM, Gamma=0.1, C=0.1	93.61%	90%	94%	91%
RBF çekirdekli DVM, Gamma=1, C=1	98.58%	99%	99%	99%
RBF çekirdekli DVM, Gamma=10, C=10	98.93%	99%	99%	99%
RBF çekirdekli DVM, Gamma=100, C=100	98.93%	99%	99%	99%
RBF çekirdekli DVM, Gamma=1000, C=1000	99.29%	99%	99%	99%

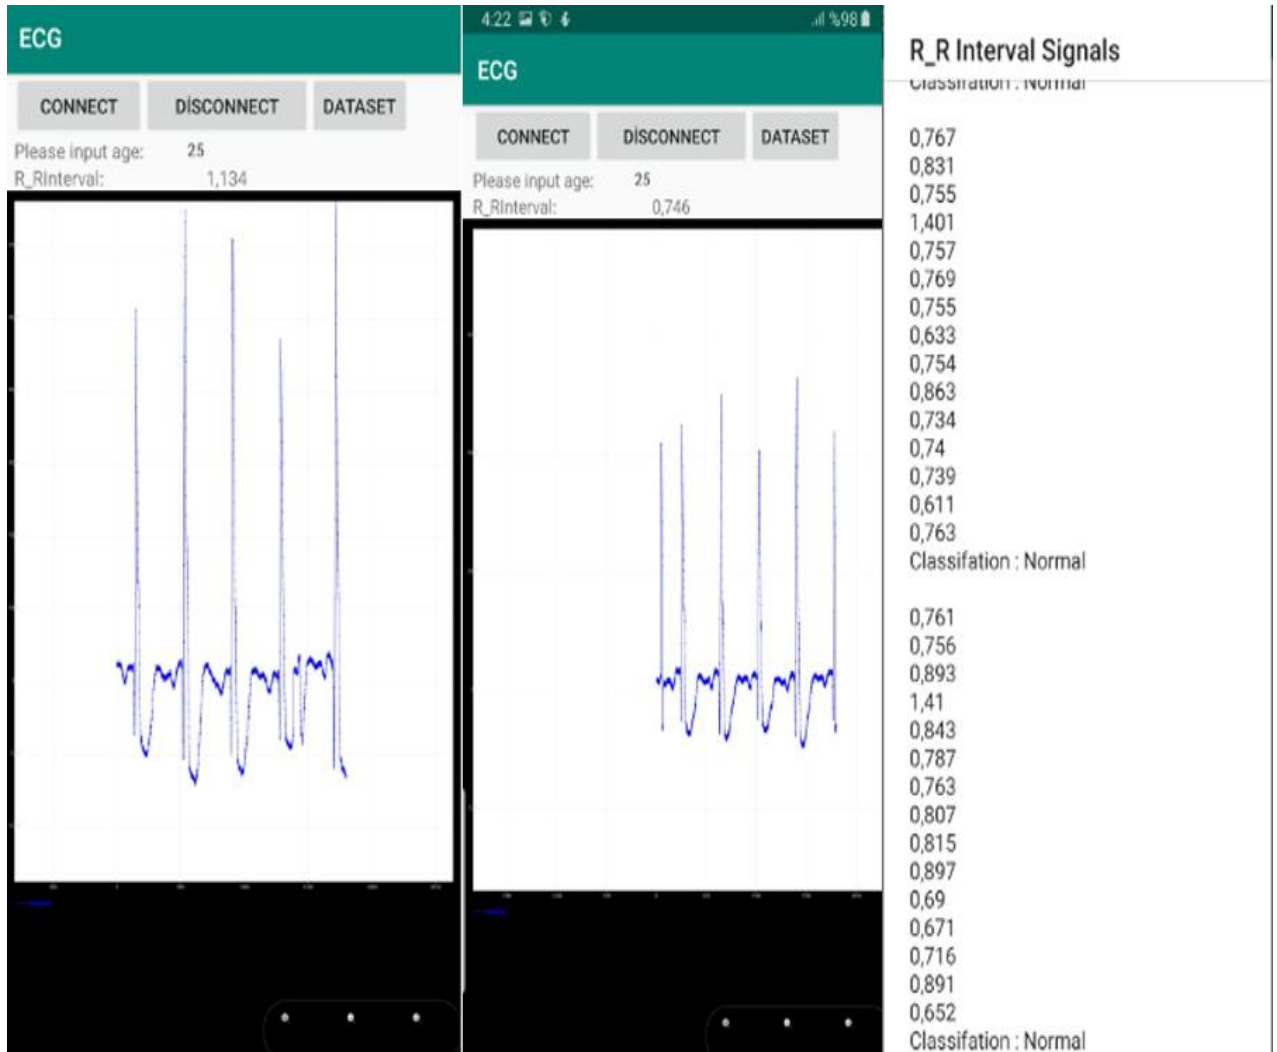
Çizelge 4.42.6 nitelik için DVM ve KNN algoritmasını karşılaştırma sonuçları.

