



**T.C.  
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**YÜKSEK LİSANS TEZİ**

**KALP SESLERİNİN EVRİŞİMSEL SİNİR AĞLARI  
KULLANILARAK SINIFLANDIRILMASI**

**Hatice Esra ALTINIŞIK**

**DANIŞMAN**

**Doç. Dr. Abdurrahim AKGÜNDOĞDU**

**Biyomedikal Mühendisliği Anabilim Dalı**

**Biyomedikal Mühendisliği Programı**

**İSTANBUL-2022**

Bu çalışma, 4.01.2022 tarihinde aşğıdaki jüri tarafından Biyomedikal Mühendisliğı Anabilim Dalı, Biyomedikal Mühendisliğı Programında Yüksek Lisans tezi olarak kabul edilmiştir.

### Tez Jürisi

Doç. Dr. Abdurrahim AKGÜNDÖĐDUI(Danışman)  
İstanbul Üniversitesi-Cerrahpaşa  
Mühendislik Fakültesi

Doç. Dr. Yasin ÖZÇELEP  
İstanbul Üniversitesi-Cerrahpaşa  
Mühendislik Fakültesi

Doç. Dr. Ali AKPEK  
Yıldız Teknik Üniversitesi  
Elektrik Elektronik Fakültesi

Unvan Adı SOYADI  
Üniversite  
Fakülte

Unvan Adı SOYADI  
Üniversite  
Fakülte



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa’nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

## ÖNSÖZ

Akademik bitirme çalışmam boyunca hoşgörüsünü eksik etmeden bilgi ve tecrübesiyle desteklerini esirgemeyen danışmanım Doç. Dr. Abdurrahim AKGÜNDOĞDU'ya müteşekkirim. İlk günden son güne kadar hayatımın her anında yanımda olan kıymetli aileme ve beni her daim destekleyen eşim Enes'e en içten şekilde teşekkür ederim.

Ocak 2022

Hatice Esra ALTINIŞIK



# İÇİNDEKİLER

Sayfa No

|                                                                               |      |
|-------------------------------------------------------------------------------|------|
| ÖNSÖZ.....                                                                    | iv   |
| İÇİNDEKİLER .....                                                             | v    |
| ŞEKİL LİSTESİ.....                                                            | vi   |
| TABLO LİSTESİ.....                                                            | viii |
| SİMGE VE KISALTMA LİSTESİ .....                                               | ix   |
| ÖZET.....                                                                     | x    |
| SUMMARY.....                                                                  | xi   |
| 1. GİRİŞ.....                                                                 | 1    |
| 2. GENEL KISIMLAR .....                                                       | 4    |
| 2.1. KALP SESİ.....                                                           | 4    |
| 2.2. ÖZNİTELİK TABANLI KALP SESLERİNİN SINIFLANDIRILMASI.....                 | 5    |
| 2.3. DERİN ÖĞRENME YAKLAŞIMLARIYLA KALP SESLERİNİN<br>SINIFLANDIRILMASI ..... | 10   |
| 3. MALZEME VE YÖNTEM.....                                                     | 13   |
| 3.1. KULLANILAN VERİ.....                                                     | 13   |
| 3.1.1. Veri Kümeleri.....                                                     | 13   |
| 3.1.2. Veri Formatı.....                                                      | 14   |
| 3.1.3. Veri Kümesindeki Sınıflar .....                                        | 14   |
| 3.2. KULLANILAN TEKNİKLER.....                                                | 16   |
| 3.2.1 Mel-Frekans Kepstral Katsayıları .....                                  | 16   |
| 3.2.2 Evrişimsel Sinir Ağları .....                                           | 17   |
| 3.2.3 Makine Öğrenmesi .....                                                  | 21   |
| 3.3. ÖNERİLEN YÖNTEM.....                                                     | 23   |
| 4. BULGULAR.....                                                              | 28   |
| 5. TARTIŞMA VE SONUÇ .....                                                    | 35   |
| 6. KAYNAKLAR.....                                                             | 37   |
| 7. EKLER .....                                                                | 43   |

## ŞEKİL LİSTESİ

|                                                                                                                                                 | Sayfa No |
|-------------------------------------------------------------------------------------------------------------------------------------------------|----------|
| Şekil 1.1: Mevcut sınıflandırma çalışmalarının şeması. ....                                                                                     | 2        |
| Şekil 2.1: EKG sinyali. ....                                                                                                                    | 4        |
| Şekil 2.2: EKG Derivasyonları. ....                                                                                                             | 5        |
| Şekil 2.3: Ön işleme aşaması şeması. ....                                                                                                       | 6        |
| Şekil 2.4: Sinyal özniteliği şeması. ....                                                                                                       | 9        |
| Şekil 2.5: Yaklaşımın akış diyagramı [33]. ....                                                                                                 | 11       |
| Şekil 3.1: Veri kümesindeki sınıfların hastalıklara dağılımı. ....                                                                              | 15       |
| Şekil 3.2: Hastalıklı ses sinyali örnekleri. ....                                                                                               | 16       |
| Şekil 3.3: MFCC çıkarma yönteminin aşamaları. ....                                                                                              | 16       |
| Şekil 3.4: YSH modeli. ....                                                                                                                     | 18       |
| Şekil 3.5: Sigmoid, tanh, ReLU aktivasyon fonksiyonları. ....                                                                                   | 18       |
| Şekil 3.6: YSA modeli. ....                                                                                                                     | 19       |
| Şekil 3.7: Bir boyutlu evrimsel sinir ağının evrim işlemi. ....                                                                                 | 20       |
| Şekil 3.8: 2 boyutlu CNN yapısı (CNN-2D). ....                                                                                                  | 21       |
| Şekil 3.9: kNN modeli. ....                                                                                                                     | 22       |
| Şekil 3.10: Destek Vektör Makineleri modeli yapısında oluşturulan destek vektörleri<br>ve bu desteklerin ortasında yer alan sınır bölgesi. .... | 22       |
| Şekil 3.11: Karar Ağacı (DT) yapısı örneği. ....                                                                                                | 23       |
| Şekil 3.12: Önerilen yöntemin genel diyagramı. ....                                                                                             | 24       |
| Şekil 3.13: Örnek bir ses dosyasına ait MFCC çıktısının ısı haritası görünümü. ....                                                             | 25       |
| Şekil 3.14: Veri kümesinin modeldeki dağılımı. ....                                                                                             | 26       |
| Şekil 3.15: Model eğitimi şeması. ....                                                                                                          | 27       |

|                                                                                                                                                    |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Şekil 4.1:</b> Veri kümesi eğitim, doğrulama ve test şeklinde üçe bölünmesi sonucu, sınıfların veri kümelerine dağılım grafikleri. ....         | 28 |
| <b>Şekil 4.2:</b> CNN-2D için 12 kaynak için elde edilen kayıp, başarımlar ve karmaşıklık matrisi grafikleri.....                                  | 31 |
| <b>Şekil 4.3:</b> CNN-2D yöntemiyle elde edilen olasılıkların rastgele orman ağacıyla birleştirilmesi sonucu elde edilen karmaşıklık matrisi. .... | 32 |
| <b>Şekil 4.4:</b> CNN-2D yöntemiyle 11 hastalık için elde edilen ROC eğrisi ve AUC sonuçları .....                                                 | 33 |
| <b>Şekil 4.5:</b> CNN-1D için elde edilen örnek başarımlar, kayıp ve karmaşıklık matrisi grafikleri. ....                                          | 33 |
| <b>Şekil 4.6:</b> Yöntemin son halindeki karmaşıklık matrisi.....                                                                                  | 34 |
| <b>Şekil 4.7:</b> Yöntem sonunda 11 hastalık için elde edilen ROC eğrileri ve AUC sonuçları .....                                                  | 34 |
| <b>Şekil 7.1:</b> Python kullanarak önerilen CNN-2D gerçekleştirilmesi. ....                                                                       | 43 |
| <b>Şekil 7.2:</b> Python kullanarak önerilen CNN-1D gerçekleştirilmesi. ....                                                                       | 43 |

## TABLO LİSTESİ

### Sayfa No

|                                                                                             |    |
|---------------------------------------------------------------------------------------------|----|
| <b>Tablo 2.1:</b> Sağlıklı yetişkin bir erkek birey için normal EKG dalga özellikleri [17]. | 8  |
| <b>Tablo 4.1:</b> 12 kaynak için CNN-2D ile elde edilen başarımlar.                         | 32 |
| <b>Tablo 4.2:</b> 12 kaynak CNN-1D için elde edilen başarımlar.                             | 32 |
| <b>Tablo 5.1:</b> Önerilen yöntemin mevcut yöntemlerle karşılaştırılması.                   | 35 |



## SİMGE VE KISALTMA LİSTESİ

| Simgeler | Açıklama |
|----------|----------|
|----------|----------|

|          |                  |
|----------|------------------|
| $\Sigma$ | : Toplam Sembolü |
| $\pi$    | : Pi Sayısı      |
| $e$      | : Euler Sayısı   |

| Kısaltmalar | Açıklama |
|-------------|----------|
|-------------|----------|

|               |                                      |
|---------------|--------------------------------------|
| <b>AKD</b>    | : Ayrık Kosinüs Dönüşümü             |
| <b>AUC</b>    | : Eğri Altında Kalan Alan            |
| <b>AV</b>     | : Atrioventriküler                   |
| <b>CNN</b>    | : Evrişimsel Sinir Ağı               |
| <b>CNN-1D</b> | : Evrişimsel Sinir Ağı-1 Boyutlu     |
| <b>CNN-2D</b> | : Evrişimsel Sinir Ağı-2 Boyutlu     |
| <b>DC</b>     | : Doğru Akım                         |
| <b>DT</b>     | : Karar Ağacı                        |
| <b>SVM</b>    | : Destek Vektör Makinesi             |
| <b>DWT</b>    | : Ayrık Dalgacık Transformü          |
| <b>EKG</b>    | : Elektrokardiyografi                |
| <b>Hz</b>     | : Hertz                              |
| <b>kNN</b>    | : En Yakın Komşuluk                  |
| <b>KVH</b>    | : Kardiyovasküler Hastalık           |
| <b>LDA</b>    | : Doğrusal Diskriminant Analizi      |
| <b>MFCC</b>   | : Mel-frekans Kepstral Katsayıları   |
| <b>mV</b>     | : Mili Volt                          |
| <b>ReLU</b>   | : Doğrutulmuş Lineer Birim           |
| <b>RF</b>     | : Rastgele Orman Ağacı               |
| <b>ROC</b>    | : Alıcı İşletim Karakteristik Eğrisi |
| <b>SA</b>     | : Sinoatriyal Düğüm                  |
| <b>WPD</b>    | : Dalgacık Paket Ayırıştırma         |
| <b>YSA</b>    | : Yapay Sinir Ağları                 |
| <b>YSH</b>    | : Yapay Sinir Hücresi                |

## ÖZET

### KALP SESLERİNİN EVRİŞİMSEL SİNİR AĞLARI KULLANILARAK SINIFLANDIRILMASI

#### YÜKSEK LİSANS TEZİ

Hatice Esra ALTINIŞIK

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Abdurrahim AKGÜNDOĞDU

Kalp seslerini kullanarak hastalık tanısı yapmak hem erken teşhis imkânı sunduğu hem de ciddi miktarda insan gücü tasarrufu ve maddi tasarruf sağladığı için uzun yıllardır üzerinde çalışılan bir problemdir. Bu tez çalışması kapsamında kalp hastası kişilerin 12 derivasyonlu elektrokardiyogram verileri kullanılarak hastalık teşhisinin yapılması hedeflenmiştir. Bu amaçla her bir elektrokardiyogram derivasyonu için bir adet bir boyutlu ve bir adet iki boyutlu olmak üzere iki adet evrişimsel sinir ağı (CNN) tasarlanmıştır. Geliştirilen yöntem 2020 yılında düzenlenen 12 derivasyonlu elektrokardiyogram verilerinin sınıflandırılması yarışması için paylaşılan veri kümesi üzerinde test edilmiştir. Geliştirilen yöntem bu veri kümesindeki en yaygın 11 farklı hastalık için %51,7 başarımla hastalık türünü tespit edebilmektedir. Aynı veri kümesi üzerinde güncel yöntemler ile %49,6 başarımla elde edilebilmektedir. Bu işlem, geliştirilen yöntemin bu veri kümesi için %2,1'lik bir iyileştirme sağladığını göstermektedir. Ayrıca yöntem 11 hastalık için ortalama %86,5 eğri altındaki alan sonucu vermiştir.

