T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

FOTOPLETİSMOGRAFİ SİNYALLERİ KULLANILARAK KALP HIZI VE KAN BASINCI TESPİTİ

Fatma Sevde KÖKLÜKAYA

DANIŞMAN
Dr. Öğr. Üyesi Mahmut ÖZTÜRK

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği Programı

İSTANBUL-2021

Bu çalışma, 30.06.2021 tarihinde aşağıdaki jüri tarafından Elektrik-Elektronik Mühendisliği Anabilim Dalı, Elektrik-Elektronik Mühendisliği Programında Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Dr. Öğr. Üyesi Mahmut ÖZTÜRK(Danışman)
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Dr. Öğr. Üyesi Bahattin KARAKAYA
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Doç. Dr. Yalçın ÇEKİÇ
Bahçeşehir Üniversitesi
Mühendislik Fakültesi

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

Yüksek lisans eğitim ve öğretimim süresince bilgi ve tecrübelerinden yararlandığım, ders dönemim ve tez çalışmalarım boyunca desteğini ve yardımını hiç bir zaman esirgemeyen çok değerli danışman hocam Dr. Öğr. Üyesi Mahmut ÖZTÜRK'e teşekkürlerimi sunarım.

Bu süreçte her zaman yanımda olan maddi manevi desteğini hiçbir zaman esirgemeyen başta babam Etem KÖKLÜKAYA, annem Gülbin KÖKLÜKAYA ile ablam Nesibe ÖNDER ve Zeynep ZEYNELGİL olmak üzere her zaman yanımda olup beni her zaman destekleyen dostlarım Gülşah YALÇINKAYA, Gizem ÇAYIRLIOĞLU, Hilal MERCAN, Utku KAYA ve Kaancan KIRKAĞAÇ'a tüm kalbimle teşekkür ederim.

Temmuz 2021 Fatma Sevde KÖKLÜKAYA

İÇİNDEKİLER

Sayfa No

ÖNSÖZ ..... **iv**
İÇİNDEKİLER ..... **v**
ŞEKİL LİSTESİ ..... **vii**
TABLO LİSTESİ ..... **ix**
SİMGE VE KISALTMA LİSTESİ ..... **x**
ÖZET ..... **xi**
SUMMARY ..... **xiii**
1. GİRİŞ **1**
2. GENEL KISIMLAR **4**
2.1. PPG ELDE EDİLMESİ 4
2.2. KAN BASINCI SEVİYELERİ 4
2.3. KALP ATIŞ HIZI (NABIZ) 6
2.4. SOLUNUM SİNYALİ TAKİBİ 7
2.5. UYKU APNESİ TESPİTİ 8
2.6. KANDAKİ OKSİJEN SATÜRASYONU ÖLÇÜMÜ 8
3. MALZEME VE YÖNTEM **9**
3.1. DALGACIK DÖNÜŞÜMÜ 9
3.1.1 Ayarlanabilir Q-faktör Dalgacık Dönüşümü (TQWT) 12
3.1.2. Çift Ağaçlı Karmaşık Dalgacık Dönüşümü (DT-CWT) 15
3.2. WEKA YAZILIM 16
3.3. YAPAY SİNİR AĞLARI (YSA) 19
3.3.1. Çok Katmanlı Algılayıcılar (Multilayer Perceptron) 21
3.4. RASTGELE ORMAN (RO) 22
3.5. DESTEK VEKTÖR MAKİNALARI (DVM) 22
3.5.1. Doğrusal Ayrılabilme Durumu 23
3.5.2. Doğrusal Ayrılamama Durumu 23
4. BULGULAR **25**
4.1. VERİ KAYITLARI 25

4.2.DEĞERLENDİRME ÖLÇÜTLERİ PERFORMANSI (PERFORMANCE EVALUATION METRICS) 25
4.3. PPG SİNYALLERİ İLE ÖZELLİK ÇIKARTILMASI 26
4.3.1. DT-CWT Kullanılarak Özellik Çıkartılması 27
4.3.2. TQWT Kullanılarak Özellik Çıkartılması 34
5. TARIŞMA VE SONUÇ 41
KAYNAKLAR 44
ÖZGEÇMİŞ 53

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: PPG İşareti Ölçümü……..……..4

Şekil 2.2: Standart PPG Sinyali ve Özellik Noktaları…….……...6

Şekil 2.3: PPG Sinyalinden Solunum Bilgisinin Çıkartılması……..7

Şekil 3.1: Dalgacık Dönüşümü…….10

Şekil 3.2: Örnek Dalgacık Şekilleri……..…11

Şekil 3.3: Ayrık Dalgacık Dönüşümüyle İşaretin Alt Bantlara Ayrışımı…..……12

Şekil 3.4: PPG Örneği..……..…14

Şekil 3.5: TQWT ile Alt Bantlara Ayırma ……15

Şekil 3.6: Çift Ağaç Karmaşık Dalgacık Dönüşümü Analizi……16

Şekil 3.7: Weka Başlangıç Arayüzü……..17

Şekil 3.8: Weka İşlem Yüzü……..18

Şekil 3.9: Yapay Sinir Ağı Hücresi……19

Şekil 3.10: Çok Katmanlı Algılayıcı Modeli……..……..…….……21

Şekil 3.11: Doğrusal Ayrılmayan Doğrusal Olarak Ayrılabilen Veriler……..…….23

Şekil 4.1: DT-CWT Kullanarak YSA ile Diastolik Kan Basıncı Tahmini……..……..…28

Şekil 4.2: DT-CWT Kullanarak YSA ile Sistolik Kan Basıncı Tahmini…….……...29

Şekil 4.3: DT-CWT Kullanarak YSA ile Kalp Hızı Tahmini……..……..29

Şekil 4.4: DT-CWT Kullanarak RO ile Diastolik Kan Basıncı Tahmini…….…...……...30

Şekil 4.5: DT-CWT Kullanarak RO ile Sistolik Kan Basıncı Tahmini…….…..…….30

Şekil 4.6: DT-CWT Kullanarak RO ile Kalp Hızı Tahmini……...…..…….31

Şekil 4.7: DT-CWT Kullanarak DVM ile Diastolik Kan Basıncı Tahmini…….….31

Şekil 4.8: DT-CWT Kullanarak DVM ile Sistolik Kan Basıncı Tahmini……32

Şekil 4.9: DT-CWT Kullanarak DVM Kalp Hızı Tahmini……..32

Şekil 4.10: TQWT Kullanarak YSA ile Diastolik Kan Basıncı Tahmini……35

Şekil 4.11: TQWT Kullanarak YSA ile Sistolik Kan Basıncı Tahmini…….35

Şekil 4.12: TQWT Kullanarak YSA ile Kalp Hızı Tahmini……..36

Şekil 4.13: TQWT Kullanarak RO ile Diastolik Kan Basıncı Tahmini……..36

Şekil 4.14: TQWT Kullanarak RO ile Sistolik Kan Basıncı Tahmini…….….37

Şekil 4.15: TQWT Kullanarak RO ile Kalp Hızı Tahmini…….…….....37

Şekil 4.16: TQWT Kullanarak DVM ile Diastolik Kan Basıncı Tahmini……..38

Şekil 4.17: TQWT Kullanarak DVM ile Sistolik Kan Basıncı Tahmini…..……..…38

Şekil 4.18: TQWT Kullanarak DVM ile Kalp Hızı Yaklaşım Tahmini….……..39

TABLO LİSTESİ

Sayfa No

Tablo 2.1: Yetişkinler için Kan Basıncının Gruplandırılması ….....….5

Tablo 4.1: DT-CWT ile Diastolik Kan Basıncı Hata Değerlerinin Karşılaştırılması……...33

Tablo 4.2: DT-CWT ile Sistolik Kan Basıncı Hata Değerlerinin Karşılaştırılması…….....33

Tablo 4.3: DT-CWT ile Kalp Hızı Hata Değerlerinin Karşılaştırılması…….....34

Tablo 4.4: TQWT ile Diastolik Kan Basıncı Hata Değerlerinin Karşılaştırılması…….....39

Tablo 4.5: TQWT ile Sistolik Kan Basıncı Hata Değerlerinin Karşılaştırılması….....40

Tablo 4.6: TQWT ile Kalp Hızı Hata Değerlerinin Karşılaştırılması…….....40

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
N	: Örnek Sayısı
s	: Standart Sapma
ϕ	: Birikimli Dağılım Fonksiyonu
Ø	: Çap
μ	: Ortalama
T	: Periyot