Sınıflandırıcı	Doğruluk	Hassasiyet	Duyarlılık	F-skor
KNN, K=3	97.16%	97%	97%	97%
KNN, K=5	96.45%	96%	96%	96%
Doğrusal çekirdekli DVM, C=0.1	96.45%	96%	96%	96%
Doğrusal çekirdekli DVM, C=10	98.58%	99%	99%	99%
Doğrusal çekirdekli DVM, C=100	98.93%	99%	99%	99%
RBF çekirdekli DVM, Gamma=0.1 , C=0.1	93.61%	90%	94%	91%
RBF çekirdekli DVM, Gamma=1 , C=1	98.58%	99%	99%	99%
RBF çekirdekli DVM, Gamma=10 , C=10	99.29%	99%	99%	99%
RBF çekirdekli DVM, Gamma=100 , C=100	99.64%	100%	100%	100%
RBF çekirdekli DVM, Gamma=1000 , C=1000	100%	100%	100%	100%

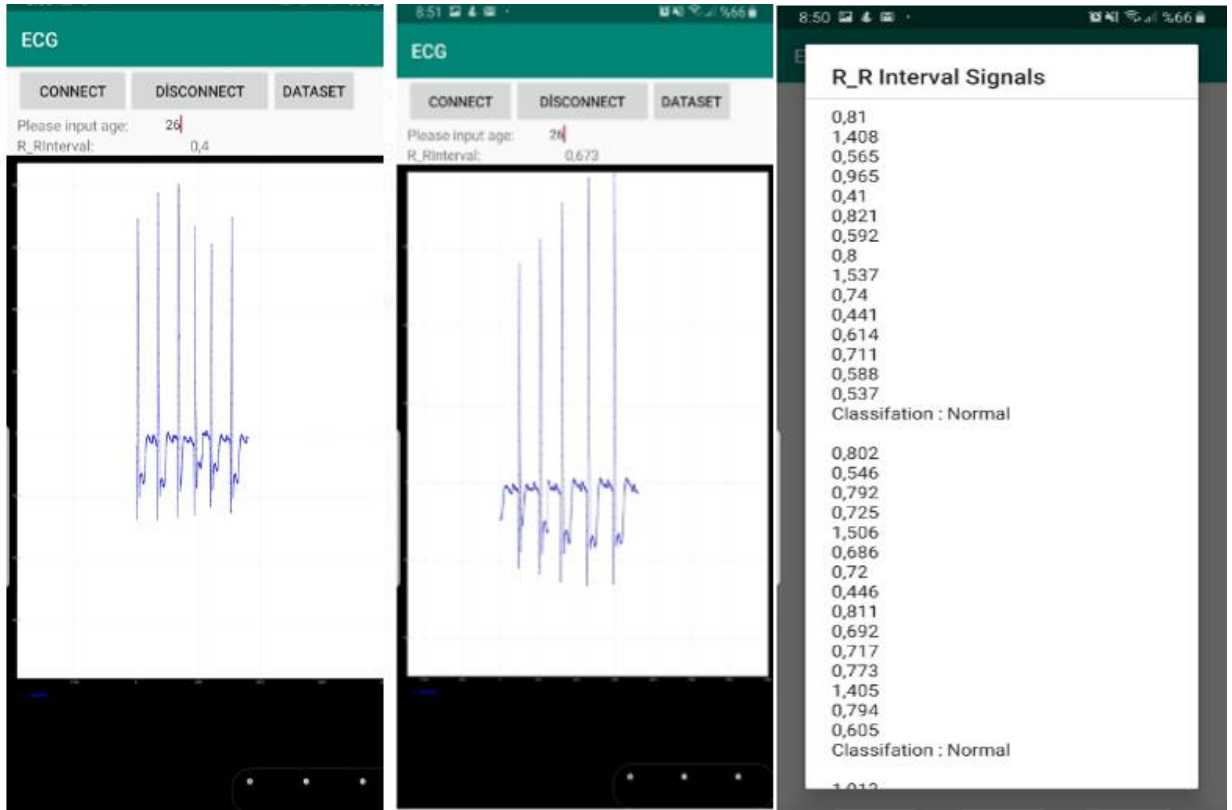
KNN ve DVM algoritmalarından elde edilen sonuçlar karşılaştırılmıştır. Karşılaştırma sonuçlarına göre yapılan her iki çalışmada Gamma=1000 ve C=1000 değerleri için RBF çekirdekli DVM algoritmasının performansı, KNN algoritmasının performansı ve doğrusal çekirdekli DVM algoritmasının performansına göre daha yüksek bulunmuştur.