Ocak 2022, 54 sayfa.

**Anahtar kelimeler:** CNN, 12 Derivasyon EKG, makine öğrenmesi, derin öğrenme

## **SUMMARY**

### **CLASSIFICATION OF HEART SOUNDS USING CONVOLUTIONAL NEURAL NETWORKS**

#### **M.Sc. THESIS**

**Hatice Esra ALTINIŞIK**

**Istanbul University-Cerrahpasa**

**Institute of Graduate Studies**

**Department of Biomedical Engineering**

**Supervisor: Assoc. Prof. Dr. Abdurrahim AKGÜNDOĞDU**

Diagnosing the disease using heart sounds is a problem that has been studied for many years, as it provides both early diagnosis and significant savings in manpower and money. Within the scope of this study, it was aimed to diagnose the disease using 12-lead electrocardiogram signals of people with heart disease. For this purpose, one one-dimensional and one two-dimensional convolutional neural networks were designed for each electrocardiogram lead. The developed method was tested on the shared dataset for the classification of the 12-lead electrocardiogram challenge in 2020. The proposed approach can detect the disease type with 51,7% accuracy for the 11 most common diseases in this dataset. On the same dataset, 49,6% accuracy can be obtained with using methods in the literature. This process shows that the proposed approach provides a 2,1% improvement for this dataset. Also, in average 86.5% area under curve score is obtained for 11 diseases with proposed approach.

January 2022, 54 pages.

**Keywords:** CNN, 12-lead EKG, machine learning, deep learning


## 1. GİRİŞ

Kalp hastalıkları ölüm oranları yüksek hastalıklardandır. Dünya sağlık örgütünün raporlarına göre, günümüzde tüm ölüm nedenlerinde kardiyovasküler hastalık (KVH) ölümleri ilk sırada yer almaktadır. Tüm ölümlerin yaklaşık yüzde 31'i kalp rahatsızlıklarındandır. Bu ölümlerin yüzde 75'inden fazlası gelişmekte olan ülkelerde meydana gelmiştir. Bu nedenle kalp ritminin düzenli olarak izlenmesi, KVH'leri önlemek için giderek daha önemli ve gerekli bir konu haline gelmiştir. [1]

Kardiyovasküler hastalıklara düzensiz kalp atışları sebep olur. Bu aritmilerin ciddiyetine bağlı olarak ani ölümler meydana gelebilir. Aritmi tanısı esas olarak EKG'ye bağlıdır. Kalp rahatsızlıkları hakkında önemli bilgiler veren Elektrokardiyogram (EKG) sinyali temel olarak kalbin elektriksel aktivitesini göstermektedir. EKG sinyalinin manuel olarak yorumlanması bilgi ve tecrübe istemektedir. Bazen iki farklı hastanın farklı hastalıklar için benzer EKG çıktıları olabilmektedir. Bu nedenle, otomatik EKG analizi sağlayan bilgisayar destekli yöntemlerden yararlanılmalıdır. EKG sinyallerinden düzensiz kalp ritimlerinin otomatik tespiti, kardiyovasküler hastalıkların otomatik teşhisi için önemli bir noktadadır. EKG grafiğinin hızlı ve doğru bir şekilde tanımlanması birçok kişinin hayatını kurtarabilir. Aynı zamanda dünya çapında sağlık maliyetlerini indirgeyebilir.

EKG analizi; ön işleme, özellik çıkarma, özellik dönüştürme ve sınıflandırma gibi birkaç adımı içerebilir. Her bir adımı gerçekleştirmek, ilgili analiz için oldukça önemlidir. Geçmiş çalışmalarda EKG sinyalinin kalp atış hızının ölçülmesi, kalp ritminin incelenmesi, kalp anormalliklerinin teşhisi, duygu tanıma gibi çeşitli amaçlar için analiz edildiği ve kullanıldığı bilinmektedir. Ebrahimi ve diğerlerinin [2] 2020 yılında yayınladıkları hastalıklı ve sağlıklı kalp seslerinin ayırt edilmesine dair bulgulara göre 2017 ve 2018 yıllarında toplam 75 yayın yapılmıştır. Bu yayınların %52'sinde CNN yöntemi kullanılmıştır. Bu yayınlarda farklı yaklaşımlar ile hastalıklı ve sağlıklı kalp seslerinin ayırt edilmesine dair %99,7 üzeri başarımler elde edilmiştir [3]. Bu yüzden son yıllardaki çalışmalar farklı kalp hastalıklarının sınıflandırılması üzerine yoğunlaşmıştır [4]. Bu sebeple bu tez çalışmasında farklı hastalıkların sınıflandırılması üzerinde çalışılmıştır.

Kalp seslerinin sınıflandırılması hakkındaki çalışmalar iki grupta incelenebilir. Şekil 1.1’de görüldüğü üzere bu çalışmalar kalp seslerini bir ön işlemeye tabi tutar. Sinyalin öznitelikleri elde edildikten sonra belli bir makine öğrenmesine verilir sınıflandırma algoritması test edilir. Ya da sinyal derin öğrenme algoritmalarına uygun hale getirilip daha sonra bir derin öğrenme algoritması uygulanarak test edilmesi şeklindedir [5].



**Şekil 1.1:** Mevcut sınıflandırma çalışmalarının şeması.

Mevcut çalışmalarda sinyal özniteliğini elde etmek için sinyalin standart sapması, enerjisi, basıklığı, çarpıklığı gibi istatistiksel yapılarından; sinyal dalga yapılarından ya da alan dönüşümleri gibi yapılardan yararlanılmıştır. Sınıflandırma aşamasında farklı metotlarla makine öğrenmesi ya da derin öğrenme algoritmaları kullanılmıştır.

Bu çalışmada öznitelik çıkarma sürecini ortadan kaldıran uçtan uca bir öğrenme sağlayan derin öğrenme algoritmalarından CNN metodu temel alınmıştır. Daha başarılı bir sonuç elde edilmesi için CNN-1D ve CNN-2D yöntemleri beraber kullanılmıştır. CNN-1D yapısı sinyalin kendi ile doğrudan eğitilirken CNN-2D yapısı için öncelikle MFCC kullanılarak sinyal 2 boyutlu uzaya çevrilmiş ve elde edilen MFCC matrisi kullanılarak CNN-2D yapısı eğitilmiştir. Her bir EKG sinyali için elde edilen CNN çıktıları makine öğrenmesi yaklaşımlarıyla birleştirilmiştir. Bu işlem sonucunda elde edilen yöntem 11 farklı hastalık içeren veri kümesinde test edildiği zaman %51,7 başarımla elde edilmiştir. Referans olarak kullanılan 2020 yılına ait yöntemle aynı veri kümesi için %49,6 başarımla elde edilmiştir. Bu sonuçlar geliştirilen yöntemin, performansı %2,1 iyileştirdiğini göstermektedir. [6]

Bu çalışma kapsamında geliştirilen yöntemin üç önemli yeniliği vardır. Bunlardan ilki CNN-1D ve CNN-2D yaklaşımlarının aynı anda kullanılmasıdır. İkinci önemli özelliği ise CNN-1D ve CNN-2D katmanlarının makine öğrenme algoritması ile birleştirilmesidir. Bu katmanın en

büyük avantajı; bu katman farklı yöntemlerin tezde önerilen yöntemlerle birleştirilmesine olanak sağlamaktadır. Bu sayede çok daha gürbüz yöntemler elde edilebilir. Yöntemin son avantajı mevcut derin öğrenme yaklaşımlarına göre daha hızlı çalışmasıdır. Referans makalede oluşturulan algoritmanın, bu çalışma için düzenlenen veri kümesini çalıştırması 5 gün sürmüştür. Bu çalışmada önerilen yöntemle, aynı veri kümesinin çalışması yaklaşık 2 saatte tamamlanmıştır. Bu durum özellikle gerçek hayat uygulamaları için önemli bir avantaj sağlamaktadır.


Tezin bundan sonraki kısımlarında sırasıyla öncelikle kalp sesinin yapısı, kalp sesinin ölçüm tekniklerinden bahsedilecek ve mevcut çalışmalar özetlenecektir. Bir sonraki kısımda öncelikle kullanılan veri kümesinin özellikleri belirtilecek, tez kapsamında kullanılan yöntemler detaylandırılacak ve önerilen yöntemin detayları sunulacaktır. Bulgular kısmında önerilen yönteme dair sonuçlar paylaşılacaktır. Tez sonuçlarının değerlendirilmesi ve mevcut yöntemlerle kıyaslanmasıyla bitirilecektir.

## 2. GENEL KISIMLAR

### 2.1. KALP SESİ

Elektrokardiyografi Hollandalı bilim insanı Willem Eindhoven tarafından bulunmuştur. EKG sinyali kalp üzerinde gerçekleşen elektriksel değişimlerin bir kayıdır. Vücuda yerleştirilen elektrotlar bu elektriksel aktivitenin bir sinyale dönüşmesini sağlar. Elektriksel aktivite ilk olarak Sinoatriyal düğümün (SA) kasılmasıyla ortaya çıkar. Kalpte oluşan bu implus yüzeyin depolarizasyona neden olur. Yüklerin hareketi de sinyalin temelini oluşturur.


EKG sinyalinde dalgaların ve tepelerin zaman aralıkları, şekilleri ya da genlikleri kalbin sağlıklı olup olmaması hakkında bilgi vermektedir. Sinyaldeki dalgalara P, QRS, T-U şeklindeki isimlendirmeler verilmiştir. P dalgası atriyumların depolarizasyonunu, QRS bileşeni ventriküllerin depolarizasyonunu ifade etmektedir. Şekil 2.1’de örnek EKG sinyali dalga yapısı görülmektedir [7].



Şekil 2.1: EKG sinyali.

Hastaların kalbindeki elektriksel aktivitenin üç boyutlu olarak izlenebilmesi adına 12 derivasyonlu EKG ölçümü yapılmaktadır. Bu derivasyonlar vücutta farklı noktalara yerleştirilen elektrotları temsil etmektedir. Bu derivasyonlar ekstremite derivasyonları ve göğüs derivasyonları olmak üzere iki grupta ele alınır.

Ekstremit  derivasyonları DI:sol kol ve saę kol arasında, DII: sol bacak ve saę kol arasında, DIII:sol bacak ve sol kol arasında; aVR:saę kol, aVL:sol kol, aVF:sol bacak  eklindedir. G ę s derivasyonları V1-V6  eklindedir. Bu  alıřmada 12 derivasyonlu EKG verilerinden yararlanılmıřtır [8].  ekil 2.2’de EKG derivasyonları g r lmektedir [9].



 ekil 2.2: EKG Derivasyonları.

## 2.2.  ZNİTELİK TABANLI KALP SESLERİNİN SINIFLANDIRILMASI


EKG sinyallerinin sınıflandırılması i in  ncelikle elde edilen ses sinyalleri d zenlenmeli, d zenlenen verilerden  znitelikler  ıkartılmalı ve bu  znitelikler sınıflandırıcılar vasıtası ile sınıflandırılmalıdır. Bu ama la kullanılan yapının ařamaları řunlardır: Filtreleme, yeniden  rnekleme, normalleřtirme,  znitelik  ıkartma ve sınıflandırmanın tasarlanmasıdır.  ekil 2.3’te  n iřleme ařamasının řeması g r lmektedir. Bu řemanın ilk kısmı hangi iřlemin uygulandıęını g stermektedir. Daha sonra her bir adım i in yaygın olarak kullanılan y ntemler tanımlanmıřtır. Son kutularda ise bu y ntem veya adımın genellikle hangi ama  doęrultusunda uygulandıęını g stermektedir.