Kısaltmalar	Açıklama
DT-CWT	: Çift Ağaçlı Karmaşık Dalgacık Dönüşümü
DVM	: Destek Vektör Makinaları
FFT	: Fast Fourier Transform
PSG	: Polisomnografi
PPG	: Fotopletismografi
RO	: Rastgele Orman
TQWT	: Ayarlanabilir Q-Faktör Dalgacık Dönüşümü
YSA	: Yapay Sinir Ağları
KK	: Korelasyon Katsayısı
OMH	: Ortalama Mutlak Hata
KOKH	: Kök Ortalama Kare Hata

ÖZET

YÜKSEK LİSANS TEZİ

FOTOPLETİSMOGRAFİ SİNYALLERİ KULLANILARAK KALP HIZI VE KAN BASINCI TESPİTİ

Fatma Sevde KÖKLÜKAYA

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman : Dr. Öğr. Üyesi Mahmut ÖZTÜRK

Bu tez çalışmasında Photoplethysmography (PPG) sinyalleri kullanılarak sistolik ve diastolik kan basınçları ile kalp atış hızı değişimlerinin tahmin edilmesi amaçlanmıştır. PPG sinyalleri ile kan basıncı ve kalp hızı bilgileri, 219 kişiye ait sinyal ve bilgileri içeren bir açık veri tabanından elde edilmiştir. PPG sinyallerine, Ayarlanabilir Q-faktör Dalgacık Dönüşümü (TQWT) ve Çift Ağaçlı Karmaşık Dalgacık Dönüşümü (DT-CWT) yöntemleri ayrı ayrı uygulanmış ve MATLAB 2019 yardımıyla her bir alt bandın katsayılarının ortalama gücü, mutlak değer ortalaması, çarpıklığı, basıklığı ve katsayıların standart sapması gibi özellikleri tespit edilmiştir. Özellikleri çıkartılan PPG sinyallerine, Weka yazılım programında Yapay Sinir Ağları (YSA), Rasgele Orman (RO) ve Destek Vektör Makinaları (DVM) algoritmaları uygulanarak regresyon analizi yapılmış ve kan basıncı seviyeleri ile kalp atış hızları tahmin edilmiştir. Regresyon analizi sonucunda korelasyon katsayısı daha yüksek ve ortalama hata payı daha düşük olan kan basıncı ve kalp atış hızı tahminleri, TQWT yöntemine RO algoritması uygulandığında elde edilmiştir. Bu nedenle TQWT yöntemine RO algoritması uygulanarak PPG sinyallerinden kan basıncı seviyeleri ile kalp atış hızları tahmini yapılmasının daha uygun olduğu görülmüştür.

Temmuz 2021, 67 sayfa.

Anahtar kelimeler: Fotopletismografi, Dalgacık Dönüşümü, Makine Öğrenmesi, Kan Basıncı, Kalp Atış Hızı

SUMMARY

DETECTION OF HEART RATE AND BLOOD PRESSURE USING PHOTOPLETHYSMOGRAPHY SIGNALS

M.Sc. THESIS

Fatma Sevde KÖKLÜKAYA

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Electrical and Electronic Engineering

Supervisor : Assist. Prof. Dr. Mahmut ÖZTÜRK

In this research, it was aimed to predict systolic and diastolic blood pressure and heart rate changes by using Photoplethysmography (PPG) signals. PPG signals with blood pressure and heart rate information were obtained from an open database containing signals and information of 219 people. Tunable Q-factor Wavelet Transform (TQWT) and Dual-Tree Complex Wavelet Transform (DT-CWT) methods are applied separately to PPG signals and with the help of MATLAB 2019, the average power, mean absolute deviation, skewness, kurtosis and standard deviation coefficients of each subband were determined. Regression analysis was performed by applying Artificial Neural Networks (ANN), Random Forest (RF) and Support Vector Machines (SVM) algorithms to PPG signals whose characteristics were determined and blood pressure levels and heart rates were estimated. As a result of the regression analysis, blood pressure and heart rate predictions with higher correlation coefficient and lower margin of error

were obtained when the RF algorithm was applied to the TQWT method. For this reason, it was found that it is more appropriate to estimate blood pressure levels and heart rate from PPG signals by applying RF algorithm to TQWT method.

July 2021, 67 pages.

Keywords: Photoplethysmography, Wavelet Transform, Machine Learning, Blood Pressure, Heart Rate

1. GİRİŞ

Günümüzde gelişen biyomedikal cihaz teknolojisi ile hastalıkların teşhisi ve izlenmesi için gerekli ölçümler hastaları rahatsız etmeden, cerrahi işlem gerektirmeden, kolayca yapılabilmektedir. Kalp atış hızı ve kan basıncı gibi ölçümler için kullanılan Fotopletismografi (PPG) olarak adlandırılan optiksel ölçüm yöntemi günümüzde sık kullanılan yöntemler arasında yer almaktadır [1]. Hertzman ve diğ. [2] ilk kez 1937 yılında PPG ölçüm tekniğini tanıtmıştır.

Fotopletismografi işaretleri, özellikle damar hastalıklarının araştırılması ve incelenmesinde, kullanımının kolay, maliyetinin düşük olması sayesinde sıklıkla kullanılmaktadır [3]. Son yıllarda PPG sinyali kullanılarak yapılan bilimsel çalışmalarda, bu sinyallerden kan basıncı, solunum kullanılmıştır. Fakat günümüzde devam eden çalışmalar sayesinde PPG sinyallerinin içerisinde kişiye ait çok sayıda fizyolojik parametreyi barındırdığı tespit edilmiştir [7]. Literatürde bu sinyalin birçok özelliği üzerine çalışmalar yapılmıştır. Bu özelliklerden bazıları; PPG darbe sayısı, nabız geçiş süresi, işaret yükselme zamanı, genlik, normalleştirilmiş PPG darbe şekli, darbe genişliği ve yüksekliği olarak incelenmiştir [8]. PPG sinyalleri literatürde birçok araştırmaya konu olmuştur. Bu çalışmalardan en temeli PPG sinyalleri kullanılarak nabzın tespit edilmesidir. Shin H. S. ve diğ. [9] adaptif eşik metodunu geliştirerek PPG piklerini tespit etmişlerdir. PPG sinyallerinin sistolik ve diastolik olarak iki adet tepe noktası bulunmaktadır [10]. Sistolik tepesi kalbin kanı vücuda pompaladığı anı, diastolik tepesi ise aort kapakçıklarının kapanma anını göstermektedir [11]. Bu durum dikkate alındığında sadece sistolik tepelerin bulunması ile pikler belirlenebilmektedir. Shin H. S. ve diğ. [7] yaptığı çalışmada adaptif eşik değeri belirlenerek PPG'ye ait sistolik tepeler tespit edilmiştir.

Johnston [12] tarafından yapılan bir çalışmada PPG işaretinden arteriyel oksijen satürasyonu, kalp hızı (HR), kalp hızı değişkenliği (HRV) ve solunum sayısını belirleyip tahmin eden metotlar araştırılmıştır. Fotopletismografi sinyallerinin ölçülmesi esnasında karşılaşılan öncelikli sorun, hastanın hareket etmesi veya benzeri bir nedenle sensöre olan temasının bozulması sonucu sinyale gürültü eklenmesidir. Hastanın istemli veya istemsiz hareketinden kaynaklanan gürültü hareket artefaktı (motion artifact) olarak adlandırılır. Hareket artefaktı tespitinin yapılması ve temizlenmesi için literatürde; Diab ve diğ. [15] Filtre transfer

fonksiyonunu dinamik olarak değiştirerek, sinyalin frekans bandındaki istenmeyen bileşenleri azaltmak için bir adaptif gürültü filtresi tekniği uygulamıştır.

Kim ve Yoo [11], hareket artefaktlarını en aza indirmek amacıyla blok serpiştirme ve Bağımsız Bileşen Analizi (ICA) olarak adlandırılan algoritma önermişlerdir.

Frekans alanı tabanlı ICA Krishnan ve diğ. [17] tarafından önerilmiştir. Salehizadeh ve diğ. [18] tekil spektrum analizi (SSA) tekniğini kullanarak bir hareket artifacti çıkarma algoritması geliştirmişlerdir.

Murray ve Foster [19], 1996 yılında PPG sinyalini kullanarak sinyali tanımlamak için fizyolojik parametre çıkarma yöntemleri üzerine çalışmalar yapmışlardır.