Bu tez, RBF çekirdekli Destek Vektör Makineleri'ne (RBF-DVM) dayalı elektrokardiyografilerin (EKG) otomatik sınıflandırılması için bir yöntemin uygulanmasını içermektedir. Metot, EKG karakterizasyonu için ortaya çıkan vuruşlar arasındaki zaman aralıklarına dayanmaktadır. Tasarlanan metodoloji yaklaşımları, kamuya açık MIT-BIH aritmi veritabanında test edilmiştir. Dört sınıf anormal ve bir sınıf normal atımı sınıflandırmıştır. DVM algoritmasına dayanan bu yaklaşım, aynı

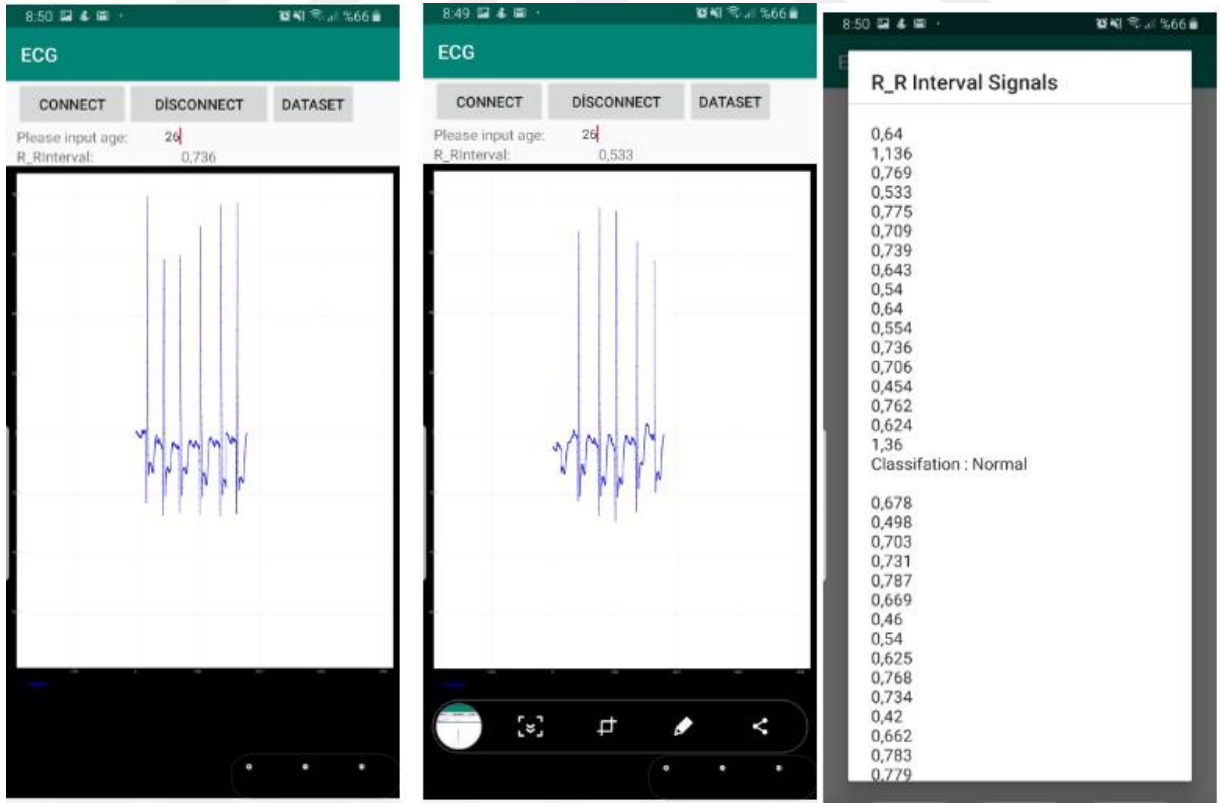
özellikleri kullanan tek bir DVM modeline kıyasla sonuçları iyileştiren tatmin edici bir performans sunmuştur. Ek olarak, bu yaklaşım, son teknolojiye ait önceki makine öğrenme yaklaşımlarıyla karşılaştırıldığında daha iyi sonuçlar göstermiştir. Programı test etmek için CardioChip (BMD101) cihazını giyen kişiden bir EKG sinyali alınmıştır ve CSV dosyasına kaydedilmiştir. DVM algoritması, EKG sinyallerinin normal mi yoksa anormal mi olduğunu tespit etmek için kişiden alınan sinyalleri MIH-BIH veri seti ile karşılaştırmıştır. Şekil 4.1,4.2 ve 4.3 uygulamada örneklerin sonuçlarını göstermektedir.