**Filtreleme:** EKG sinyallerini analiz etmek i in  ncelikle belli frekanslar filtrelenir. Sinyallerdeki g r lt ler    ana  eřitte filtrelenmektedir. İlk grup genellikle kas g r lt lerinden oluřmaktadır ve bu g r lt  bileřenlerini ayıklamak i in bant ge iren filtreler yaygın olarak kullanılır. Bant ge iren filtreleme i in en sık 0,1–100 Hz frekans aralıęı kullanılmaktadır. İkinci t r g r lt ler elektrik hattının girişimden kaynaklı y ksek frekanslı

sinyallerdir. Başarılı bir alçak geçiren filtre verilerin çoğunluğunu kaybetmeden bu gürültüyü filtreleyebilmelidir. Bunların aksine, vücut ile elektrotun bağlantısından kaynaklı DC ofsetin ortadan kaldırılması için yüksek geçirgen filtreler de kullanılmıştır. Bu yöntemin en büyük problemi analog yüksek geçirgen filtrelerde, sinyalin ilk 5-10 harmonilerini etkileyen faz kaymalarına neden olmasıdır [10].

Bu filtreler haricinde çentik filtresi [11] bir diğer yaygın kullanılan filtreleme yöntemidir. Çentik filtresi diğer adıyla bant durduran filtre temel olarak bir yüksek geçiren ve bir düşük geçiren filtrenin birleştirilmesiyle belli bir bant alanının durdurulmasını hedefler. Bu filtre genellikle elektrik hatlarından kaynaklı gürültüleri durdurmak için kullanıldığından elektrik hatlarının genel frekansı olan 50 Hz ve 60 Hz frekansları için kullanılır. Bu sayede bu frekansların etkisi EKG sinyalinden kaldırılmış olur.

Bir diğer yaygın filtreleme işlemi medyan filtresidir [12]. Bu amaçla tasarlanan medyan filtrelerde genellikle 200 ve 600 milisaniyelik zaman aralıkları için sinyalden medyan değeri kaldırılır. Genellikle ikinci dereceden ve beşinci dereceden medyan filtreler kullanılmaktadır. Bu filtrenin iki avantajı vardır. İlki sinyal içindeki rastgele gürültüleri yok etmesidir. İkinci avantajı ise sistem üzerindeki temel sinyali azaltarak P dalgalarının polarizasyonun karar verilmesini kolaylaştırmaktadır. Sinyallerdeki dış gürültüler dışında filtrenmesi gereken bir başka nokta da sinyalin kendisinden kaynaklanan gürültülerdir. Bu amaçla Savitsky-Golay filtrelemesi veya dijital yumuşatma polinom filtrelemesi EKG sinyallerini yumuşatmak için kullanılmıştır [13]. Şekil 2.3'te sinyal ön işleme aşamasının örneklerini içeren bir şema görülmektedir.



**Şekil 2.3:** Ön işleme aşaması şeması.

**Yeniden Örnekleme:** Büyük veri setlerinde hesaplama maliyeti bir problem oluşturmaktadır. Bu problemi çözmek için yeniden örneklendirme literatürde yaygın bir işlemdir. Bu amaçla Ayırık Dalgacık Transformu (DWT) en yaygın kullanılan yaklaşımlardan biridir [14]. Yeniden öğrenmenin yaygın kullanılan bir diğer alan ise veri kümesindeki örneklem sayısının yeniden örneklenmesidir. Bu yöntem özellikle veri kümesinin dengesiz dağılıma sahip olduğu durumlarda kullanılmaktadır. Bunun nedeni birçok yöntem başarımı en yüksek seviye çıkarmak için tasarlanmıştır. Denklem 2.1’de başarımın formülü görülmektedir. Bu denklemdeki doğru pozitif ve doğru negatif ifadesi ikili sınıflandırma problemleri için kullanılmaktadır. Bu ifadelerden doğru pozitif ifadesi hastalıklı kalp seslerinin ne kadarının doğru şekilde tespit edildiğini gösterirken, doğru negatif ifadesi sağlıklı kişilerin ne kadarının sağlıklı olarak tespit edildiğini belirtmektedir. Bu denklemdeki doğru pozitif ve doğru negatif ifadeleri birden çok sınıf içeren sınıflandırma problemleri için sınıfı doğru tespit edilen örneklemelerin sayısı olarak hesaplanabilir.

$$\frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Tüm Veri Kümesi}} \quad (2.1)$$

Denklem 2.1’de de görülebileceği üzere başarımlar her bir sınıf için ayrı ayrı hesaplanmamaktadır. Verinin tamamı için bir başarımlar hesaplanmaktadır. Bu durumda eğer verinin dağılımında dengesizlik mevcut ise bu dengesizlik, dengesizliğin baskın olduğu sınıfın aleyhine olacak şekilde bir hataya yol açacaktır. Örneğin veri kümesinin %90’ı aynı sınıfa ait verilerden oluşuyor ise, sınıflandırıcı her durumda bu sınıfı seçerek %90 başarımlar elde edecektir. Bu sorunu çözmek için iki farklı yöntem yaygın olarak kullanılmaktadır. Bunlardan ilki eğitim ve test aşamasının her ikisinde de başarımlar sınıfların dağılımıyla ters orantılı olarak hesaplamaktır. Ağırlıklandırma yöntemi olarak adlandırılan bu yöntem sayesinde veri kümesi dengesiz dağılım içerse bile ölçüm metriği düzeltildiği için hata oluşmamaktadır. İkinci olarak kullanılan yöntem ise veri kümesinin örneklenmesidir. Bu işlem iki şekilde gerçekleştirilebilir. Bunlardan ilki az örnek içeren sınıfın elemanlarının tekrarlama gibi teknikler kullanılarak çoğaltılmasıdır. İkinci yaygın kullanılan yöntem ise daha çok örnek içeren sınıfın rastgele olarak azaltılmasıdır. Bu yöntemin bir avantajı veri kümesi küçüldüğü için çalışma zamanı azalmaktadır; fakat örneklem kümesi azaldığı için modelin eğitim başarısı da azalmaktadır.

**Normalleştirme:** Genlik normalizasyonu ön işleme aşamasında kullanılan adımlardan biridir [15]. Farklı hastalardan gelen sinyalleri görsel olarak karşılaştırmaya yardımcı olan bu adım isteğe bağlı olarak tercih edilmektedir [16]. Bu işlem genel olarak şu şekilde uygulanır. Normalleştirme işlemi genel olarak öncelikle sinyalden ortalama değerin çıkartılıp daha sonra sinyalin maksimum değeri 1 minimum değeri -1 olacak şekilde oranlanması ile elde edilir; fakat bu noktada farklı yaklaşımlar kullanılabilmektedir.

**Öznitelik Çıkarma:** Elektrokardiyografi analizinde sinyallerden ayırt edici bilgileri ortaya koyabilmek için farklı öznitelik çıkarma metotları kullanılmıştır. Bu metotlar ayrı ayrı ya da birlikte de kullanılabilmektedir.


**Tablo 2.1:** Sağlıklı yetişkin bir erkek birey için normal EKG dalga özellikleri [17].

| Öznitelik      | Normal Değer   | Limit Değer         |
|----------------|----------------|---------------------|
| P genişliği    | 110 milisaniye | $\pm 20$ milisaniye |
| PR aralığı     | 160 milisaniye | $\pm 40$ milisaniye |
| QRS genişliği  | 100 milisaniye | $\pm 20$ milisaniye |
| Q-Tc aralığı   | 400 milisaniye | $\pm 40$ milisaniye |
| P genliği      | 0,15 milivolt  | $\pm 0,05$ milivolt |
| QRS yüksekliği | 1,5 milivolt   | $\pm 0,5$ milivolt  |
| S-T seviyesi   | 0 milivolt     | $\pm 0,01$ milivolt |
| T genliği      | 0,3 milivolt   | $\pm 0,2$ milivolt  |

Sağlıklı bir elektrokardiyografi sinyalinde birtakım dalga yapıları bulunmaktadır. EKG sinyalinde bulunan P-QRS-T dalga yapıları sinyal içerisinde konum, sapma ya da süre ifade etmektedir [17]. Sağlıklı, yetişkin bir erkek birey için normal bir EKG sinyali dalga yapılarının özellikleri Tablo 2.1’de görülmektedir. Bu yapı öznitelik çıkarmak için güçlü bir özellik bir olarak değerlendirilmiştir. P-QRS-T dalga yapılarının özniteliklerinin çıkarılması tabloda belirtilen değerlerin analizini gerektirdiğinden farklı algoritmalar önerilmiştir. Fazör dönüşümü [18], sinir ağları [19], dalgacık dönüşümü [20], dijital filtreler [21] tabanlı algoritmalar bunlardan bazılarıdır. Yaygın olarak kullanılan bir diğer algoritma Pan-Tompkins algoritmasıdır [22].

EKG sinyallerinin zaman eksenindeki değerleri kullanılarak istatistiksel özellikleri analiz edilebilmektedir. Öznitelik çıkarmada standart sapma, enerji, ortalama, basıklık, çarpıklık gibi istatistiksel niteliklerden yararlanılır. [23]. Kullanılan yaygın öznitelikler dalgacık paket

ayırıştırma (WPD) katsayılarından elde edilen entropi yaklaşımı dalgacık katsayıları ile sinyallerden elde edilen doğrusal ve doğrusal olmayan özellikleridir [24]. Şekil 2.4'te sinyal özneliği şeması görülmektedir.



Şekil 2.4: Sinyal özneliği şeması.

**Sınıflandırma:** Literatürde EKG analizi ve sınıflandırma görevleri için kullanılan çeşitli sınıflandırıcılar bulunmaktadır. Bu amaçla kullanılan yöntemlerden ilki en yakın komşuluk algoritmasıdır. (kNN). Bu algoritma eğitim kümesindeki öznelik vektörlerinin uzayda birbirlerine olan Öklid uzaklıklarına göre komşuluk ilişkilerini tanımlar. Öklid uzaklığı temel olarak iki vektörün uzaydaki birbirlerine olan doğru uzaklıklarını temsil etmektedir. Bu işlem iki vektörün tüm elemanlarının farkların kareleri toplamının karekökü olarak tanımlanır. Ayrıca bu aşamada farklı uzaklık formülleri kullanılabilir. Bir diğer yaygın kullanılan Manhattan uzaklığında ise iki vektörün tüm elemanlarının farkının toplamı alınır. Daha sonra test kümesindeki her elemanı, en yakın k komşusunun çoğunluğunun ait olduğu sınıfı etiketler. Burada yaygın kullanılan k değeri 1, 3 ve 5 değerleridir. Bu sayının tek seçilmesinin bir avantajı ikili sınıflandırmada sınıflardan birinin daha çok ön plana çıkmasını sağlamaktır. Bu yöntem farklı öznelikler ile farklı çalışmalarda kullanılmıştır [25].

Diğer bir yaygın sınıflandırma yöntemi ise destek vektör makinesi (SVM) yaklaşımıdır. SVM yöntemi eğitim setindeki verilerin dağılımına bakarak uzayı her sınıf için bölgelere böler. Bu bölme işleminde kNN vb. yaklaşımlardan farklı olarak öncelikle bölgeler arası sınırları bulur daha sonra bu sınırların orta noktasını iki sınıf arasındaki sınır olarak belirler. Bu yaklaşım literatürdeki birçok yayında kullanılmıştır [26].

Bir diğer sınıflandırma yöntemi Karar Ağacı (DT) yaklaşımıdır. Bu amaçla özniteliklere bakarak her adımda bir bölgeye doğru harekete edilir. Her hareket eden sonra belli olasılıkla bir karar verilmiş olur. Bu şekilde öznitelikler bitinceye veya doğru sınıf bulununcaya kadar devam edilir. DT, bazı EKG sınıflandırma çalışmalarında kullanılmıştır [27]. Bu yaklaşım da tek bir ağaç oluşturmak yerine çok sayıda ağaç oluşturulursa bu yöntem Rastgele Orman Ağacı (RF) olarak adlandırılır. Bu yöntemin avantajı sadece bir karar yerine birçok DT tarafından verilen kararların çoğunluğuna uyulduğu için daha başarılıdır [28].


Bu yaklaşımlara göre daha modern bir yaklaşıma sahip olan Doğrusal Diskriminant Analizi (LDA) son zamanlarda EKG sınıflandırma problemi için de yaygın olarak kullanılmıştır [29]. Bu yaklaşımın özü sınıflar arası varyansın sınıf içi varansa oranını en yüksek seviyede tutarak ve farklı sınıflar arasında mümkün olan en yüksek ayrımı sağlamaktır. Bir diğer yaygın kullanılan modern yöntem ise derin öğrenme yaklaşımının temelinde yer alan ve öznitelik sınıflandırmak için kullanılan Yapay Sinir Ağları (YSA) yaklaşımıdır. YSA biyolojik sinir ağlarında bulunan nöronların esinlenen matematiksel bir modeldir. Bu nöronlar çok farklı sayıda ve katmanda olabilir. Bu yöntemlerin detayları yöntem kısmında detaylı anlatılacaktır.