Şentürk Ü.ve diğ. [20] EKG ve PPG sinyallerini kullanarak her kalp atımı için, EKG ve PPG sinyallerinden 22 zaman domeni öznitelikleri çıkartılarak Lavenberg-Marquardt Yapay Sinir Ağları (LM-YSA) modeline giriş olarak verilerek, sistolik kan basınç ve diastolik kan basınç değerlerini tespit etmişlerdir. Suzuki T. ve diğ. [21] kalp atımının belirlenmesi için PPG sinyalleri kullanıp, kalp atımındaki düzensizliği tespit eden çalışma yürütmüşlerdir. Yapılan bir başka çalışmada Pham T. D. ve diğ. [22] PPG sinyalleri üzerinden mental bozuklukların tespitini yapabildikleri bir çalışma gerçekleştirmişlerdir. Kan şekeri ölçümü kişilerden kan alınarak gerçekleşir. Bu işlem sürekli tekrarlandığında zahmetli ve zor bir yöntem olduğundan dolayı Arnold M. A. [23] Non-invazif ölçüm yapılabilen PPG teknolojisini kullanarak kan şekerini ölçmek üzerine çalışmalar yapmıştır. Lazaro ve diğ. [24] PPG sinyalinin genlik dalgalanmalarındaki azalmasını ve nabız hızı değişkenliğini kullanarak %86.67 doğrulukta apneli olan ve olmayan bölgeleri belirlemiştir. Kavsaoğlu ve diğ. [25] temassız PPG sinyalleri ile biyometrik tanımaya yönelik bir çalışma gerçekleştirmişlerdir. Eş zamanlı elde edilen temaslı ve temassız PPG sinyallerinden 15 öznitelik çıkartılmıştır. PPG sinyalleri ile biyometrik tanımaya yönelik performanslarını karşılaştırmak için K-En Yakın Komşu sınıflama algoritmasını kullanmışlardır. Temaslı PPG sinyallerinde %99.33 tanımlama başarısı elde edilirken temassız PPG sinyalleri ile %84.66 tanımlama başarısı elde edilmiştir. Elde edilen sonuçlar temassız PPG sinyallerinin biyometrik tanıma amaçlı kullanılabilirliğini kanıtlamıştır. Koç ve diğ. [26] akıllı telefon kamerası ile alınan video kayıtlarından görüntü işleme tekniklerini kullanarak elde edilen fotopletismografi sinyali ile kalp hızını tespit etmişlerdir. Korkmaz ve Aydemir [27], PPG verilerinden öznitelikler çıkartılarak kişilerin sigara tüketimleri, açlık durumları ve cinsiyetleri belirlenmeye çalışılmıştır. Çıkartılan öznitelikler K-En Yakın Komşu yöntemi ile sınıflandırılmıştır. Sigara kullanımı, cinsiyeti ve açlık durumlarını

tespiti sırasıyla ortalama %73.7, %72.8 ve %65.8 oranında bir doğrulukla sınıflandırılmıştır. Bu tez çalışmasında, yaşları 21 ile 86 arasında değişen 104 erkek ve 115 kadından oluşan toplam 219 kişiden alınan PPG sinyalleri kullanılarak sistolik ve diastolik kan basınçları ile kalp atış hızı değişimleri tahmin edilmeye çalışılmıştır. Kan basıncının ve kalp atış hızının tahmin edilmesinde dalgacık dönüşümünün Ayarlanabilir Q-faktör Dalgacık Dönüşümü (TQWT) ve Çift Ağaçlı Karmaşık Dalgacık Dönüşümü (DT-CWT) gibi farklı yöntemler kullanılarak Weka yazılım programı aracılığıyla Yapay Sinir Ağları (YSA), Rastgele Orman (RO) ve Destek Vektör Makinaları (DVM) algoritmaları kullanılarak analiz edilmiş ve kan basıncı seviyeleri belirlenmiştir.

2. GENEL KISIMLAR

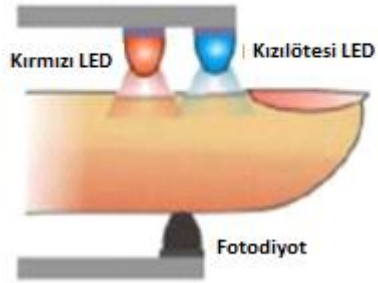
2.1. PPG ELDE EDİLMESİ

PPG sinyali parmak ucu, kulak memesi gibi kılcal damarların çok olduğu bölgelerden ölçülebildiği gibi bilek üzerinden de ölçüm alınabilmektedir. Bu ölçüm sırasında algılayıcı kısmında verici olarak belli bir dalgaboyunda ışık yayan LED ve alıcı olarak da kullanılan bu dalgaboyuna duyarlı bir fotodiyot kullanılmaktadır [7].

PPG sinyali elde edilirken, genellikle biyolojik dokuya yayılan monokromatik ışığı almak için bir fotodedektör kullanılmaktadır [28]. PPG parmak ucu, ayak parmağı, alın ve kulak memesi gibi çıkıntılardan ölçülmektedir [3, 13, 14].

Fotopletismografi sinyalleri vücut dışından özellikle parmaktan veya kulaktan alındığı için elde edilebilmesi ve işlenmesi geleneksel tıbbi yöntemlere göre daha hızlı, ağrısız ve pratiktir [29].

Parmaktan ölçüm yapılırken, parmağın bir tarafına kızıl ötesi ışık tutulup ve diğer tarafına ışığı yakalayacak fotodedektör yerleştirilmektedir [30]. PPG sinyalinin ölçümü Şekil 2.1'de gösterilmiştir [31].



Şekil 2.1:PPG işareti ölçümü [31].

2.2. KAN BASINCI SEVİYELERİ

Hipertansiyon, arteriyel kan basıncının normal değerlerin üstüne çıkması durumuna denir. Hipertansiyon sayılması gereken kan basıncı değerleri hakkında tartışmalar sürse de günümüzde sistolik kan basıncının 140 mmHg, diastolik kan basıncının da 90 mHg veya

üzerinde bulunması veya bireyin antihipertansif ilaç kullanıyor olması hipertansiyon şeklinde ifade edilmektedir.

Yetişkin bir bireyde kan basıncı düzeyinin sınıflandırılması niteldir. Ancak, uygulamada doktorların kolaylıkla tanı ve tedaviyi gerçekleştirebilmeleri için kan basıncı değerlerinin dikkate alınması önemlidir.

Kan basıncı düzeylerine göre sınıflandırma: 18 yaş ve üzerindeki yetişkin bireylerin kan basınçları optimal, normal, yüksek-normal ve hipertansiyon olarak dört gruba bölünmüştür (Tablo 2.1). Tablo 2.1'e göre optimal kan basıncı değeri 120/80 mmHg'dan düşüktür. Normal kan basıncı ise 135/85 mmHg değerinden düşük olarak verilmiştir. Yüksek-normal tansyionda kan basıncı seviyesi 130-139/85-89 mmHg iken, hipertansiyonda kan değerleri bu değerin yukarısındaki değerler olarak kabul edilmektedir. Bir yetişkin bireye hipertansiyon tanısı koymak için iki veya daha çok muayene ve ölçümlerin ortalama değerine bakılmalıdır. İlave olarak, hipertansiyon kendi içerisinde kan basıncı düzeylerine göre üç gruba ayrılmıştır [32].

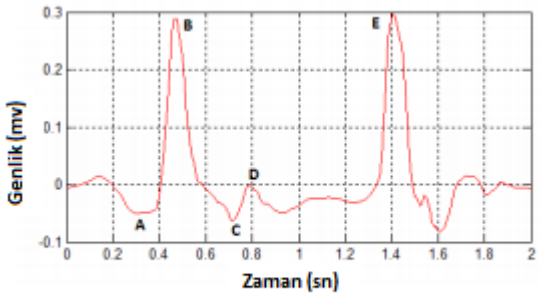
Tablo 2.1: Yetişkinler için Kan Basıncının Gruplandırılması [32].

Kan Basıncı Derecesi	**Sistolik Kan Basıncı**		**Diastolik Kan Basıncı**
Optimal	< 120	ve	<80
Normal	<130	ve	< 85
Yüksek-Normal	130-139	veya	85-89
Hipertansiyon			
Evre 1	140-159	veya	90-99
Evre 2	160-179	veya	100-109
Evre 3	≥180	veya	≥110
İzole sistolik hipertansiyon	140-160		< 90
İzole sistolik hipertansiyon (sınırda)	≥160		< 90

Bu gruplandırma, antihipertansif ilaç almayan ve akut olarak hasta olmayanlar için kullanılır. Gruplandırmada sistolik ve diastolik kan basınçları farklı gruplara düşerse, kişinin kan basıncı durumuna karar vermek için daha yüksek olan kan basıncı değeri dikkate alınmaktadır. Örneğin; 160/92 mmHg evre 2 hipertansiyon ve 174/120 mm Hg da evre 3 hipertansiyon olarak gruplandırılır. Sistolik kan basıncı 140-160 mmHg, diastolik kan basıncı da 90 mmHg değerinden düşük ise sınırda izole sistolik hipertansiyondan, sistolik kan basıncı 160 mmHg ve üzerinde diastolik kan basıncı 90 mmHg değerinden düşük olduğu zaman da izole sistolik hipertansiyondan bahsedilir [32].