Şekil 4.1 Örneklerin sonuçları-1



Şekil 4.2 Örneklerin sonuçları-2



Şekil 4.3 Örneklerin sonuçları-3

## 5. SONUÇLAR VE ÖNERİLER

### 5.1 Sonuçlar

Günümüzde ulaşılabilen her yerde çeşitli sağlık kuruluşları bulunmaktadır. Ancak bütün bu sağlık kuruluşlarında tıp biliminin tüm alanlarına özgü uzmanlaşmış sağlık personellerinin olması her zaman mümkün olmamaktadır. Bundan dolayı bazı mühim hastalıklar erken teşhis edilememektedir. Erken teşhisin insan hayatını kurtarmadaki önemli rolünün daha iyi anlaşılmasıyla son zamanlarda metasezgisel algoritmalarla yapılan çalışmalar ön plana çıkmıştır. Bu tez çalışmasında ise MIT-BIH veri tabanından alınan veriler KNN, doğrusal-DVM ve RBF-DVM sistemleriyle sınıflandırılmış ve kalbe ait bazı ritm bozukluklarının teşhisi sağlanmıştır. Elde edilen sonuçlar daha sonra bu algoritmalar arasında karşılaştırılmıştır. Kullanılan sistemlerin performanslarının değerlendirilmesi de Python programlama dilinde yapılmıştır.

Bu tez çalışmasında, MIT-BIH aritmi veri tabanından alınan EKG sinyallerinde kritik noktalar belirlenmiştir ve QRS analizleri yapılmıştır. Bu noktalara göre QRS analizleri 4 farklı vuru tipine göre sınıflandırılmıştır. Bunlar; normal sinüs ritmi (N), ventriküler taşikardi (VT), ventriküler bigemine (B) ve ventriküler trigeminedir (T). Çalışmanın ön işleme kısmında, tepe mesafesini (R-R aralığı) elde etmek için EKG'den sinyal zaman vektörü çıkarılmıştır; sinyal vektörü, sinyal frekansı, sinyal örneklerinin büyüklüğü ve sinyal zaman büyüklüğü (saniye olarak) uygulanarak sinyale ait özelliklerin çıkarımı için hazır hale getirilmiştir. Kritik noktaların tespiti için zaman alanındaki özniteliklerin belirlenmesinde kalp hızındaki değişim, EKG'ye ait genlik bilgileri ve zaman aralıkları her bir örnek için çıkartılmıştır. VT, B ve T vurularının sınıflandırmasında ise sınıflandırıcı olarak ise literatürde en çok kullanılan yöntem olan DVM ve KNN seçilmiştir. EKG üzerinden çıkarılan R-R aralığı, genlik, kalp atış hızı, yaş, cinsiyet ve ilaç kullanımının öznitelikleri modelin girdileri olarak belirlenmiştir.