### **2.3. DERİN ÖĞRENME YAKLAŞIMLARIYLA KALP SESLERİNİN SINIFLANDIRILMASI**

Son yıllarda, derin öğrenme teknikleri, örüntü tanıma uygulamalarında üstün performanslarını göstermiştir. Bu nedenle araştırmacılar ve mühendisler, dikkatlerini derin öğrenme ile ilgili tekniklere dayalı EKG sınıflandırma çalışmalarına kaydırmışlardır. Yukarıda bahsedilen çalışmalar, genellikle bir öznitelik çıkarma süreci gerektirmektedir. Bu sürecin olumsuz özelliği sistem başarımının öznitelik çıkarma sürecine çok bağlı olmasıdır. Bu problemi çözmek için derin öğrenme yaklaşımları kullanılmaktadır [30]. Derin öğrenme yaklaşımlarının problemi çok fazla veriye ihtiyaç duymalarıdır; fakat derin öğrenme yaklaşımları öznitelik çıkarma sürecini ortadan kaldırarak uçtan uca bir öğrenme sağlamaktadır. Bu amaçla kullanılan ilk yaklaşımlardan biri tekrarlayan sinir ağları yaklaşımıdır. Bu yaklaşımın normal YSA'na göre avantajı insan beynine benzer şekilde bir geri besleme yapısının olmasıdır.

Derin öğrenme tekniklerinin en etkililerinden olan ve resimlerin sınıflandırılması konusunda çok büyük başarı elde eden evrimsel sinir ağları (CNN) yaklaşımı yaygın kullanılmaktadır.

2017-2018 yılları arasından kalp seslerinden hastalık tanımlanması problemi üzerine yapılan 75 uluslararası yayının %52'sinde bu CNN yaklaşımları kullanılmıştır [2]. Bu amaçla ilk önerilen yöntemlerde bir boyutlu CNN (CNN-1D) kullanılmaktaydı [31]. Bu yaklaşımlarda CNN-1D ses verisini girdi olarak bir sinyal matrisi cinsinden işlemektedir. Daha sonra araştırmacılar iki boyutlu CNN (CNN-2D) kullanarak daha yüksek başarılar elde etmiştir [32]. Beş farklı kalp ritmi bozukluğu için iki boyutlu konvolüsyonel sinir ağını (CNN) kullanmışlardır [33]. Bunun için öncelikle EKG sinyalini iki boyutlu zaman-frekans spektrogramlarına dönüştürmüşler ve elde edilen görüntüler CNN-2D modeline verilmiştir. Bu amaç ile uygulanan adımın ilki kalp sesi dalgalarının bölütlenmesidir. Bölütleme işlemi sinyalin 10 saniyelik parçalara getirilmesi ile yapılmıştır. Daha sonra sinyalin spektrumu hesaplanırken 256x256 bir matris elde edilmiştir. Bu işlem sonucu elde edilen ısı haritalarına öncelikle CNN-2D işlemi uygulanmış ve evrisim çıktıları 3 katman içeren YSA ile sınıflandırılmıştır. 4 farklı hastalık ve sağlam kalp seslerinden oluşan sınıfların her biri için 450 örnek eğitim ve 90 örnek test için kullanılmıştır. Bu işlem sonucunda %99 başarımlar elde edilmiştir. Yöntemin genel akış diyagramı Şekil 2.5'te görülmektedir. CNN ile geliştirilen bu yöntemler genel olarak güncel CNN mimarileri ve bu mimarilerin tasarımları kullanılarak daha iyi sonuçlar almayı hedeflemektedir. CNN yaklaşımlarından önce ön işleme adımlarının uygulanması CNN başarımlarını arttırabilmektedir.



**Şekil 2.5:** Yaklaşımın akış diyagramı [33].

Yakın zamanda hastalıkların sınıflandırılması amacı ile geliştirilen yöntemlerde daha güncel yaklaşımlar kullanılmıştır. Bunlardan yaygın kullanılanı Artık Ağlar (ResNet) yaklaşımıdır

[34]. ResNet yaklaşımı amacı YSA’larda katman artıkça oluşan aşırı uyum problemlerini çözmektir. Bu amaç katmanlar arasında kısa yol bağlantıları eklenerek sistemin daha gürbüz olması sağlanır. Yaygın kullanılan ResNet yaklaşımı 50 katmandan oluşan ResNet50 yapısıdır. ResNet tabanlı yaklaşımlardan ilki [35] bir boyutlu sinyale ResNet yaklaşımı uygulanmakta ve elde edilen çıktılar dikkat mekanizması kullanarak birleştirmektedir. Bu aşamada öncelikle ResNet yapısı 3 adet CNN-1D kullanılarak tasarlanmıştır. Bu noktada artık ağ için ilk katman ve üçüncü katman birleştirilmiştir. Elde edilen ResNet yapısı toplamda 5 defa tekrar edilmiştir. Sonuç olarak elde edilen çıktılar geri beslemeli yapay sinir ağları kullanarak sınıflandırılmıştır. Bu yöntemde ayrıca yazarlar sinyallerin üzerine voltaj normalleştirme işlemi de uygulamıştır. Bu işlem başarımlarını %10 civarı arttırmıştır.

Bir diğer yaklaşımda [6], yazarlar bir boyutlu ResNet sonucunu YSA kullanarak birleştirmiştir. Yazarlar bu işlem için her biri iki adet evrişim katmanı içeren beş adet ResNet yapısı kullanmışlardır. Yazarların kullandığı en önemli özelliklerden biri modelin yedi farklı şekilde eğitmeleridir. Bu sayede modelin rastgele başlangıçtan dolayı bir noktada sabit kalmasından kaynaklanabilecek sorunları çözmüşlerdir. Yedi model sonucu elde edilen sonuçları YSA yardımıyla birleştirmişlerdir. Benzer şekilde [36] metodu ResNet kullanarak kalp seslerini sınıflandırmayı denemiştir. Bir diğer yaklaşımda da [37] yazarlar CNN dikkat mekanizması kullanmışlardır. Son yaklaşımların en önemli farkları bu yöntemler kalp seslerinden hastalık sınıflandırılması için tasarlanmış olmalarıdır. 2020 öncesi yayınlarda yaygın olarak hastalıklı ve sağlıklı kalp seslerinin ayırt edilmesi problemi üzerine odaklanılırken, elde edilen yüksek başarımlarla öncelikle problem tanımı yaygın kalp hastalıklarının tanısının konması problemine evrilmiştir. 2020 yılına gelindiğinde bu problem için elde edilen %99 üzeri başarımdan dolayı yeni yayınlarda [6,35,36] çok sınıflı sınıflandırma problemi olan farklı hastalıklarının ayırt edilmesi problemi üzerine odaklanılmıştır.

### 3. MALZEME VE YÖNTEM

Bu başlık altında öncelikle tez kapsamında kullanılan veri kümesinin içeriğinden, formatından ve veri kümesindeki hastalık türlerinin dağılımından bahsedilecektir. Bir sonraki aşamada öncelikle geliştirilen yöntemde kullanılan temel teknikler detaylandırılacaktır. Son aşamada ise önerilen yöntemin detayları aktarılacaktır.

#### 3.1. KULLANILAN VERİ

Birçok makine öğrenmesi yöntemi için en önemli problemlerden biri veri kümesi oluşturmaktır. Kalp seslerinin sınıflandırılması problemi için 2020 yılında PhysioNet tarafından bir yarışma düzenlenmiştir. Bu yarışma kapsamında 5 veri seti kullanılmıştır. Çalışmada aşağıdaki veri kümelerinden yararlanılmıştır.

- CPSC Veri Kümesi ve CPSC-Ekstra Veri Kümesi
- İNCART Veri Kümesi
- PTB ve PTB-XL Veri Kümesi
- The Georgia 12-lead ECG Challenge (G12EC) Veri Kümesi
- Kapalı Veri Kümesi

##### 3.1.1. Veri Kümeleri

**CPSC Veri Kümesi ve CPSC-Ekstra Veri Kümesi:** İlk veri seti 2018 yılında düzenlenen 7.Uluslararası Biyomedikal Mühendisliği ve Biyoteknoloji Konferansı Nanjing kapsamındaki Çin Fizyolojik Sinyal Yarışması'nda (China Physiological Signal Challenge) (CPSC) kullanılan CPSC veri kümesi ve bu yarışma için oluşturulan fakat kullanılmayan CPSC-Ekstra veri setlerini içermektedir. Test veri kümesi, geliştirilen yöntemlerin başarımının ölçülebilmesi için kurul tarafından paylaşılmıştır. Paylaşılan eğitim veri seti iki kısımdan oluşmaktadır. İlk kısmı 3.699 erkek ve 3.178 kadın olmak üzere 6.877 kişiden, ikinci kısım ise 1.834 erkek ve 1.610 kadın olmak üzere 3.453 kişiden toplanmıştır. 12 derivasyonlu EKG kayıtlarının uzunluğu 6 ile 60 saniye arasında olup 500 Hz ile örneklenmiştir.

**İNCART Veri Kümesi:** İkinci veri seti herkese açık olan İNCART (St. Petersburg INCART 12-lead Arrhythmia) veri setidir. Bu veri 32 holter ile kaydedilmiş 74 tane 12 derivasyonlu

EKG verisi içermektedir. Bu veri kümesi diğer kümelerden farklı olarak 30 dakika ile daha uzun veri içermektedir ve 257 Hz ile örneklenmiştir.

**PTB ve PTB-XL Veri Kümesi:** PTB (Physikalisch Technische Bundesanstalt) çok büyük iki tane veri kümesi yayınlamıştır. Bunlardan ilki PTB EKG veri seti 377 erkek ve 139 kadından elde edilen ve 100 Hz ile örneklenmiş 516 kayıt içermektedir. İkincisi PTB-XL veri kümesi 11.379 erkek ve 10.458 kadından elde edilen toplam 21.837 tane 10 saniyelik 500 Hz ile örneklenmiş klinik kaydı içermektedir.

**G12EC Veri Kümesi:** Georgia tarafından yayımlanan bu veri seti Amerika Birleşik Devletleri'nin Southeastern eyaletindeki 5.551 erkek ve 4.793 kadına ait 10.344 kayıt içermektedir. Bu kayıtların her biri 10 saniye uzunluğundadır ve 500 Hz ile örneklenmiştir.

**Kapalı Veri Kümesi:** Sonuncu veri kümesi G12EC veri kümesinden 10 bin tane paylaşılmayan veri içermektedir. PhysioNet yarışması kapsamında bu veriler test amaçlı kullanıldığı için paylaşılmamıştır. Bu nedenle bu veri kümesine ulaşamamıştır.


### 3.1.2. Veri Formatı

Veri dosyaları WFDB formatındadır. Her bir EKG kaydında sinyalleri içeren MATLAB v4 dosyası ve hastalık teşhisi ile hastanın yaş ve cinsiyet özelliklerini açıklayan metin dosyası bulunur. Bu dosyalar okunabilmektedir [38]. EKG kayıtlarının her biri 12 derivasyonlu olup 500 Hz frekansındadır. Sinyaller 16 bit, genliği 1000 mV dur. Sayısallaştırmak için analogdan dijitale dönüştürülmüştür.

### 3.1.3. Veri Kümesindeki Sınıflar

Veri kümesindeki her EKG kaydı farklı kalp hastalığı türü veya da türlerini içermektedir. Tüm hastalık listesine [39] üzerinden ulaşılabilir. Şekil 3.1'de veri setindeki sınıfların dağılımı görünmektedir. Veri kümesinde toplam 99 farklı sınıfa ait veri bulunmaktadır. Şekil 3.1'den de anlaşılacağı üzere veri kümesi dengesiz bir dağılıma sahiptir. Dengesiz dağılıma sahip veri kümeleri üzerinde çalışırken uygulanacak çok sayıda yöntem vardır. Bunlardan ilki model eğitimi sırasında sınıfları, eğitim kümesindeki frekanslarına göre ağırlıklandırmaktır. Bu yöntemin dezavantajı veri kümesindeki tüm elemanlar aynı ağırlığa sahip olmasına karşın, bazı sınıflardan az örnek olduğu için model bu sınıfları gerektiği kadar öğrenmektedir. Ayrıca





Şekil 3.2: Hastalıklı ses sinyali örnekleri

### 3.2. KULLANILAN TEKNİKLER

Tez kapsamında geliştirilen tekniklerin detaylarına girmeden kullanılacak yöntemler detaylandırılacak olursa, tez kapsamında kullanılan temel yöntemler mel-frequency cepstrum (MFCC), CNN-1D, CNN-2D ve RF yöntemleridir. Bu kısımda öncelikle bu yöntemler detaylandırılacaktır sonra da önerilen yöntem tanımlanacaktır.