2.3. KALP ATIŞ HIZI (NABIZ)

Kalp atış hızı(nabız), insan vücudunun fizyolojik durumu hakkında bilgi veren önemli sinyallerdendir. Örnek olarak dinlenme halindeki nabız değeri kalp hastalığı için önemli bir belirleyici olarak tespit edilmiştir [33]. Bu yüzden nabız ölçümü oldukça önemlidir. EKG (Elektrokardiyogram) sinyaline alternatif olarak PPG sinyali ile nabız ölçümü sağlanmaktadır. PPG sinyali kalbin periyodik atımı ile oluşturulmaktadır. Şekil 2.2'de normal bir PPG sinyali ve özellik noktaları belirtilmektedir. Bir PPG sinyalinde A noktasından B noktasına kadar olan bölge hızlı atım ve B noktasından C noktasına kadar olan bölge gecikme kısmını göstermektedir. B olarak belirtilen nokta PPG sinyalinin temel tepe noktasıdır. Bu değerde kan basıncı (BP) değeri tüm periyottaki en büyük büyüklüğe ulaşır. İkinci tepe D noktası ,atar damarın uyumunu yansıtan dikrotik dalgasıdır. C noktası dikrotik çentik olarak adlandırılır. Kalp hızı iki ana tepe arası (B-E) süreden (TPP) elde edilmektedir. B-D zaman aralığı arterioskleroz'un (damar sertliğinin) bir indeksidir fakat çeşitli etkenlerden dolayı, gerçek PPG sinyalinin özellik noktalarını direkt olarak belirlemek güçtür. Bu yüzden PPG sinyalini en doğru şekilde tespit edebilmek için bilgi çıkartma ve ön işleme yöntemleri bulmak gerekmektedir [34].



Şekil 2.2: Standart PPG Sinyali ve Özellik Noktaları [35].

Standart PPG sinyali kullanılarak dakikadaki vuruş sayısına göre nabız değeri denklem 2.1'deki gibi hesaplanır [31]:

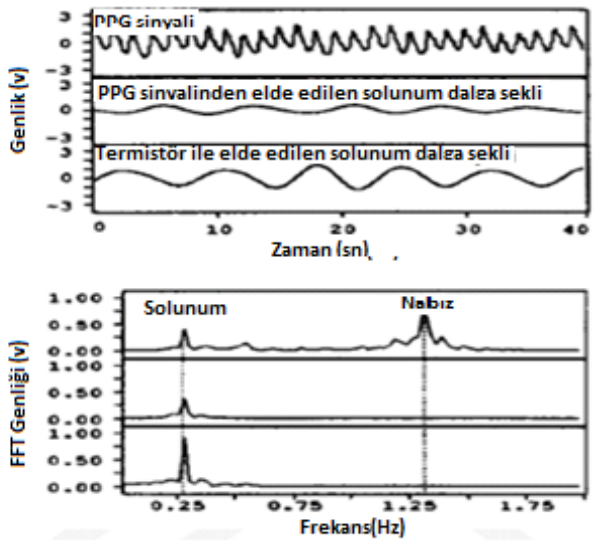
$$\text{Nabız}=[(N \times 60) / T] \text{ bpm} \quad (2.1)$$

Bu denklemdeki N bir periyottaki vuruş sayısını T ise periyodu ifade eder.

Standart bir PPG sinyali deri kas ve kemikten geçen büyük bir DC bileşenden ve deri, kas ve kemikten ayrıldıktan sonra doğrudan kan damarlarından geçen küçük bir AC bileşenden oluşur. Fakat kişiye ait önemli özellik içeren bu AC bileşenin etkisi sinyalde çok küçüktür. Bu sebeple bir yükseltgeç devresi sayesinde AC sinyalden istenen bilginin çıkartılması sağlanmaktadır. Bu amaçla sinyaldeki DC bileşenin azaltılıp AC bileşenin kuvvetlendirilmesi gerekmektedir. Tipik bir Sinyalin %99'u deri, kas ve kemikten, %0,9'u toplardamardan, %0,1'i atardamarlardan gelir. Kalp kasının kasılmasının hemen ardından arterlerdeki kan miktarı çoğalır ve alınan ışık şiddeti de azalır. Kalp kasının gevşemesi boyunca arterlerdeki kan miktarı düşer ve ışık şiddetinde çoğalma görülür [28].

2.4. SOLUNUM SİNYALİ TAKİBİ

PPG sinyalleri incelendiğinde, içerisinde solunum sinyalinin bulunduğu görülmüştür. Şekil 2.3'de gösterildiği gibi yapılan çalışmada PPG sinyallerine Hızlı Fourier dönüşümü (FFT) dönüşümü uygulandıktan sonra nabız ve solunum olmak üzere iki adet biyolojik sinyal elde edilmiştir [36]. Solunum sinyali genel olarak incelendiğinde sinüs sinyali ile benzerlik göstermektedir. Bu bilgiler doğrultusunda PPG sinyalinden elde edilen solunum sinyali, termistör aracılığıyla elde edilen solunum sinyali ile benzerliği görülmüştür [7].



Şekil 2.3: PPG Sinyalinden Solunum Bilgisinin Çıkartılması [36].

2.5. UYKU APNESİ TESPİTİ

Uyku apnesi solunumun uyku sırasında ani bir şekilde durmasından kaynaklanan önemli bir hastalıktır. Yaygın olarak Polismonografi (PSG) ile belirlenir. PSG laboratuvar ortamında elde edilen, uyku apne sendromu tanısında altın standardı oluşturmaktadır ve uykuda solunum bozukluklarının teşhisinde önemli bir yere sahiptir [37,38]. Fakat PSG zor ve pahalı bir yöntemdir. Bunun yerine hastadan PPG sinyalleri alınarak işlem daha kolay ve hızlı şekilde yapılabilmektedir.

2.6. KANDAKİ OKSİJEN SATÜRASYONU ÖLÇÜMÜ

Kandaki oksijen satürasyonu, tüm kan hacmindeki toplam oksijen kapasitesininin yüzdesini ve azalan hemoglobin ile birleştirilen oksijen kapasitesinin yüzdesini belirten insan vücudunun önemli bir göstergesidir. Birçok klinik hastalık, hücrelerin normal metabolizmasını doğrudan etkileyecek ve insan vücudunun sağlığına zarar verecek olan oksijen kaynağı eksikliğinden ortaya çıkar [39].

Oksijen saturasyonu Puls Oksimetre kullanılarak ölçülür. Kan oksijen saturasyonu değerini temassız olarak ölçebilen puls oksimetre cihazlarında PPG teknolojisini kullanılmaktadır [7]. Bu sayede kandaki oksijen satürasyonu rahat, kolay ve ucuz bir şekilde ölçülebilmektedir.

3. MALZEME VE YÖNTEM

PPG sinyallerinden kan basıncı ve kalp atış hızının elde edilmesinde iki aşamada yapılan bu çalışmanın ilk aşamasında, dalgacık dönüşümünün Ayarlanabilir Q-faktör Dalgacık Dönüşümü (TQWT) ve Çift Ağaçlı Karmaşık Dalgacık Dönüşümü (DT-CWT) gibi yöntemleri kullanılarak MATLAB 2019'da bazı özellikleri çıkartılmıştır. İkinci aşamada, özellikleri belirlenen PPG sinyallerinin, Yapay Sinir Ağları (YSA), Rasgele Orman (RO) ve Destek Vektör Makinaları (DVM) algoritmaları kullanılarak WEKA programı üzerinden regresyon analizi yapılmıştır.

3.1. DALGACIK DÖNÜŞÜMÜ

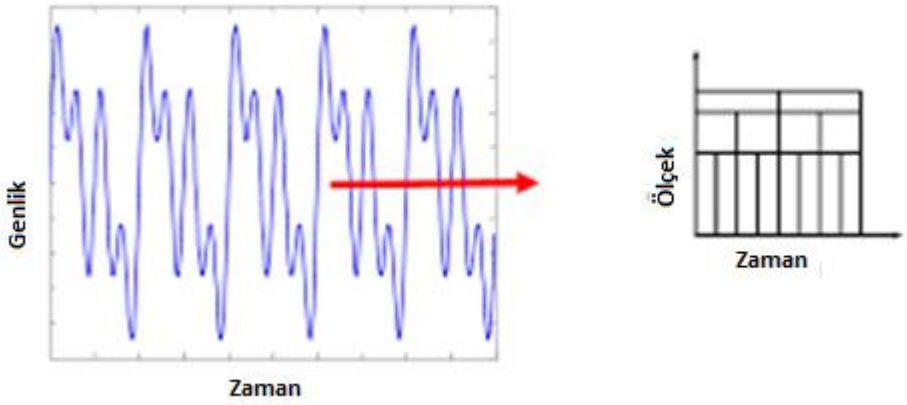
Wavelet (Dalgacık) dönüşümü, bir işaretin zaman-frekans analizinde kullanılan bir dönüşüm şeklidir. Yapılan çalışmalar ile dalgacık analizinin çok çeşitli sinyal tiplerine uygulanabilir olduğu görülmüştür [40,41].