Bu çalışmada kullanılan sistemlerin performansları bazı parametrelere bağlı olarak değişiklik göstermiştir. Çalışmada KNN ve DVM (doğrusal çekirdekli DVM ve RBF çekirdekli DVM) algoritmaları kullanılmıştır. KNN algoritmasında K parametresi için 3 ve 5 değerleri kullanılmıştır. Elde edilen sonuçlara göre KNN algoritması K=3 değeri için en yüksek performansı göstermiştir. Doğrusal çekirdekli DVM'de C=0.1, C=10 ve C=100 değerleri önerilmiştir. Elde edilen sonuçlara göre doğrusal çekirdekli DVM algoritması C=100 değeri için en yüksek performansı göstermiştir. RBF

çekirdekli DVM'de ise  $\text{Gamma}=0.1$  ve  $C=0.1$ ,  $\text{Gamma}=1$  ve  $C=1$ ,  $\text{Gamma}=10$  ve  $C=10$ ,  $\text{Gamma}=100$  ve  $C=100$ ,  $\text{Gamma}=1000$  ve  $C=1000$  değerleri kullanılmıştır. Elde edilen sonuçlara göre ise RBF-DVM algoritması  $\text{Gamma}=1000$  ve  $C=1000$  değerleri için en yüksek performansı göstermiştir. KNN ve DVM algoritmalarından elde edilen sonuçlar karşılaştırılmıştır. Karşılaştırma sonuçlarına göre  $\text{Gamma}=1000$  ve  $C=1000$  değerleri için RBF çekirdekli DVM algoritmasının performansı; KNN algoritmasının ve doğrusal çekirdekli DVM algoritmasının performansına göre daha yüksek bulunmuştur.

Elde edilen sonuçlara göre tez çalışmasının sonuçlarının kardiyojide, analiz ve yorum yazılımı olarak, teşhis işlemini kolaylaştırabilecek önemli bir alternatif olacağı düşünülmektedir. Bu durum göz önüne alındığında da çalışmanın hem zamandan tasarruf sağlayabileceği hem de gözden kaçabilecek ani değişikliklerin yakalanmasında avantajlı olması beklenmektedir.

## 5.2 Öneriler

Bu çalışmada DVM ve KNN sınıflandırıcılar kullanılarak EKG sinyal verisinden kalp hastalıklarının teşhis edilmesi amaçlanmıştır. DVM algoritmasında doğrusal çekirdekli DVM ve RBF çekirdekli DVM olarak iki çekirdek fonksiyonu kullanılmıştır. Kullanılan algoritmaların başarılarının test edilmesi için farklı parametreler kullanılmıştır. Bunlar; KNN için  $K=3$  ve  $K=5$  parametreleri, doğrusal çekirdekli DVM için  $C=0.1$ ,  $C=10$ ,  $C=100$  parametreleri, RBF çekirdekli DVM için ise  $\text{Gamma}=0.1$  ve  $C=0.1$ ,  $\text{Gamma}=1$  ve  $C=1$ ,  $\text{Gamma}=10$  ve  $C=10$ ,  $\text{Gamma}=100$  ve  $C=100$ ,  $\text{Gamma}=1000$  ve  $C=1000$  parametreleridir. Bu tez çalışmasında, çalışmanın başarısını etkileyen yöntemlerin ve parametrelerin üzerinde durulmuştur.

Bu çalışmanın ön işleme aşamasında kullanılan veri tabanında sağlıklı ve hastalıklı kişi verileri eşit olarak dağılmamıştır. Bu da elde edilen sonuçları olumsuz etkilemiştir. Hastalıklı veri sayısının artırılarak daha doğru sonuçların elde edilmesi sağlanabilir.

Çalışmada 6 tane öznelik çıkarılmıştır. Çeşitli yöntemler kullanılarak öznelik sayısının çoğaltılıp doğruluğun artırılması sağlanabilir.

Sınıflandırma aşamasında sınıflandırıcılara ait farklı parametreler kullanılarak farklı performans analizleri yapılabilir.

Çalışma Python ortamında optimize edilmeyen kodlarla uygulanmıştır. Kodların optimize edilip, paralel programlama üzerinden daha kısa sürede sonuç vermesi ya da farklı bir programlama dilinde yazılıp yine daha kısa sürede sonuç vermesi sağlanabilir.