#### 3.2.1 Mel-Frekans Kepstral Katsayıları

İnsan kulağının ses frekanslarını algılayış şekli ile bilgisayarların ses frekanslarını algılayış şekli birbirinden farklıdır. Bu problemi ele almak için yaygın kullanılan bir yöntem mel-frekans kepsral katsayıları (MFCC) yöntemidir. Bu yöntem ile öncelikle ses dalgası küçük parçalara bölünür ve her bir küçük ses parçacığı için ses sinyalinin gücü hesaplanır. Genel diyagram Şekil 3.3'te görülebilir.



Şekil 3.3: MFCC çıkarma yönteminin aşamaları.

Bu diyagram  $X[n]$  sisteme girdi olarak verilen sinyali temsil etmektedir. Girdi sinyali daha sonra küçük parçalara bölünür. Buradaki amaç tüm sinyali bir bütün olarak ele almak yerine

sinyalin her bir küçük bölgesine ait detayları yakalamaktır. Bu amaçla kullanılan pencerenin boyutu sinyalin niteliklerine göre değişmektedir. Bu noktada önemli bir nokta çerçevelerin birbiriyle örtüşmesidir. Bu işlemin amacı küçük parçaların arasındaki etkileşimin kaybolmamasıdır. Bu noktada kullanılan örtüşme oranı genellikle %35 ile %70 arasındadır.

Sinyali çerçevelere bölmek sinyalin sürekliliğini bozduğu için spektrumunda bozulmalara neden olacaktır. Bu sorunu çözmek için sinyalin üzerine sinyalin uç noktalarının etkisini azaltan pencereleme yöntemi uygulanır. Hanning, Hamming, Gauss, Blackman, gibi filtreler yaygın kullanılan filtrelerdir.


Bir sonraki adım sinyal işlemenin temel fonksiyonlarından biri olan Hızlı Fourier Dönüşümü (FFT) işlemidir. Bu işlem ile zaman alanındaki sinyal frekans alanına döndürülür. Genel FFT formülü Denklem 3.1’de görülmektedir.

$$X[k] = \sum_{n=0}^{N-1} x_n \cdot e^{-2\pi jkn/N}, k = 0,1,2, \dots, N-1 \quad (3.1)$$

Bu denklemde  $X[k]$ ,  $k$ . frekansa denk gelen katsayıyı belirtmektedir. Zaman alanındaki sinyalin uzunluğunu belirtmektedir. Bu işlem ile zaman alanındaki sinyal frekans alanına çevrilmiş olur. Bu işlemin bir avantajı da sinyal uzunluğundan bağımsız olarak katsayı sayısı belirlenebilir. Bir sonraki işlem çıkış sinyaline süzgeç dizisi uygulamaktır [40]. Bu işlem temel olarak merkez frekansı mel ölçeğinde olacak şekilde sinyale üçgen süzgeç dizilerinin uygulanmasıdır. Son adım olarak frekans alanına çevrilen sinyal tekrardan zaman alanına çevrilir. Bu amaçla en çok kullanılan işlem Ayırık Kosinüs Dönüşümü dır. (AKD). Bu işlem sonucunda MFCC değerleri elde edilmiş olur.


### 3.2.2 Evrimsel Sinir Ağları

Evrimsel sinir ağlarını tanımlamadan önce yapay sinir ağları (YSA) tanımlamak konunun anlaşılması için gereklidir. YSA çok sayıda yapay sinir hücresinin (YSH) birleşmesiyle oluşmaktadır [41]. Her bir YSH farklı kaynaklardan, ki bu kaynak bir başka YSH’de olabilir sisteme verilen bir girdi ya da belli bir işlem sonucu oluşan başka girdiler de olabilir, aldığı girdi elemanlarını; farklı oranlarla ağırlandırarak toplar. Şekil 3.4’te genel bir YSH modeli görülmektedir [42].




**Şekil 3.4:** YSH modeli.

Bu yapının önemli faydası her bir YSH'nin çıktının bir parçasından sorumlu olmasıdır. Ağırlık fonksiyonunu kullanarak, her hücre kendisi için en çok katkısı olan girdileri belirler. Bu sayede geleneksel makine öğrenmesi tekniklerinde gerekli olan öznetelik çıkarma işlemi bu hücreler tarafından yapılmış olur. YSH'nin bir sonraki adımı her girdinin ağırlıklı toplamının  $[-1,1]$  aralığına indirgenmesidir. Bu işlemin iki avantajı vardır. İki yapay sinir ağları girdi olarak  $[-1,1]$  arasında işlem yapmaya duyarlıdır ve genelde bir YSH'nin çıktısı başka bir YSH'ye girdi oluşturduğu için kullanışlıdır. İkinci amacı ise YSH'nin çıktıları çok yüksek değerlere ulaşabilir, özellikle uç uca eklenmiş çok sayıda YSH için bu çok olasıdır. Bu amaçla çıktıların belli bir bölgeye limitlenmesi önemlidir [43]. Bu amaçla kullanılan en yaygın 3 aktivasyon fonksiyonu Şekil 3.5'te görülmektedir. Şekilden de görülebildiği üzere 3 fonksiyon da sıfıra yakın değerler için çok fazla değişim gösterirken uç değerler için daha birbirine yakın değerler almaktadır. Bu fonksiyonlardan Sigmoid ve tanh fonksiyonları incelendiği zaman, bu fonksiyonların girdi değerini  $[0,1]$  bölgesine çevirdiği görülmektedir. Bunların aksine ReLU fonksiyonu negatif girdi değerleri için sıfır verirken, pozitif girdiler için çıktı girdiye eşit olmaktadır.



**Şekil 3.5:** Sigmoid, tanh, ReLU aktivasyon fonksiyonları.

Bu yapı sonucunda elde edilenler tek başlarına iken çok bir anlam ifade etmezler. Bu yapıların anlamlı hale gelmesi için YSH'lerin birbirine paralel bağlanması gerekir. Böylece YSA katmanları oluşturulur. Bu katmanların seri bağlanması sonucu ise YSA ağı oluşmuş olur. Şekil 3.6'da geleneksel bir YSA görünmektedir. Giriş katmanında bulunan YSH'leri gizli katmandaki YSH'leri besler. Girdiler çok sayıda YSH'den geçtikten sonra çıkış katmanına ulaşır. Genellikle tasarlanan modeller son katmanda mevcut sınıf sayısı kadar YSH kullanır ve her bir YSH bir sınıfı temsil eder.




**Şekil 3.6:** YSA modeli.

YSA'lar uzunca süre araştırmacılar tarafından kullanılsa da pratik etkileri görülemedi. Bunun en önemli nedenlerinden biri gerektirdikleri işlem gücüdür. Bilgisayarlardaki işlem gücünün artması ve ekran kartların paralelleştirme özelliklerinin kullanılmasıyla birlikte, insanların YSA'lara olan ilgisi artmıştır. 2012 yılında Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet) yarışmasında evrimsel sinir ağları (CNN) tabanlı yaklaşım sunulmuştur ve bu yaklaşım mevcut tüm sistemlere göre çok büyük başarı göstermiştir [44]. Böyle bir sistem için öncelikle girdi boyutu küçültülmelidir; çünkü örneğin elimizde 1 milyon piksel (1 Megapiksel) içeren, 1000x1000 boyutlarında bir resim olduğunu düşünelim. 1 milyon tane piksel ile 500 YSH içeren bir katmanı gitmek istersek 500 x 1 milyondan, 500 milyon ağırlık parametresinin hesaplanması gerekecektir. Özellikle bu işlem ileri adımlara taşınırsa oluşacak parametre uzayı çok büyük olacaktır. Bu problemi çözebilmek için resmin özelliklerini koruyarak girdi yüzeyi azaltılmalıdır. Bu amaçla kullanılan en etkili yöntemler


resmin belli bir büyüklükteki matris ile evrişiminin hesaplanması ve havuzlanmasıdır. Bu yöntem CNN'nin temelini oluşturmaktadır. Girdi matrisinin bir boyutlu ve iki boyutlu olmasına göre bu yöntem bir boyutlu CNN (CNN-1D) ve iki boyutlu CNN (CNN-2D) olarak tanımlanır. Bir boyutlu ve iki boyutlu CNN'leri temelde aynı yaklaşıma sahiplerdir. İki yöntem arasındaki farklılık boyut farkından kaynaklı olarak farklı evrişim işlemlerinin uygulanmasıdır.

Bir boyutlu CNN yaklaşımı temel evrişim yöntemine dayanmaktadır. Elimizdeki girdi sinyali için bir filtre tasarlanır. Bu filtre geliştirilen yöntemde göre farklı uzunlukta bir dizidir. Daha sonra dizinin her bir elemanı girdi dizisiyle çarpılır ve tüm çarpılan bölge bir nokta ile temsil edilir. Bu işlem tüm girdi dizini bitinceye kadar tekrar edilir. Genelde her adımda filtre bir birim kaydırılarak dizi üzerinden geçirilir. Daha sonra maksimum havuzlama (Max Pooling) işlemi uygulanır. Bu işlem de evrişim işlemi sonucu elde edilen dizinin belli uzunluklardaki en büyük değeri seçilir [45]. Şekil 3.7'de bir boyutlu evrişimsel sinir ağının evrişim işlemi görülmektedir.



**Şekil 3.7:** Bir boyutlu evrişimsel sinir ağının evrişim işlemi.

İki boyutlu CNN'nin bir önceki yöntemden farkı, girdinin ve kullanılan filtrenin dizi değil matris olmasıdır. Bu nedenle eleman çarpımı değil matris çarpımı yapılır. Şekil 3.8'da örnek bir girdi ve filtre matrisine karşın çıktıyı göstermektedir. Tanımlanan pencerede kaydırılarak çıktı matrisinin her bir elemanı için sonuç hesaplanır. Elde edilen sonuç tekrardan maksimum havuzlama işlemine tabi tutulur. Bir önceki yöntemden farklı olarak bu adımda dizide bir uzunluk yerine belli bir matriste yapılır.




Şekil 3.8: 2 boyutlu CNN yapısı (CNN-2D).

### 3.2.3 Makine Öğrenmesi

Oluşturulan öznitelik vektörlerinin sınıflandırılmasında yaygın olarak makine öğrenme yöntemleri kullanılır.


**En Yakın Komşuluk (kNN):** Kullanılan bu yöntemlerden eskilerinden biri en yakın komşuluk yaklaşımıdır [46]. Bu yaklaşımda sınıfı tespit edilmek istenen test sınıfındaki her bir elemanın eğitim setindeki tüm elemanlara olan uzaklığı tespit edilir. Uzaklık ölçümünde en yaygın kullanılan yöntem Öklid mesafesidir. Öklid mesafesi uzaydaki iki noktanın kartezyen koordinatlarının farkının karesinin toplamının kare köküyle hesaplanır. Bunun yanında Manhattan ve Lorentzian gibi yöntemler de kullanılmaktadır [47]. Örnek olarak Şekil 3.9'daki kırmızı noktanın hangi sınıfta olduğunu öğrenmek istediğimizde en yakın k tane komşusuna bakılır. Bu örnek için  $k = 5$  olarak belirlenmiştir, bu durumda en yakın 5 komşusundan 4 tanesi turuncu sınıfa, 1 tanesi yeşil sınıfa aittir. En çok komşuluğu turuncu sınıfla olduğu için bu nokta turuncu ile işaretlenir. Bu yaklaşımı daha hızlı bir şekilde gerçekleşmesi için, eğitim aşamasında her bir sınıf için bir sınır belirlenir ve test aşamasında elemanın hangi bölgeye düştüğüne bakılır. Şekil 3.9'da kNN modeli görülmektedir [48].