İlk olarak A.Haar'ın çalışmasının bir bölümünde Dalgacık Dönüşümü kavramından söz edilmiştir. Daha sonra Dalgacık Dönüşümü kavramı Grossman ve Morlet tarafından tanımlanmıştır. Grossman ve Morlet'in çalışmalarının amacı; sismik sinyallerin salınan sonlu süreli basit bir fonksiyonun ötelenmiş ve ölçeklendirilmiş hallerinin birleşimi şeklinde ifade edilebileceğinin kanıtlanmasıdır. Bu çalışmaların ışığında, Sürekli Dalgacık Dönüşümü ortaya çıkarılmıştır. Yine 1985 yılında Stephane Mallat sayısal sinyal işleme ile ilgili Dalgacık Dönüşümü üzerine araştırmalar yapmış ve bu araştırmalar günümüzdeki pek çok uygulama ve araştırmanın temelini oluşturmuştur. Daha sonra günümüz Dalgacık uygulamalarında sıklıkla kullanılan Dalgacık orthonormal baz fonksiyon takımı Ingrid Daubechies tarafından geliştirilmiştir [42].

Süreksiz sinyallerin tanısında (örnek olarak kalp grafiklerinin yorumlanması) ve sinyalden gürültü çıkarmada dalgacık dönüşümünden faydalanılmıştır [43].

Dalgacık dönüşümü isminden de anlaşıldığı üzere dalgacıklar yardımı ile gerçekleşmektedir. Dalgacık dönüşümü kısa zamanlı Fourier dönüşümüne benzer şekilde gerçekleşirken; pencere görevini ana dalgacık diye adlandırılan bir fonksiyon gerçekleştirir, ancak bu ana dalgacık, dönüşüm işlemi sürecinde hem ölçeklenir hem de ötelenir. Öteleme, zaman ekseninde dalganın kaydırılması iken ölçekleme ise dalganın daraltılıp genişletilmesine karşılık gelir [44].

Dalgacık Dönüşümü'nün sağladığı en büyük avantaj yüksek frekanslar için dar, düşük frekanslar için geniş pencere boyutlarına sahip olmasıdır. Böylece, bütün frekans aralıklarında optimum zaman-frekans çözünürlüğüne ulaşılmaktadır [45,46]. Şekil 3.1 dalgacık dönüşümü ile sinyalde ölçek ve zaman değişimini ifade etmektedir.



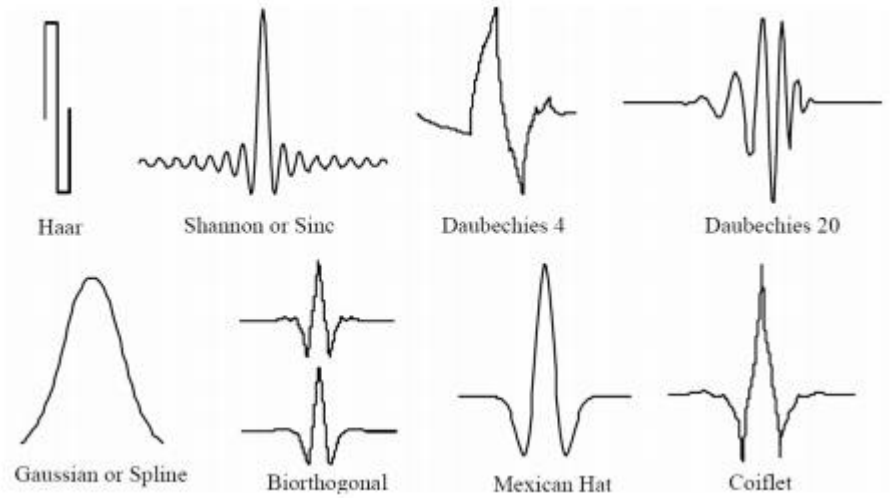
Şekil 3.1: Dalgacık Dönüşümü [47].

Dalgacık kelimesi, küçük dalga anlamında dalgacık olarak tanımlanır. Bahsedilen küçüklük belli uzunlukta pencere fonksiyonu olarak ifade edilmektedir. Ana kelimesi ise bir ana fonksiyondan dönüşüm tekniği ile üretilp değişik alanları desteklemek için oluşturulan fonksiyonlardır. Başka deyişle ana dalgacık bir modeldir. Dalgacık özellik bakımından değerlendirilecek olursa aşağıda verilen denklem 3.1 ve 3.2'deki gibi iki koşulu sağlayan bir gerçek değerli $\psi(x)$fonksiyonu olması gerekir [47].

$$\int_{-\infty}^{\infty} \psi(x)dx = 0 \tag{3.1}$$

$$\left(\int_{-\infty}^{\infty} \psi^2(x)dx\right) = 1 \tag{3.2}$$

Bazı örnek dalgacıklar Şekil 3.2'de gösterilmiştir.



Şekil 3.2: Örnek Dalgacık Şekilleri [48].

Dalgacık dönüşümündeki başlıca amaç, bir f işaretini ψ_i fonksiyonuna bağlı olarak bileşenlerine ayırmaktır [49]. İşaret elde edilirken fonksiyon ölçekleme katsayısı ile çarpılır ve çarpımlar toplanır [50].

$$f = \sum_i a_i \psi_i \tag{3.3}$$

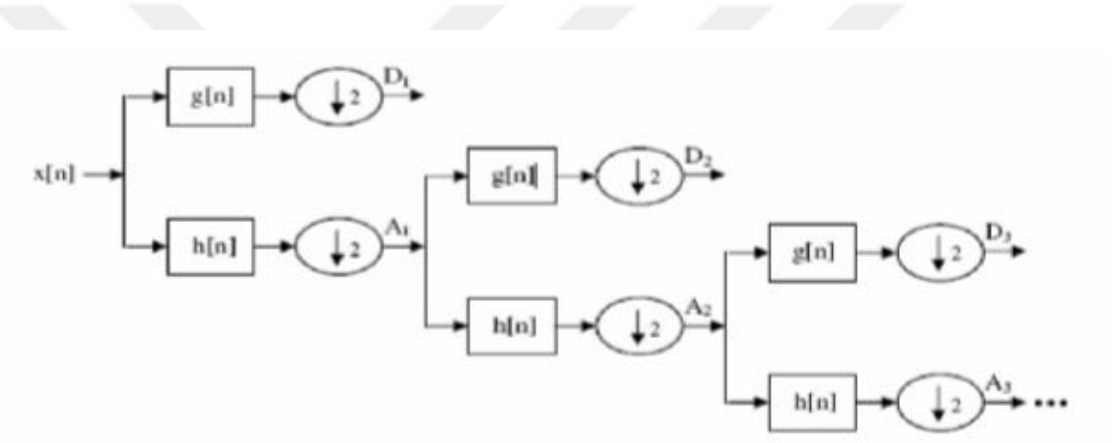
a_i: ölçekleme katsayısı, ψ_i : ana dalgacık fonksiyonunu göstermektedir.
Wavelet (dalgacık) dönüşümünde ölçek katsayısı 'a' ile ifade edilir ve doğrudan frekansa bağlıdır. Büyük ölçekler düşük frekanslara, küçük ölçekler de yüksek frekanslara denk gelirler. Dalgacık dönüşümü ile işaret analizi yapılırken kullanılan ölçek küçük değerde ise üzerinde çalışılan işarette bulunan yüksek frekanslı bileşenler daha kolay ayırt edilebilirler. Aynı zamanda ölçek büyük alındığında düşük frekanslı işaretler daha kolay ayırt edilebilecektir [47].