## KAYNAKLAR

- Abdul, S. ve Basha, A., 2011, SVM Classification and Analysis of Margin Distance on Microarray Data, *University of Akron*.
- Addison, P. S., 2005, Wavelet transforms and the ECG: a review, *Physiological measurement*, 26 (5), R155.
- Aktürk, T. B., 2009, Pda Tabanlı Gerçek Zamanlı Ekg Görüntüleme Sistemi.
- Andersson, D., 2017, Real-time ECG for objective stress level measurement.
- Andreao, R. V., Dorizzi, B. ve Boudy, J., 2006, ECG signal analysis through hidden Markov models, *IEEE Transactions on Biomedical engineering*, 53 (8), 1541-1549.
- Anuradha, B. ve Reddy, V. V., 2008, ANN for classification of cardiac arrhythmias, *ARPN Journal of Engineering and Applied Sciences*, 3 (3), 1-6.
- Barman, T., Ghongade, R. ve Ratnaparkhi, A., 2016, Rough set based segmentation and classification model for ECG, *Advances in Signal Processing (CASP), Conference on*, 18-23.
- Batra, A. ve Jawa, V., 1975, Classification of arrhythmia using conjunction of machine learning algorithms and ECG diagnostic criteria, *Training Journal*.
- Behadada, O. ve Chikh, M. A., 2013, An interpretable classifier for detection of cardiac arrhythmias by using the fuzzy decision tree, *Artificial Intelligence Research*, 2 (3), 45.
- Bensujin, C. ve Hubert, C., 2014, Detection of ST Segment Elevation Myocardial Infarction (STEMI) Using Bacterial Foraging Optimization Technique, *Int. J. Eng. Technol*, 6 (2), 1212-1223.
- Ceylan, R., Özbay, Y. ve Karlik, B., 2009, A novel approach for classification of ECG arrhythmias: Type-2 fuzzy clustering neural network, *Expert Systems with Applications*, 36 (3), 6721-6726.
- Chen, Y.-l., Wang, T., Wang, B.-s. ve Li, Z.-j., 2009, A survey of fuzzy decision tree classifier, *Fuzzy Information and Engineering*, 1 (2), 149-159.
- Cortes, C. ve Vapnik, V., 1995, Support-vector networks, *Machine learning*, 20 (3), 273-297.
- Dalal, S. ve Birok, R., 2016, Analysis of ECG Signals using Hybrid Classifier, *Analysis*, 3 (7).
- De Gaetano, A., Panunzi, S., Rinaldi, F., Risi, A. ve Sciandrone, M., 2009, A patient adaptable ECG beat classifier based on neural networks, *Applied Mathematics and Computation*, 213 (1), 243-249.
- Delano, M. K., 2012, A long term wearable electrocardiogram (ECG) measurement system, *Massachusetts Institute of Technology*.
- El-Dahshan, E.-S. A., 2011, Genetic algorithm and wavelet hybrid scheme for ECG signal denoising, *Telecommunication Systems*, 46 (3), 209-215.
- Finlay, D. D., Bond, R. R., Kennedy, A., Guldenring, D., Moran, K. ve McLaughlin, J., 2015, The effects of electrode placement on an automated algorithm for detecting ST segment changes on the 12-lead ECG, *Computing in Cardiology Conference (CinC), 2015*, 1161-1164.
- Frénay, B., De Lannoy, G. ve Verleysen, M., 2009, Improving the transition modelling in hidden Markov models for ECG segmentation, *ESANN*.
- Fushiki, T., 2011, Estimation of prediction error by using K-fold cross-validation, *Statistics and Computing*, 21 (2), 137-146.