**Destek Vektör Makineleri (SVM):** Bir başka temel yaklaşım destek vektör makineleri (SVM) yaklaşımıdır [49]. Bu yaklaşımın kNN yaklaşımından farkı sınır bölgelerinin sınıf elemanlarına yakın olması yerine; iki sınıfa da en uzak noktada seçilmesidir. Şekil 3.10'da destek vektör makineleri modeli görülmektedir [50].



**Şekil 3.9:** kNN modeli.


Bu amaçla öncelikle iki sınıf için de destek vektörleri belirlenir. Bu destek vektörleri iki sınıрын birbirine komşu olan noktalarından geçen doğrular veya çok boyutlu uzay için düşünülürse vektörlerdir. Şekil 3.10'da bu vektörler görülmektedir. Sınıfların ayrımı bu iki vektörün ikisine de en uzak vektör kullanılarak bulunur. Bu sayede eğitim aşamasında görünmeyen noktalar olsa dahi en iyi şekilde birbirlerinden ayrılması sağlanır.



**Şekil 3.10:** Destek Vektör Makineleri modeli yapısında oluşturulan destek vektörleri ve bu desteklerin ortasında yer alan sınır bölgesi.

**Karar Ağacı (DT):** Bu yaklaşımdan farklı olarak noktaların uzaydaki uzaklıkları yerine, vektördeki her bir koordinatın verilen karara etkisi incelenir. Bu süreç normal bir insanın karar verme sürecine benzetilebilir. Bir kararı verirken her adımda sadece vektörün bir elemanına bakılır. Bu elemanın aldığı değer için karar ağacında dallanmalar yapılır. Yeni kullanılan noktada karar mekanizması kullanılarak bu dallandırma işlemi yapraklardaki sınıfa

ulaşıncaya kadar devam edilir. Örneğin Şekil 3.11’de hava durumu için oluşturulan bir karar ağacı görülmektedir. Yağmur yağma olasılığı olup olmadığına karar vermek için öncelikle havanın mevcut durumuna bakılır. Buna göre ağaçta belli bir noktaya geçilir. Bu noktada yeni bir sorunla karşılaşılır ve bunun cevabına göre karar verilir [51].




Şekil 3.11: Karar Ağacı (DT) yapısı örneği.

**Rastgele Orman Ağacı (RF):** Karar ağacı yönteminin eksikliği sadece bir karara bağlı kalmasıdır. Başka bir soru ile başlamak cevabı değiştirebilir. Bu amaçla rastgele orman ağacı kullanılır. Eğitim aşamasında çok sayıda karar ağacı oluşturulur ve bunlar sonucunda en çok kabul bulan karar cevap olarak bulunur.

### 3.3. ÖNERİLEN YÖNTEM

Şu ana kadar sınıflandırma işlemi için yaygın kullanılan yöntemler detaylandırıldı. Bu yöntemlerden yola çıkarak Şekil 3.12’de diyagramı verilen yöntem geliştirildi. Bu yöntem detaylı incelenirse 3 farklı karar mekanizmasının bir makine öğrenmesi yöntemiyle birleştirilmesini içermektedir. Bu karar mekanizmaları sırasıyla CNN-1D, CNN-2D ve veri kümesinde ses kayıtlarına ek sunulan yaş ve cinsiyet bilgileridir.


Kullanılan karar mekanizmalardan ilki CNN-1D'dir. Bu ve diğer aşamalar için öncelikle veri kümesindeki tüm sesler aynı örnekleme seviyesine ve uzunluğa getirilmiştir. Elde edilen 12 EKG sinyalinin her biri için bir CNN-1D sınıflandırıcı tasarlanmıştır. Bu amaçla öncelikle sinyale bir boyutlu evrişim uygulandı. Bu aşamada kullanılan filtrenin uzunluğu 8 birim seçildi ve toplam 16 tane filtre kullanıldı. Daha sonra elde edilen sonuçlar ReLU fonksiyonundan geçirilmiştir. Elde edilen çıktı tekrardan bir boyutlu evrişim mekanizmasına konuldu. Bu işlemde 16 birim uzunluğunda 32 filtre kullanıldı. Sonuçlara aktivasyon fonksiyonu olarak tekrardan ReLU fonksiyonu uygulanmıştır. Tüm sonuçlar çıktıktan sonra üçer eleman kullanarak havuzlama işlemi yapılmıştır. Elde edilen sonuçlar bir girdiye dönüştürülerek önce 126 YSH içeren daha sonra da veri kümesindeki sınıf adeti olan 11 YSH içeren katmanlardan geçirilerek 11 sınıfın her biri için bir olasılık elde edilmiştir.



Şekil 3.12: Önerilen yöntemin genel diyagramı.

Kullanılan ikinci karar mekanizması CNN-2D'dir, fakat bu işlem için öncelikle tek boyutlu ses sinyali iki boyutlu görüntüye çevrilmelidir. Bu amaçla en yaygın kullanılan yöntem MFCC yöntemidir. Bu amaçla her bir EKG sinyali için 126 X 126 MFCC değerleri


çıkartılmıştır. Bu amaçla Python librosa kütüphanesi kullanılmıştır. Veri setinin tamamı 500 Hz ile örneklendiği için örnekleme parametresi 500 seçilmiştir. MFCC sayısı matrisin bir boyutunu temsil ettiği için 126 olarak belirlenmiştir. MFCC pencere boyutu olarak 20 ve FFT boyutu 128 seçildi. Pencere boyutu ve FFT sayısı küçük hareketleri yakalamak için düşük tutulurken; MFCC sayısı kare matris elde etmek için 126 olarak belirlenmiştir. Farklı büyüklükle yapılan testler sonucunda en başarılı yöntem bu değerler için elde edilmiştir.



**Şekil 3.13:** Örnek bir ses dosyasına ait MFCC çıktısının ısı haritası görünümü.

Her sinyal MFCC kullanılarak 2 boyutlu matrise çevrildikten sonra CNN-2D'ye girdi olarak verildi. CNN-2D'nin ilk adımı 3 x 3'lük 16 filtre içermektedir. Bu evrişim işlemi sonucu oluşan matrisin 2 x 2'lik parçalar halinde maksimum elemanları seçilmiştir ve çıktıya ReLU fonksiyonu uygulanmıştır. Oluşturulan yeni matris tekrardan CNN-2D'ye girdi olarak verilmiştir. Yeni CNN katmanı 5 x 5'lik 32 tane filtre içermektedir. Çıktı bir önceki adımdaki gibi tekrardan maksimum havuzlama ve ReLU işlemine tabi tutulmuştur. Elde edilen matris tekrardan 5x5'lik 64 filtreden geçirip; maksimum havuzlama ve ReLU işlemine tabi tutulmuştur. Son aşamada çıktılar bir boyutlu diziye çevrilip öncelikle 64 YSH içeren bir gizli katmandan daha sonra da sınıf sayısı olan 11 YSH'den oluşan çıktı katmanına girdi olarak verilmiştir. Bu işlem sonucu her bir sinyal için 11 sınıfın olasılığı elde edilmiştir. Şekil 3.13'te örnek bir ses dosyasına ait MFCC çıktısının ısı haritası görünümüne yer verilmiştir.

Tüm eğitim süreci için öncelikle eğitim veri kümesi %85'i eğitim, %15'i de doğrulama olacak şekilde 2 parçaya bölünmüştür. Burada önemli olan veri kümesi süreçten önce eğitim ve test olarak ikiye bölünmüştür ve her küme sırasıyla veri kümesinin %70 ve %30 undan oluşmaktadır. Test veri kümesi eğitim süresince kesinlikle kullanılmamıştır. Şekil 3.14'te veri kümesinin modeldeki dağılımı daire grafiğinde görülmektedir.




**Şekil 3.14:** Veri kümesinin modeldeki dağılımı.

İki CNN de 12 sinyalin her biri için ayrı ayrı eğitilmiştir. Eğitim süresince önemli olan verilerden biri eğitim tur sayısıdır. Bu sayıyı belirlemenin bir yolu doğrulama kümesi için belirlenen kayıp miktarının uzun süre azalmamasıdır. Doğrulama kümesi için kayıp miktarının azalmıyor olması sistemin eğitim kümesini ezberlemeye başladığı anlamına gelmektedir. Bu amaçla eğer 8 tur boyunca doğrulama veri kümesi için kayıp fonksiyonu azalmış ise eğitim süreci durdurulmuştur. Şekil 3.15'te model eğitimi şeması görülmektedir. Bu işlem sonucu her bir sinyal için 11 sınıfın her biri için her CNN'den bir olasılık elde edildi. Bu sayede 12 sinyalin her biri için 11 olasılıktan her bir CNN yöntemi için 132 tane olasılık elde edilmiş olur. CNN-1D ve CNN-2D birleştirildiği zaman toplam 264 olasılık elde edilmiş olur.


CNN-1D ve CNN-2D sonuçlarını birleştirmek için makine öğrenmesi kullanılmıştır. Bu amaçla öncelikle 12 sinyalin her biri için bir adet CNN-1D ve bir adet CNN-2D eğitilmiştir. Daha sonra bu modeller kullanılarak doğrulama kümesindeki her bir eleman için 264 olasılık elde edildi. Doğrulama kümesine ait her örnek için elde edilen 264'er tane olasılık ve cinsiyet

ile yaş bilgileri birleştirilerek bir tane rastgele orman ağacı eğitilmiştir. Daha sonra test aşamasında daha önce eğitilen CNN modelleri kullanılarak test kümesi için 264'er olasılık ve cinsiyet ile yaş bilgisi, doğrulama kümesi ile eğitilen rastgele orman ağacı ile test edilmiştir.



#### 4. BULGULAR

Gerçekleşen yöntemin test edilmesi için öncelikle veri kümesini %30 test, %70 eğitim kümesi olacak şekilde iki parçaya bölünmüştür. Daha sonra elde edilen eğitim kümesi %15'i doğrulama kümesi olacak şekilde iki parçaya bölünmüştür. Bu işlemler sonrasında oluşan veri kümesinin dağılımı Şekil 4.1'de görülmektedir. Bu işlem sonucu her sınıf için ortalamada eğitim kümesi için 250, doğrulama kümesi için 50 ve test kümesi için 130 adet 12 derivasyonlu EKG sinyali elde edilmiştir.




**Şekil 4.1:** Veri kümesi eğitim, doğrulama ve test şeklinde üçe bölünmesi sonucu, sınıfların veri kümelerine dağılım grafikleri.
















Yöntemin başarımının daha doğru ölçebilmek için, açık kaynak veri kümesini gereksinimlere göre yeniden tanımladığımız için, öncelikle aynı veri kümesi üzerinde en güncel makalelerden biri test edilmiştir [6]. Bu makalenin seçilme nedeni, bu makale açık kodu olan ve ortak veri kümelerinde en iyi sonucu veren en güncel yayın olmasıdır. Bu yöntemle yazarlar temel olarak sinyali son zamanlarda yaygın olarak kullanılan bir CNN yaklaşımı olan ResNet ile modellemişlerdir [34]. Yöntemin açık kaynak kodu GitHub üzerinden ulaşılabilir durumdadır [52].


Bu yöntem bir doğrulama kümesine ihtiyaç duymadığı için eğitim kümesi ve doğrulama kümesi birleştirilerek eğitim için kullanıldı ve test kümesi aynı tutulmuştur. Her bir eğitim turu 5 saate yakın sürdüğü için model 25 tur boyutunca eğitildi ve kayıp miktarı azalmaya başladığı için eğitim süreci bitirildi. Bu işlem sonucu en yüksek test başarımı %49,6 ile 21.

eğitim turunda elde edildi. Bu noktadan sonra %49,6 bu veri seti için taban başarımları olarak kullanıldı.

Yöntemin başarısı ölçmek için öncelikle eğitim ve doğrulama kümesini kullanarak CNN-2D modeli eğitildi. Şekil 4.2’de tüm EKG sinyali için elde edilen başarı ve kayıp grafikleri görülmektedir. Her bir kaynak için ilk grafik eğitim ve doğrulama kümeleri için her bir eğitim turunda elde edilen başarı gösterilmektedir. Her bir sinyal için ikinci görsel eğitim ve doğrulama kümeleri için kayıp miktarını göstermektedir. Son grafikler ise test kümesi için elde edilen karmaşıklık matrisini göstermektedir. Bu grafiklerdeki önemli bir gözlem, genellikle ilk 10 eğitimden sonra doğrulama kümesi için elde edilen kayıp miktarı artmaya başlamaktadır. Bu noktada sistemin eğitim kümesini ezberlemeye başladığı düşünülebilir. Bu nedenle sistem öğrenme süreci genellikle 20 turdan önce durdurulmuştur.