Ana dalgacık fonksiyonu yüksek geçiren (h[n]) ve alçak geçiren (g[n]) filtrelerden geçirilerek işaretin yüksek frekanslı bölgeleri ve alçak frekanslı bölgeleri belirlenmiş olur. Sonraki adım için önceden elde edilmiş alçak frekanslı bölge alınır ve filtreleme işlemi tekrar uygulanır. Bu süreç önceden belirlenmiş bir seviyeye gelinceye kadar tekrar edilir. Bu işleme ayrışım (decomposition) adı verilmektedir. Bu işlemlerin sonucunda girdi verisi yüksek ve alçak frekanslı bileşenlerine ayrışmış olur. Filtrelerin matematiksel gösterimi denklem 3.4 ve 3.5' te ifade edilmiştir [51].

$$Y_{alçak}[n] = \sum_{-\infty}^{\infty} x[k].g[2n-k] \quad (3.4)$$

$$Y_{yüksek}[n] = \sum_{-\infty}^{\infty} x[k].h[2n-k] \quad (3.5)$$

Sonuç olarak ayrışım işlemi sonunda frekans grupları elde edilir. Filtreleme işlemi sonucunda yüksek geçiren filtreden elde edilen verilere ayrıntı verileri, alçak geçiren filtreden elde edilen verilere ise yaklaşım verileri denmektedir [51]. Şekil 3.3'te Dalgacık dönüşümüyle işaretin alçak (g[n]) ve yüksek (h[n]) geçiren filtrelerle alt bantlara ayrışımı gösterilmiştir [52].



Şekil 3.3: Ayrık Dalgacık Dönüşümüyle İşaretin Alt Bantlara Ayrışımı [52].

3.1.1 Ayarlanabilir Q-faktör Dalgacık Dönüşümü (TQWT)

PPG gibi durağan olmayan sinyallerin salınımlı yapısından dolayı analiz etmek biraz daha zordur. Q-faktör Dalgacık Dönüşümü salınımlara göre ayarlandığı için bu tür sinyalleri analiz etmekte TQWT büyük fayda sağlamaktadır.

Selesnick tarafından geliştirilen yeni Ayarlanabilir Q-faktör Dalgacık Dönüşümü (TQWT), Dalgacıkları frekans alanında ifade edilen temsili bir dalgacık dönüşümü olarak sonlu uzunluktaki ayrık zaman sinyallerini radix-2 FFT'ler kullanarak analiz edilmektedir[53]. Geleneksel Q sabit dalgacık dönüşümleri ile karşılaştırıldığında, TQWT Q faktörünün kolaylıkla belirlenebildiği ve farklı sinyallerin salınımlarına uyacak şekilde sürekli ayarlanabildiği mükemmel bir özelliğe sahiptir. Bununla birlikte, TQWT tabanlı ayrıştırma

kullanarak başarılı hata özelliği çıkarımı, ayrıştırma seviyesi, Q faktörü ve artıklık gibi uygun TQWT parametrelerine dayanır [54].

Q faktörünün değeri TQWT ile üretilen dalgacıktaki salınımların sayısı ile orantılıdır. Ek olarak dalgacıkların zaman alanında yerelleştirilmesi, TQWT'deki artıklık (R) parametresiyle sağlanır. TQWT, iki kanallı filtre bankası kullanılarak oluşturulmuştur. İki kanallı filtre bankası bir alçak geçiren ve bir yüksek geçiren kanaldan oluşur. Alçak geçişli kanalda bir alçak geçiş filtresi (AGF) ve ardından bir alçak geçiş ölçeklendirme faktörü (AÖF) bulunur. Yüksek geçiren kanalında ise yüksek geçişli bir filtre (YGF) ve ardından yüksek geçişli ölçeklendirme faktörü (YÖF) bulunur. Sinyal aynı anda hem alçak geçiş kanalına hem de yüksek geçiş kanalına giriş olarak uygulanır. Daha sonra, alçak geçiş kanalından gelen bilgi, bir sonraki iki kanal filtre öbeğine bir girdi olarak verilir. Bu şekilde iki kanallı filtre bankası bağlanır. Bu bağlantıda, her iki kanallı filtre bankasının yüksek geçiş kanalından çıkış bir alt bant oluşturur ve filtre bankasının alçak geçiş kanalı da bir alt bant oluşturur. Böylece TQWT'nin frekans cevabında J +1 alt bantları mevcuttur. Birinci alt bant, ilk iki kanal filtre bankasının yüksek geçiş kanalından elde edilir. (J+1). alt bant ise J'inci iki kanallı filtre bankasının alçak geçiş kanalından elde edilir. Her bir alt bandın merkez frekansının (MF) bant genişliğine oranı, TQWT'yi uygulamak için kullanılan Q faktörüne eşittir. Bir alt bandın MF ve bant genişliği aşağıdaki ifadelerden hesaplanabilir [53]:

$$MF(J) = (A\ddot{O}F)^{J}\left[\frac{2-(Y\ddot{O}F)}{4(A\ddot{O}F)}\right] fs \tag{3.6}$$

$$Bant\ geni\text{ş}li\breve{g}i(j) = \frac{(Y\ddot{O}F)(A\ddot{O}F)^{J-1}}{4} \tag{3.7}$$

Denklem 3.6 ve 3.7'den ölçekleme faktörlerinin merkez frekans ve bant genişliğine etkisi gözlemlenmektedir.

Burada j, $1 \leq J \leq J+1$ fs'nin örnekleme frekansı olduğu alt bant numarasını temsil eder. Q faktörü R tarafından kontrol edilir ve bağlantısı denklem 3.8 ve 3.9'da verilmiştir [46].

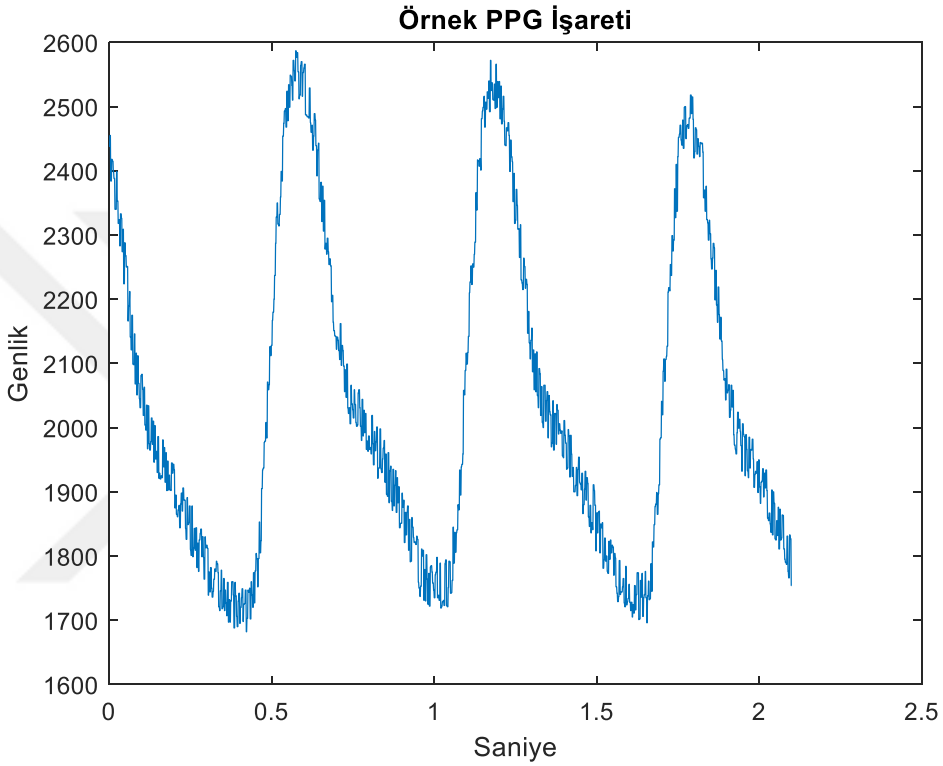
$$A\ddot{O}F = 1 - \frac{Y\ddot{O}F}{R} \tag{3.8}$$

$$Y\ddot{O}F = \frac{2}{Q+1} \tag{3.9}$$

AÖF ve YÖF'nün dürtü tepkisini yerelleştirmek için iki kanallı filtre bankası, ölçek faktörlerinin değeri içinde (0 ile 1 arasında) olmalıdır [53]. Bu nedenle Q faktörü ve R seçimi,

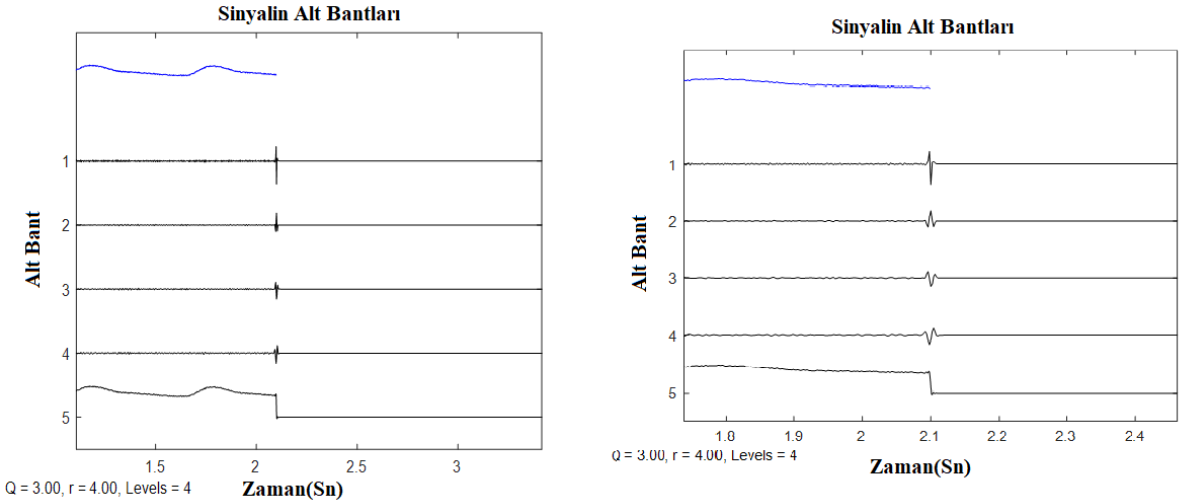
Denklem 3.8 ve 3.9 bu koşulu karşılayacak şekilde olmalıdır.