- Gaamouri, S., Salah, M. B. ve Hamdi, R., 2018, Denoising ECG Signals by Using Extended Kalman Filter to Train Multi-Layer Perceptron Neural Network, *Automatic Control and Computer Sciences*, 52 (6), 528-538.
- Gao, D., Madden, M., Schukat, M., Chambers, D. ve Lyons, G., 2004, Arrhythmia identification from ECG signals with a neural network classifier based on a Bayesian framework, *Proceedings of the 24th SGAI International Conference on Innovative Techniques and Applications of Artificial Intelligence*.
- Garshnek, V. ve Burkle Jr, F. M., 1999, Applications of telemedicine and telecommunications to disaster medicine: historical and future perspectives, *Journal of the American Medical Informatics Association*, 6 (1), 26-37.
- Ghosh, B., Indurkar, M. ve Jain, M., 2013, ECG: A simple noninvasive tool to localize culprit vessel occlusion site in acute STEMI, *Indian Journal of Clinical Practice*, 23 (10), 590-595.
- Goel, S., Tomar, P. ve Kaur, G., 2016, A fuzzy based approach for denoising of ECG signal using wavelet transform, *International Journal of Bio-Science and Bio-Technology*, 8 (2), 143-156.
- Güldoğan, E., ARSLAN, A. K. ve YAĞMUR, J., 2017, Çeşitli Çekirdek Fonksiyonları ile Oluşturulan Destek Vektör Makinesi Modellerinin Performanslarının İncelenmesi: Bir Klinik Uygulama, *Firat Tip Dergisi*, 22 (3).
- Guler, I. ve Ubeyli, E. D., 2007, Multiclass support vector machines for EEG-signals classification, *IEEE Transactions on Information Technology in Biomedicine*, 11 (2), 117-126.
- Güler, I. ve Übeyli, E. D., 2004, Application of adaptive neuro-fuzzy inference system for detection of electrocardiographic changes in patients with partial epilepsy using feature extraction, *Expert Systems with Applications*, 27 (3), 323-330.
- Gupta, K. O. ve Chatur, P., 2012, ECG Signal Analysis and Classification using Data Mining and Artificial Neural Networks 1.
- Huang, X.-M. ve Zhang, Y.-H., 2003, A new application of rough set to ECG recognition, *Machine Learning and Cybernetics, 2003 International Conference on*, 1729-1734.
- Jadhav, S. M., Nalbalwar, S. L. ve Ghatol, A. A., 2012, Artificial neural network models based cardiac arrhythmia disease diagnosis from ECG signal data, *International Journal of Computer Applications*, 44 (15), 8-13.
- Jeyalakshmi, M. ve Robin, C., 2016, Fuzzy based Expert system for Sleep Apnea diagnosis, *International Journal of Engineering Trends and Technology (IJETT)–Volume*, 35.
- Kampouraki, A., Manis, G. ve Nikou, C., 2009, Heartbeat time series classification with support vector machines, *IEEE Trans. Information Technology in Biomedicine*, 13 (4), 512-518.
- Legarreta, I. R., Addison, P. S., Reed, M., Grubb, N., Clegg, G. R., Robertson, C. E. ve Watson, J. N., 2005, Continuous wavelet transform modulus maxima analysis of the electrocardiogram: Beat characterisation and beat-to-beat measurement, *International Journal of Wavelets, Multiresolution and Information Processing*, 3 (01), 19-42.
- Lei, W. K., Li, B. N., Dong, M. C. ve Vai, M. I., 2007, AFC-ECG: an adaptive fuzzy ECG classifier, In: *Soft Computing in Industrial Applications*, Eds: Springer, p. 189-199.
- Li, C., Zheng, C. ve Tai, C., 1995, Detection of ECG characteristic points using wavelet transforms, *IEEE Transactions on biomedical engineering*, 42 (1), 21-28.