**Şekil 4.2:** CNN-2D için 12 kaynak için elde edilen kayıp, başarımlar ve karmaşıklık matrisi grafikleri. Elde edilen sonuçlardan bir başka önemli nokta ise farklı ses kaynaklarından gelen sinyallerin farklı sınıflar için farklı oranda etkili olmasıdır. Bu amaçla çıktı olasılıklarını kullanılarak bir makine öğrenmesi yaklaşımı kullanmanın etkili olacağı varsayımının doğru olduğunu düşünebiliriz. Tablo 4.1’de 12 farklı kaynak için elde edilen CNN-2D başarımlar sonuçları görülmektedir. Sonuçlara göre en başarılı EKG kaynağı %41 ile V1’dir.

**Tablo 4.1:** 12 kaynak için CNN-2D ile elde edilen başarımlar.

| Kaynak      | I  | II | III | aVR | aVL | aVF | V1 | V2 | V3 | V4 | V5 | V6 |
|-------------|----|----|-----|-----|-----|-----|----|----|----|----|----|----|
| Başarım (%) | 32 | 36 | 38  | 30  | 32  | 31  | 41 | 37 | 36 | 33 | 33 | 32 |


Bir sonraki adımda 11 sınıfın her biri için 12 kaynaktan gelen 132 tane olasılık kullanılarak kNN, karar ağacı ve rastgele orman ağacı eğitildi. Eğitim için doğrulama kümesinin sonuçları kullanıldı, eğitim süresince test kümesinden bir örnek kesinlikle kullanılmadı. Bu işlem sonucunda yöntemler için sırasıyla %42,1, %35,8 ve %47,7 elde edildi. Rastgele orman ağacı yöntemi test kümesi için en iyi sonuç veren yöntem olmaktadır. Şekil 4.3'te bu yöntem için test kümesinde elde edilen karmaşıklık matrisi görülebilmektedir.

**Şekil 4.3:** CNN-2D yöntemiyle elde edilen olasılıkların rastgele orman ağacıyla birleştirilmesi sonucu elde edilen karmaşıklık matrisi.

Yöntemin farklı sınır değerlerine göre nasıl davrandığını anlayabilmek için 11 hastalığın her biri için Alıcı İşletim Karakteristik Eğrisi (Receiver Operating Characteristic Curve-ROC) çizdirildi. Çizdirilen ROC eğrisi Şekil 4.4'te görülmektedir. Ayrıca bu görselde her bir sınıf için elde edilen Eğri Altında Kalan Alan (Area Under the Curve-AUC) sonuçları görülebilmektedir. Sonuçlardan da görülebildiği üzere tüm hastalıklar için %70'in üzerinde AUC sonuçları vardır. Ortalamada ise %80'in üzerinde AUC sonucu elde edilmiştir.


**Tablo 4.2:** 12 kaynak CNN-1D için elde edilen başarımlar.

| Kaynak      | I  | II | III | aVR | aVL | aVF | V1 | V2 | V3 | V4 | V5 | V6 |
|-------------|----|----|-----|-----|-----|-----|----|----|----|----|----|----|
| Başarım (%) | 22 | 23 | 20  | 24  | 20  | 22  | 26 | 27 | 22 | 22 | 22 | 22 |



**Şekil 4.4:** CNN-2D yöntemiyle 11 hastalık için elde edilen ROC eğrişi ve AUC sonuçları


İkinci adım olarak CNN-1D modeli eğitildi. Bu modelin için CNN-1D’de uygulanan süreçler aynen tekrarlanır. Şekil 4.5’te 2 farklı kaynak için elde edilen istatistikler görülmektedir. Bu yöntem beklendiği üzere CNN-2D yönteminden daha kötü çalışmaktadır. Tablo 4.2’de bu yöntemin 12 kaynak için elde edilen başarımları görülmektedir.



**Şekil 4.5:** CNN-1D için elde edilen örnek başarımlar, kayıp ve karmaşıklık matrisi grafikleri.


Bu modelleri daha önceki yöntemle olduğu gibi makine öğrenmesi yöntemiyle birleştirince yöntemler için sırasıyla %39,7, %36,8 ve %51,3 başarımlar elde edildi. Bu yöntemle veri setinde

gelen yaş ve cinsiyet verileri de eklendiği zaman rastgele orman ağacı için elde edilen başarımlı değeri %51,7'ye çıktı. Bu yöntem için elde edilen karmaşıklık matrisi Şekil 4.6'da görülmektedir.



**Şekil 4.6:** Yöntemin son halindeki karmaşıklık matrisi

Şekil 4.7'de 11 hastalık sınıfı için tüm yöntem sonucunda elde edilen ROC eğrileri görülmektedir. Aynı şekil üzerinde bu hastalıklar için elde edilen AUC sonuçları da görülmektedir. Bu sonuçlara göre hastalıkların tamamı için %74'ün üzerinde AUC sonucu elde edilmiştir. Ortalamada ise %86,5 AUC sonucu elde edilmiştir.



**Şekil 4.7:**Yöntem sonunda 11 hastalık için elde edilen ROC eğrileri ve AUC sonuçları

## 5. TARTIŞMA VE SONUÇ

Bu tez kapsamında kalp hastalıklarının 12 derivasyonlu EKG sinyalleri kullanılarak sınıflandırılması problemi üzerine çalışıldı. Bu problem iki açıdan önem arz etmektedir. İlk olarak kalp hastalıklarının erken teşhisi birçok hastalığın daha hızlı bir şekilde tedavi edilmesini sağlayacaktır. İkinci olarak özellikle akıllı saatler gibi küçük donanım cihazlarının kullanımıyla bu verinin ucuz bir şekilde toplanması hastalık tespiti sürecindeki harcamaları düşürerek ciddi miktarda tasarruf sağlayacaktır.

Bu amaçla önerilen yöntem 11 farklı hastalığı %51,7 başarı ile ayırt edebilmektedir. Yöntemin mevcut uygulamalarla karşılaştırılması noktasında en önemli problem veri kümelerinin farklı olmasıdır. Mevcut yöntemlerin kullandığı veri seti mevcut veri kümesinden daha çok hastalık sınıfı ve örnek içermektedir. Ayrıca mevcut yöntemlerin test edilmesinde kullanılan veri kümesi paylaşılmamıştır. Bu nedenle geliştirilen yöntemin başarımı açık kaynak kodu bulunan referans yaklaşım [6] kullanılarak mevcut yöntemlerle karşılaştırılmıştır.

**Tablo 5.1:** Önerilen yöntemin mevcut yöntemlerle karşılaştırılması

| Yöntem          | PhysioNET Doğrulama Puanı | Tez Veri Kümesi |                       |
|-----------------|---------------------------|-----------------|-----------------------|
|                 |                           | Başarımı (%)    | Çalışma Zamanı (Saat) |
| [35]            | 0,659                     | -               | -                     |
| [6]             | 0,657                     | 49,6            | 108                   |
| [36]            | 0,653                     | -               | -                     |
| [37]            | 0,543                     | -               | -                     |
| Önerilen Yöntem | -                         | <b>51,7</b>     | <b>2</b>              |

Tablo 5.1’de PhysioNET yarışması kapsamında CNN kullanan doğrulama puanı yüksek makalelerin karşılaştırılması görülmektedir. Bu yöntemlerden [6] yaklaşımının açık kaynak kodu bulunduğu için bu yöntem tez kapsamında kullanılan veri kümesinde test edilmiştir. Bu noktada referans makalenin en yüksek sonuca sahip olmamakla birlikte, en yüksek sonuç ile

çok yakın sonuçlar vermesi önemli bir noktadır. Elde edilen sonuçlar göstermektedir ki geliştirilen yöntem referans yayının başarımını %2,1 arttırmıştır.

Yöntemin bir diğer avantajı ise diğer yöntemlere göre çalışma zamanının daha düşük olmasıdır. Referans makale i5 işlemcili 8GB ram sahibi ortalama bir dizustu bilgisayarda tez veri kümesi için yaklaşık 5 gün sonunda sonuç üretmişken, aynı makine ve veri kümesi için geliştirilen yöntem sadece 2 saatte sonuç üretebilmektedir. Özellikle büyük veri kümeleri için bu önemli bir avantajdır.

Önerilen yöntemi geliştirmek için farklı yöntemler denenmiştir. Bu yöntemlerden ilk katmanlardaki filtrelerin sayısını ve katmanlardaki YSH sayılarını değiştirmektir; fakat en iyi sonuç bu yöntem ile elde edilmiştir.

Daha sonrasında referans olarak kullanılan makalenin temel aldığı ResNet yönteminin 2 boyutlu hali denenmiştir. Bu işlem sonucu tasarlanan CNN-2D yönteminden daha düşük sonuçlar elde edilmiştir. Bir diğer yaklaşım olarak her bir kaynak için ayrı bir model eğitimi yerine kaynaklar hepsi için ortak bir model eğitilmiştir. Bu iki farklı şekilde yapılabilir: ilki kaynakların girdi adımından önce birleştirilmesidir, ikincisi ise CNN modelini 12 sinyali de aynı anda girdi olarak izleyebilecek kabiliyete getirmektedir. Bu iki işlemin sonucu da tasarlanan yöntemden daha düşük kalmıştır.

Yapılan testler ve önceki makalelerden elde edilen sonuçlar göstermektedir ki geliştirilen yöntem sınıflandırma başarımı üzerinde yaklaşık olarak %2,1'lik bir iyileştirme sağlamaktadır. Tezin tüm gerçekleşmesine ve verilere Kaggle üzerinden erişilebilir [53]. Python'da kullanılan CNN gerçekleştirilmesi Şekil 7.1 ve Şekil 7.2'de görülmektedir. Bu çalışma ileriki çalışmalarda sınıf ve örneklem sayısı artırılarak iyileştirilebilir.

## 6. KAYNAKLAR

- [1] Jiang, J., Zhang, H., Pi, D., & Dai, C. (2019). A novel multi-module neural network system for imbalanced heartbeats classification. *Expert Systems with Applications: X*, 1, 100003.
- [2] Ebrahimi, Z., Loni, M., Daneshtalab, M., & Gharehbaghi, A. (2020). A review on deep learning methods for ECG arrhythmia classification. *Expert Systems with Applications: X*, 7, 100033.
- [3] Sannino, G., & De Pietro, G. (2018). A deep learning approach for ECG-based heartbeat classification for arrhythmia detection. *Future Generation Computer Systems*, 86, 446-455.
- [4] Wang, T., Lu, C., Sun, Y., Yang, M., Liu, C., & Ou, C. (2021). Automatic ECG Classification Using Continuous Wavelet Transform and Convolutional Neural Network. *Entropy*, 23(1), 119.
- [5] Liu, W., Huang, Q., Chang, S., Wang, H., & He, J. (2018). Multiple-feature-branch convolutional neural network for myocardial infarction diagnosis using electrocardiogram. *Biomedical Signal Processing and Control*, 45, 22-32.
- [6] Ribeiro, A. H., Gedon, D., Teixeira, D. M., Ribeiro, M. H., Ribeiro, A. L. P., Schön, T. B., & Meira, W. (2020, September). Automatic 12-lead ECG Classification Using a Convolutional Network Ensemble. In *2020 Computing in Cardiology* (pp. 1-4). IEEE.
- [7] Demir, T., 2019, *Temel EKG*, <https://www.acilcalisanlari.com/temel-ekg.html>, [Ziyaret Tarihi: 5 Kasım 2021]
- [8] Goldberger, A. L. (2006). Atrioventricular (AV) heart block. *Goldberger AL. Clinical Electrocardiography: A Simplified Approach. 7th ed. St. Louis: Mosby/Elsevier*, 203-14.
- [9] Burns, E., Buttner, R., 2021, *ECG Limb Lead Reversal*, <https://litfl.com/ecg-limb-lead-reversal-ecg-library/>, [Ziyaret Tarihi: 5 Kasım 2021]
- [10] Watford, C. (2014). Understanding ECG filtering. *EMS 12-Lead*.