Hazır dataset'den aldığımız 2.1 saniyelik PPG işareti Şekil 3.4'te verilmiştir [87].



Şekil 3.4: PPG Örneği [87].

Dataset'den [87] alığımız sinyalin TQWT yöntemi uygulanarak alt bantlara ayrışmış hali Şekil 3.5'te verilmiştir.



Şekil 3.5: TQWT ile Alt Bantlara Ayırma

3.1.2. Çift Ağaçlı Karmaşık Dalgacık Dönüşümü (DT-CWT)

Ayrık Dalgacık Dönüşümü (DWT) nin yeni bir çeşidi olan Çift Ağaçlı Karmaşık Dalgacık Dönüşümü (DT-CWT), DWT'nin çeşitli olumsuz taraflarını ortadan kaldırır [55].

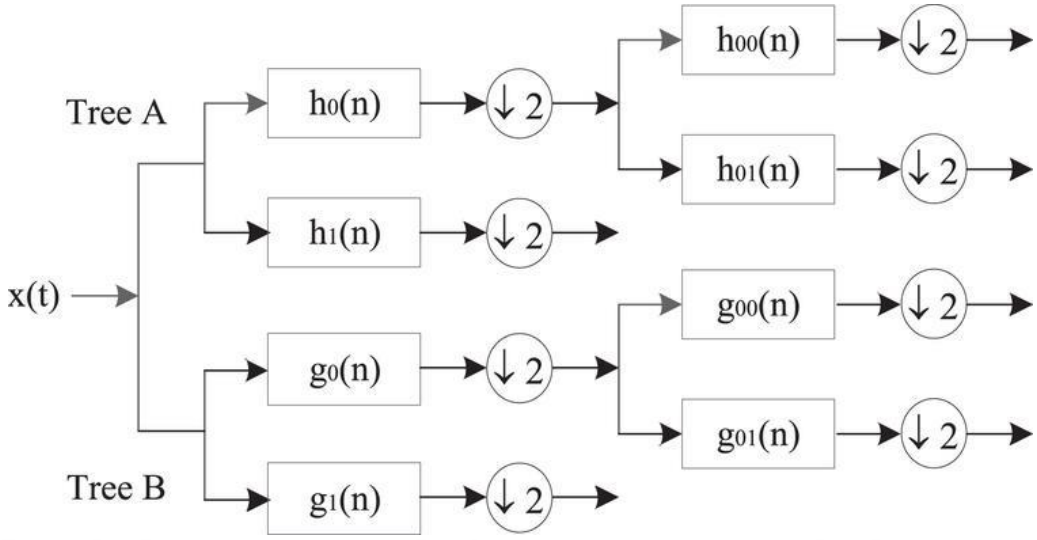
Kingsbury [56] tarafından tanıtılan DT-CWT, gerçek ve sanal parçaları elde etmek için ikili bir dalgacık filtresi ağacı kullanarak karmaşık katsayılar oluşturur. DWT ile karşılaştırıldığında, DT-CWT'nin gelişen özellikleri yaklaşık kayma değişmezliği ve kenar yumuşatmadır [57].

DT-CWT, iki gerçek DWT kullanır. Bir DWT, dönüşümün gerçek kısmını verirken, diğer DWT sanal kısmı verir. Mükemmel yeniden yapılandırma koşullarını sağlamak için Kingsbury, bir ağaçta tek uzunlukta filtreler ve diğer ağaçta çift uzunlukta filtreler olmasını tasarladı. İki filtre seti, genel dönüşüm yaklaşık olarak analitik olacak şekilde ortaklaşa tasarlanmıştır [58].

Kingsbury, denklem 3.10 ile karmaşık bir dalgacık oluşturmayı önerdi.

$$\phi(t) = \phi_h(t) + i\phi_g(t) \tag{3.10}$$

Burada $\phi_h(t)$ gerçek ve çift, $i\phi_g(t)$ sanal ve tek kısımı ifade eder. Diğer bir deyişle $\phi_g(t)$ yaklaşık olarak $\phi_h(t)$'nin Hilbert dönüşümüdür .



Şekil 3.6: Çift Ağaç Karmaşık Dalgacık Dönüşümü Analizi [59].

Şekil 3.6'da gösterilen ikili ağaç karmaşık dalgacık dönüşümü grafiğinde alttaki ağaç, dalgacık katsayısının sanal kısmını verir. Üstteki ağaç ise karmaşık dalgacık katsayısının gerçek kısmını verir.

Ortaya çıkan DT-CWT katsayıları salınımlı değildir. DWT'nin aksine, DT-CWT çok azaltılmış örtüşme, ancak daha fazla yönlülüğe sahiptir. D-boyutlu bir işaretin DT-CWT ayrışmasından ortaya çıkan artıklık faktörü 2^d'dir [60, 61].

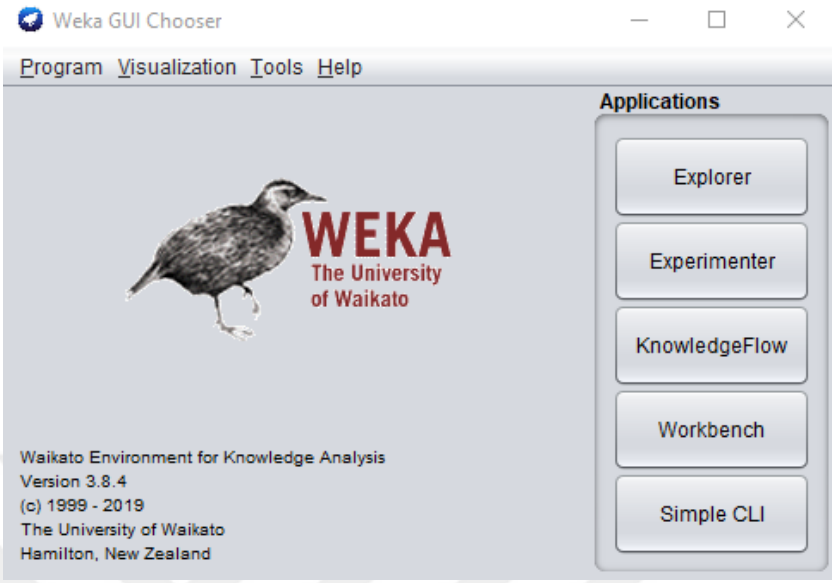
3.2. WEKA YAZILIM

Yeni Zelanda Waikato Üniversitesi tarafından Java programlama dili ile geliştirilmiş WEKA (Waikato Environment for Knowledge Analysis) programı ile son yıllarda birçok çalışma yapılmıştır. Bir makine öğrenme ve veri madenciliği geliştirme programı olan WEKA yazılımı ücretsiz ve açık kaynak kodlu bir kullanıma sahiptir. Bu programın içerisinde pek çok ön işleme yöntemleri, regresyon, sınıflandırma, kümeleme, bağıntı kuralları ve algoritmaları içermektedir [62, 63].

WEKA, istatistiksel, görsel ve grafiksel olarak veri analizi ve iş zekası uygulamalarına imkan tanımaktadır [64].

WEKA programında algoritmalar veri kümesine doğrudan veya dışarıdan Java kodu kullanılarak çalışılabilmektedir [65].