- Liang, W., Zhang, Y., Tan, J. ve Li, Y., 2014, A novel approach to ECG classification based upon two-layered HMMs in body sensor networks, *Sensors*, 14 (4), 5994-6011.
- Lo, C.-I., Chang, S.-S., Tsai, J.-P., Kuo, J.-Y., Chen, Y.-J., Huang, M.-Y., Lee, C.-H., Sung, K.-T., Hung, C.-L. ve Hou, C. J.-Y., 2018, Evaluation of the accuracy of ECG captured by CardioChip through comparison of lead I recording to a standard 12-lead ECG recording device, *Acta Cardiologica Sinica*, 34 (2), 144.
- Martínez, J. P., Almeida, R., Olmos, S., Rocha, A. P. ve Laguna, P., 2004, A wavelet-based ECG delineator: evaluation on standard databases, *IEEE Transactions on biomedical engineering*, 51 (4), 570-581.
- Mitra, S., Mitra, M. ve Chaudhuri, B. B., 2006, A rough-set-based inference engine for ECG classification, *IEEE Transactions on instrumentation and measurement*, 55 (6), 2198-2206.
- Moody, G. B. ve Mark, R. G., 2001, The impact of the MIT-BIH arrhythmia database, *IEEE Engineering in Medicine and Biology Magazine*, 20 (3), 45-50.
- Omran, S. S., Taha, S. ve Awadh, N. A., 2009, ECG Rhythm Analysis by Using Neuro-Genetic Algorithms, *Journal of Basic and Applied Sciences*, 1 (3), 522-530.
- Pal, D., Mandana, K., Pal, S., Sarkar, D. ve Chakraborty, C., 2012, Fuzzy expert system approach for coronary artery disease screening using clinical parameters, *Knowledge-Based Systems*, 36, 162-174.
- Pan, J. ve Tompkins, W. J., 1985, A real-time QRS detection algorithm, *IEEE Trans. Biomed. Eng.*, 32 (3), 230-236.
- Partal, T., KAHYA, E. ve CİĞİZOĞLU, K., 2011, Yağış verilerinin yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini, *İTÜDERGİSİ/d*, 7 (3).
- Polat, K., Akdemir, B. ve Güneş, S., 2008, Computer aided diagnosis of ECG data on the least square support vector machine, *Digital Signal Processing*, 18 (1), 25-32.
- Priyadharshini, V. ve Kumar, S., 2015, An Enhanced Approach on ECG Data Analysis using Improvised Genetic Algorithm, *International Research Journal of Engineering and Technology (IRJET)*, 2 (5), 1248-1256.
- Rajaguru, H. ve Prabhakar, S. K., 2017, KNN Classifier and K-Means Clustering for Robust Classification of Epilepsy from EEG Signals. A Detailed Analysis, diplom. de, p.
- Rodriguez, J. D., Perez, A. ve Lozano, J. A., 2009, Sensitivity analysis of k-fold cross validation in prediction error estimation, *IEEE transactions on pattern analysis and machine intelligence*, 32 (3), 569-575.
- Sao, P., Hegadi, R. ve Karmakar, S., 2015, ECG Signal Analysis Using Artificial Neural Network, *International Journal of Science and Research, National Conference on Knowledge, Innovation in Technology and Engineering*, 82-86.
- Schukat, M., Lyons, G. J., Gao, D., Madden, M. G. ve Chambers, D., 2004, Arrhythmia Identification from ECG Signals with a Neural Network Classifier Based on a Bayesian Framework.
- Senthilkumaran, N. ve Rajesh, R., 2010, A Note on Image Segmentation Techniques, *International J. of Recent Trends in Engineering and Technology*, 3 (2), 21-23.
- Setiawan, N., Venkatachalam, P. ve Fadzil, A. M., 2009, Rule selection for coronary artery disease diagnosis based on rough set, *International Journal of Recent Trends in Engineering*, 2 (5), 198.
- Silveira, R. M., Agulhari, C. M., Bonatti, I. S. ve Peres, P. L., 2007, A genetic algorithm to compress electrocardiograms using parameterized wavelets, *Signal*

- Processing and Information Technology, 2007 IEEE International Symposium on*, 402-407.
- Tripathy, B., Acharjya, D. ve Cynthya, V., 2013, A framework for intelligent medical diagnosis using rough set with formal concept analysis, *arXiv preprint arXiv:1301.6011*.
- Vishwa, A., Lal, M. K., Dixit, S. ve Vardwaj, P., 2011, Clasification of arrhythmic ECG data using machine learning techniques, *IJIMAI*, 1 (4), 67-70.
- Wakulicz-Deja, A. ve Peszek, P., 2003, Applying rough set theory to multi stage medical diagnosing, *Fundamenta Informaticae*, 54 (4), 387-408.
- Wang, T.-Y. ve Chiang, H.-M., 2007, Fuzzy support vector machine for multi-class text categorization, *Information Processing & Management*, 43 (4), 914-929.
- Yücel, M., GÖKTAŞ, H. H. ve ÖZKARACA, O., 2010, ERBİYUM KATKILI FİBER YÜKSELTEÇTE GÜRÜLTÜ FAKTÖRÜNÜN SICAKLIK BAĞIMLILIĞI, *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 25 (3).



## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı** : Mustafa Hasan Najm Algburi  
**Uyruğu** : IRAQ  
**Doğum Yeri ve Tarihi** : KERKUK 22/06/1993  
**Telefon** : 05399310248  
**Faks** :  
**e-mail** : [mhn\\_m93@yahoo.com](mailto:mhn_m93@yahoo.com)

### EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Omar ibn AL-Khatib Erkek lisesi , Kerkuk	2011
Üniversite	: Kerkuk Teknik Üniversitesi , Kerkuk	2015
Yüksek Lisans :		
Doktora :		

### İŞ DENEYİMLERİ

Yıl	Kurum	Görevi

### UZMANLIK ALANI

### YABANCI DİLLER

### BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

### YAYINLAR

Kaya, E. ve ALGBURI, M. 2018 ,“Heart arrhythmias on mobile application based on DVM(Support Vector Machine) Algorithm”,International Conference on Engineering Technologies (ICENTE’18), Konya/TURKEY.