- [11] Padhy, S., & Dandapat, S. (2017). Third-order tensor based analysis of multilead ECG for classification of myocardial infarction. *Biomedical Signal Processing and Control*, 31, 71-78.
- [12] Kutlu, Y., & Kuntalp, D. (2012). Feature extraction for ECG heartbeats using higher order statistics of WPD coefficients. *Computer methods and programs in biomedicine*, 105(3), 257-267.
- [13] Ebrahimpour, R., Sadeghnejad, N., Sajedin, A., & Mohammadi, N. (2013). Electrocardiogram beat classification via coupled boosting by filtering and preloaded mixture of experts. *Neural Computing and Applications*, 23(3), 1169-1178.
- [14] Seera, M., Lim, C. P., Liew, W. S., Lim, E., & Loo, C. K. (2015). Classification of electrocardiogram and auscultatory blood pressure signals using machine learning models. *Expert Systems with Applications*, 42(7), 3643-3652.
- [15] Manikandan, M. S., & Dandapat, S. (2014). Wavelet-based electrocardiogram signal compression methods and their performances: A prospective review. *Biomedical Signal Processing and Control*, 14, 73-107.
- [16] Donoso, F. I., Figueroa, R. L., Lecannelier, E. A., Pino, E. J., & Rojas, A. J. (2013). Atrial activity selection for atrial fibrillation ECG recordings. *Computers in biology and medicine*, 43(10), 1628-1636.
- [17] Clifford, G. D., Azuaje, F., & McSharry, P. (2006). *Advanced methods and tools for ECG data analysis* (p. 12). Boston: Artech house.
- [18] Martínez, A., Alcaraz, R., & Rieta, J. J. (2010). Application of the phasor transform for automatic delineation of single-lead ECG fiducial points. *Physiological measurement*, 31(11), 1467.
- [19] Abibullaev, B., & Seo, H. D. (2011). A new QRS detection method using wavelets and artificial neural networks. *Journal of medical systems*, 35(4), 683-691.

- [20] Martínez, J. P., Almeida, R., Olmos, S., Rocha, A. P., & Laguna, P. (2004). A wavelet-based ECG delineator: evaluation on standard databases. *IEEE Transactions on biomedical engineering*, 51(4), 570-581.
- [21] Afonso, V. X., Tompkins, W. J., Nguyen, T. Q., & Luo, S. (1999). ECG beat detection using filter banks. *IEEE transactions on biomedical engineering*, 46(2), 192-202.
- [22] Pan, J., & Tompkins, W. J. (1985). A real-time QRS detection algorithm. *IEEE transactions on biomedical engineering*, (3), 230-236.
- [23] Tantawi, M. M., Revett, K., Salem, A., & Tolba, M. F. (2013). Fiducial feature reduction analysis for electrocardiogram (ECG) based biometric recognition. *Journal of Intelligent Information Systems*, 40(1), 17-39.
- [24] Elhaj, F. A., Salim, N., Harris, A. R., Swee, T. T., & Ahmed, T. (2016). Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals. *Computer methods and programs in biomedicine*, 127, 52-63.
- [25] Coutinho, D. P., Silva, H., Gamboa, H., Fred, A., & Figueiredo, M. (2013). Novel fiducial and non-fiducial approaches to electrocardiogram-based biometric systems. *IET biometrics*, 2(2), 64-75.
- [26] Martis, R. J., Acharya, U. R., & Min, L. C. (2013). ECG beat classification using PCA, LDA, ICA and discrete wavelet transform. *Biomedical Signal Processing and Control*, 8(5), 437-448.
- [27] Lin, C. W., Wang, J. S., & Chung, P. C. (2010). Mining physiological conditions from heart rate variability analysis. *IEEE Computational Intelligence Magazine*, 5(1), 50-58.
- [28] Rahman, Q. A., Tereshchenko, L. G., Kongkatong, M., Abraham, T., Abraham, M. R., & Shatkay, H. (2015). Utilizing ECG-based heartbeat classification for hypertrophic cardiomyopathy identification. *IEEE transactions on nanobioscience*, 14(5), 505-512.
- [29] Balasundaram, K., Masse, S., Nair, K., & Umapathy, K. (2013). A classification scheme for ventricular arrhythmias using wavelets analysis. *Medical & biological engineering & computing*, 51(1), 153-164.

- [30] Salem, M., Taheri, S., & Yuan, J. S. (2018, October). ECG arrhythmia classification using transfer learning from 2-dimensional deep CNN features. In *2018 IEEE Biomedical Circuits and Systems Conference (BioCAS)* (pp. 1-4). IEEE.
- [31] Kiranyaz, S., Ince, T., & Gabbouj, M. (2015). Real-time patient-specific ECG classification by 1-D convolutional neural networks. *IEEE Transactions on Biomedical Engineering*, 63(3), 664-675.
- [32] Yin, W., Yang, X., Zhang, L., & Oki, E. (2016). ECG monitoring system integrated with IR-UWB radar based on CNN. *IEEE Access*, 4, 6344-6351.
- [33] Huang, J., Chen, B., Yao, B., & He, W. (2019). ECG arrhythmia classification using STFT-based spectrogram and convolutional neural network. *IEEE Access*, 7, 92871-92880.
- [34] Targ, S., Almeida, D., & Lyman, K. (2016). Resnet in resnet: Generalizing residual architectures. *arXiv preprint arXiv:1603.08029*.
- [35] Nejedly, P., Ivora, A., Viscor, I., Halamek, J., Jurak, P., & Plesinger, F. (2020, September). Utilization of Residual CNN-GRU with Attention Mechanism for Classification of 12-lead ECG. In *2020 Computing in Cardiology* (pp. 1-4). IEEE.
- [36] Jia, W., Xu, X., Xu, X., Sun, Y., & Liu, X. (2020, September). Automatic Detection and Classification of 12-lead ECGs Using a Deep Neural Network. In *2020 Computing in Cardiology* (pp. 1-4). IEEE.
- [37] He, R., Wang, K., Zhao, N., Sun, Q., Li, Y., Li, Q., & Zhang, H. (2020, September). Automatic Classification of Arrhythmias by Residual Network and BiGRU With Attention Mechanism. In *2020 Computing in Cardiology* (pp. 1-4). IEEE.
- [38] Load variables from file into workspace- MATLAB load, <https://www.mathworks.com/help/matlab/ref/load.html>, [Ziyaret tarihi: 4 Kasım 2021]
- [39] physionetchallenges, [https://github.com/physionetchallenges/physionetchallenges.github.io/blob/master/2020/Dx\\_map.csv](https://github.com/physionetchallenges/physionetchallenges.github.io/blob/master/2020/Dx_map.csv), [Ziyaret tarihi: 10 Ekim 2021]

- [40] Davis, S., & Mermelstein, P. (1980). Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. *IEEE transactions on acoustics, speech, and signal processing*, 28(4), 357-366.
- [41] Kröse, B., Krose, B., van der Smagt, P., & Smagt, P. (1993). An introduction to neural networks.
- [42] Ak, Y., 2019, *Ek Bilgiler*, <https://ai.yemreak.com/ek-bilgiler>, [Ziyaret Tarihi: 6 Kasım 2021]
- [43] Ramachandran, P., Zoph, B., & Le, Q. V. (2017). Searching for activation functions. *arXiv preprint arXiv:1710.05941*.
- [44] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105.
- [45] Graham, B. (2014). Fractional max-pooling. *arXiv preprint arXiv:1412.6071*.
- [46] Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1), 21-27.
- [47] Bilge, H. Ş., & Kerimbekov, Y. (2015, May). Classification with Lorentzian distance metric. In *2015 23rd Signal Processing and Communications Applications Conference (SIU)* (pp. 2106-2109). IEEE.
- [48] Afifi, M., 2019, *kNN classifier*, [https://la.mathworks.com/matlabcentral/fileexchange/63621-knn-classifier?s\\_tid=FX\\_rc2\\_behav](https://la.mathworks.com/matlabcentral/fileexchange/63621-knn-classifier?s_tid=FX_rc2_behav), [Ziyaret Tarihi: 7 Kasım 2021].
- [49] Vapnik, V. (1999). *The nature of statistical learning theory*. Springer science & business media.
- [50] Bozkurt, E., 2021, *Machine Learning Classification Algorithms with Codes*, <https://medium.com/analytics-vidhya/machine-learning-classification-algorithms-with-codes-5a8af4491fcb>, [Ziyaret Tarihi: 10 Kasım 2021].

[51] Uzun, E., *Decision Tree (Karar Ağacı): ID3 Algoritması – Classification (Sınıflama)*, [https://erdincuzun.com/makine\\_ogrenmesi/decision-tree-karar-agaci-id3-algoritmasi-classification-siniflama/](https://erdincuzun.com/makine_ogrenmesi/decision-tree-karar-agaci-id3-algoritmasi-classification-siniflama/), [Ziyaret Tarihi: 11 Kasım 2021].

[52] Ribeiro, H. ,2020, physionet-12ecg-classification, <https://github.com/antonior92/physionet-12ecg-classification>, [Ziyaret tarihi: 15 Ekim 2021].

[53] Altınışık, H., 2021, Kaggle, <https://www.kaggle.com/haticesraltnsk/notebookb5cb008c1a>, [Ziyaret tarihi: 5 Aralık 2021].



## 7. EKLER

```
def CNN2D(mfccTest,mfccTrain,mfccVal, lead):
    X_test = np.reshape(mfccTest,(testCnt,126, 126,1))
    X_train = np.reshape(mfccTrain,(trainCnt,126, 126,1))
    X_val = np.reshape(mfccVal,(valCnt,126, 126,1))
    model = Sequential()

    model.add(Conv2D(16, (3), input_shape=X_train.shape[1:]))
    model.add(Activation('relu'))
    model.add(MaxPooling2D(pool_size=(2, 2)))

    model.add(Conv2D(32, (5, 5)))
    model.add(Activation('relu'))
    model.add(MaxPooling2D(pool_size=(2, 2)))

    model.add(Conv2D(64, (5, 5),padding='same'))
    model.add(Activation('relu'))
    model.add(MaxPooling2D(pool_size=(2, 2)))

    model.add(Flatten()) # this converts our 3D feature maps to 1D feature vectors

    model.add(Dense(64))

    model.add(Dense(11))
    model.add(Activation('softmax'))
    sgd = optimizers.SGD(lr=0.000001, decay=1e-6, momentum=0.9, nesterov=True)

    model.compile(loss='categorical_crossentropy', optimizer='adam',metrics=['accuracy'])

    callbacks = [EarlyStopping(monitor='val_loss', patience=8),
                  ModelCheckpoint(filepath=lead+'_best_model_cnn2d.h5', monitor='val_accuracy', save_best_only=True)]
    history=model.fit(X_train, y_train, validation_data=(X_val, y_val), epochs=50, callbacks=callbacks, batch_size=32, verbose=0)
```

Şekil 7.1: Python kullanarak önerilen CNN-2D gerçekleştirilmesi.

```
def CNN1D(lead):
    X_train = new_dfTrain[lead].values[:, :-1]
    X_test = new_dfTest[lead].values[:, :-1]
    X_val = new_dfVal[lead].values[:, :-1]

    X_train=X_train.reshape(X_train.shape[0],X_train.shape[1],-1)
    X_test=X_test.reshape(X_test.shape[0],X_test.shape[1],-1)
    X_val=X_val.reshape(X_val.shape[0],X_val.shape[1],-1)

    model = Sequential()

    model.add(Conv1D(filters=16, kernel_size=(8), padding='same', activation='relu', input_shape = (X_train.shape[1],1)))
    model.add(Conv1D(filters=32, kernel_size=(16), padding='same', activation='relu'))

    model.add(MaxPool1D(pool_size=(3), strides=2, padding='same'))
    model.add(Dropout(0.5))
    model.add(Flatten())

    model.add(Dense(units = 512, activation='relu'))

    model.add(Dense(units = 11, activation='softmax'))

    callbacks = [EarlyStopping(monitor='val_loss', patience=8),
                  ModelCheckpoint(lead+'_conv1d_best_model.h5', monitor='val_accuracy', save_best_only='true')]

    model.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy'])
    history=model.fit(X_train, y_train, validation_data=(X_val, y_val), epochs=15 , callbacks=callbacks, batch_size=32, verbose=0)
```

Şekil 7.2: Python kullanarak önerilen CNN-1D gerçekleştirilmesi.