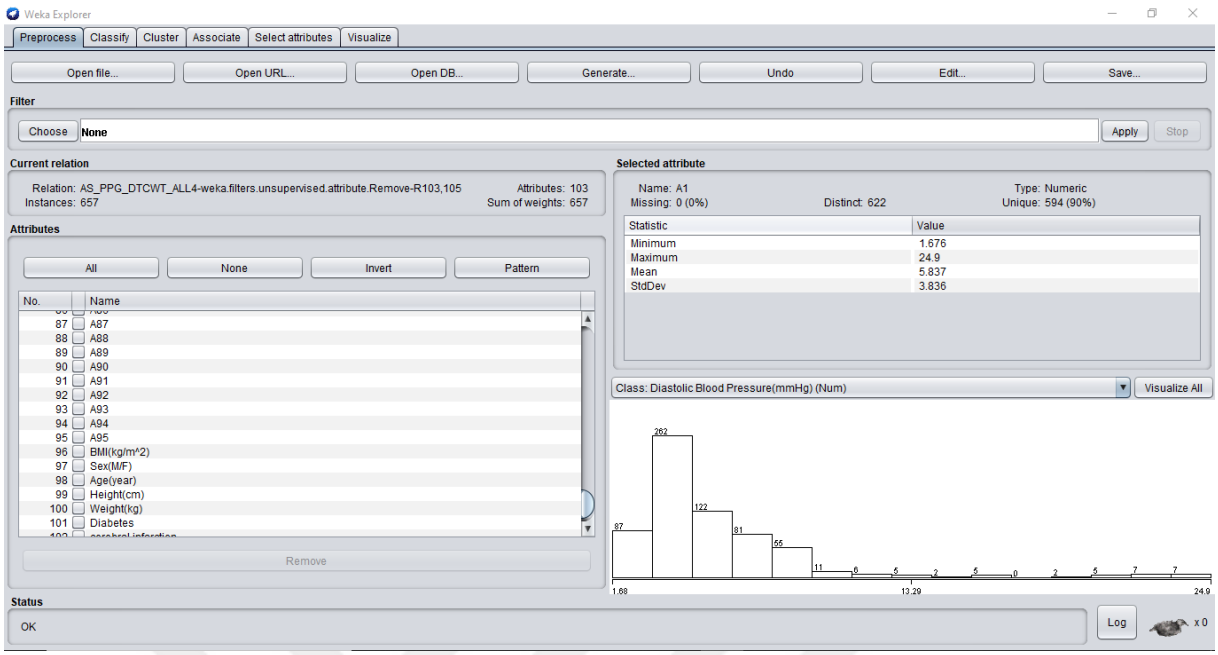
Weka arayüzü Şekil 3.7'te gösterilmektedir.



Şekil 3.7: Weka Başlangıç Arayüzü

Program başlangıç arayüzünde ; "Explorer", "Experimenter", "Knowledge Flow" ve "Simple CLI" butonu şeklinde dört ana bölüm bulunmaktadır. "Explorer", butonu içinde bir veri seti ile çalışılacak uygulamalar mevcuttur [66]. "Experimenter" butonu ise bir veya daha fazla veri setine birden fazla algoritmanın uygulanarak öğrenme şemaları arasında istatistiksel testler yapma işlemlerini barındırmaktadır. "KnowledgeFlow" buton Java-Beans tabanlı makine öğrenmesi uygulamaları sunulmaktadır [67]. Son olarak ara yüzde bulunan "Simple CLI" butonu ise komut ekranı sayesinde komutlar yazılarak işlem yürütmeye yönelik bölümdür [66].

Wekanın işlem yüzü Şekil 3.8'de gösterilmektedir.



Şekil 3.8: Weka İşlem Yüzü

Veri Hazırlama-Önişleme (Preprocess) : Preprocess dosyaların programa aktarıldığı filtre işleminin yapıldığı ve verilerin düzenlendiği işlemlerdir. Veriler 1. dosyadan (Open File), 2. Ağdaki veri tabanı sunucusundan (Open DB), 3. internet veri tabanı üzerinden (Open URL) olmak üzere üç şekilde seçilebilmektedir. Seçilen verilerin WEKA'da işlenebilmesi için WEKA da işlenebilmesi için dosya formatının WEKA'ya uygun olması gerekmektedir. Çalışılan dosya türleri arff, arff.gz, names, data, csv, c45, libsvm, dat, bsi, xrff, xrff.gz, c45 şeklindedir [66].

Sınıflandırma : Sınıflandırma algoritmalarının bulunduğu bölümdür.İşlem yapılacak veri dosyasını sınıflandırmak için kullanılacak sınıflandırma algoritmaları bu seçenek aracılığıyla uygulanır. Bu seçenekte bulunan "Test Options" bölümü; veri dosyasının tamamının (use training set), ayrı bir veri dosyasının (supplied test set), çapraz doğrulama (crossvalidation) ve belli bir yüzdeliğin (percentage split) test için kullanılmasına fırsat tanır. Kullanılan sınıflandırma algoritmasının veri seti üzerindeki performans bilgilerinin gösterimi için "result list" ekranı kullanılarak sınıflandırıcı adı, ortalama mutlak hata, içerdiği örnek sayısı, öznitelik sayısı, doğruluk tablosu, doğru ve yanlış sınıflandırılan örnek sayıları gibi bilgilere ulaşılabilinir. Sınıflandırıcı çıkışında (classifier output) ise çalışma bilgileri, hata matrisi, doğruluk tablosu ve sınıflandırma ile ilgili özet bilgiler gösterilmektedir [68].

Kümeleme : Veri setlerine uygulanacak kümeleme algoritmalarının bulunduğu bölümdür [69].

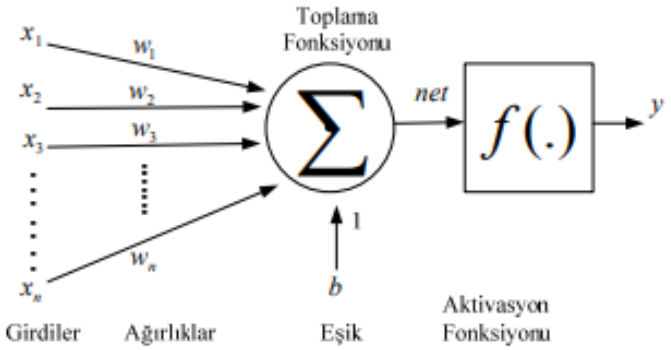
Birleştirme : Veriler hakkında bağlantı kurallarının değerlendirilip öğrenildiği bölümdür [68].

Özellik Seçimi : Bu bölümde öznitelik seçimi yapılmaktadır. Öznitelik seçiminden önce "Attribute Evaluator" ve "Search Method" seçilmelidir. İlk olarak, özniteliklerin her bir alt kümesinin uygunluk düzeyinin kestirilmesi için kullanılacak değerlendirme şekli ve diğeri özniteliklerin arasında nasıl bulanacağını belirler. "Attribute selection mode" bölümünde özniteliklerin değerlendirilmesinde eğitim veri kümesinin nasıl seçileceğini belirlenir. Seçim yapılırken ya tamamı (Use full training set) veya çapraz doğrulama (Cross- Validation) kullanılarak işlem yapılır. Seçilen özniteliklere "Attribute selection output" başlığı altından ulaşılabilir [68].

Visualize : Bu bölümde kullanıcıya bağlı olarak özellik seçilerek görsel inceleme fırsatı sunar [68].

3.3. YAPAY SİNİR AĞLARI (YSA)

YSA: Yapay sinir ağları, insan beyninin keşfedebilme, öğrenme ve yeni bilgiler üretebilme gibi yetenekleri hiçbir yardım almadan kendi kendine yapabilmek amacıyla biyolojik sinir ağlarından ilham alınarak geliştirilen sistemlerdir [70,71].



Şekil 3.9: Yapay Sinir Ağı Hücresi [72].

Girdiler $x_1, x_2, x_3, \ldots . x_n$ şeklinde olup diğer hücrelerden ya da dış ortamlardan hücreye gönderilen bilgilerdir. Bu girdiler ağın öğrenmesi istenen örnekler tarafından belirlenir.

Ağırlıklar $w_1, w_2, w_3, \ldots . w$, girdi kümesi veya kendinden önceki bir katmandaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini ifade eden değerlerdir. Her bir girdi, o girdiyi işlem elemanına bağlayan ağırlık değeriyle çarpılarak, toplam fonksiyonu aracılığıyla birleştirilir. Toplam fonksiyonu denklem 3.11' de verildiği şekildedir.

$$\text{net} = \sum_{i=1}^{n} w_i x_i + b \tag{3.11}$$

Toplam fonksiyonu sonucunda elde edilen değer doğrusal ya da doğrusal olmayan türevlenebilir bir transfer fonksiyonundan geçirilerek işlem elemanının çıktısı hesaplanır.

$$y = f(net) = f(\sum_{i=1}^{n} w_i x_i + b) \tag{3.12}$$

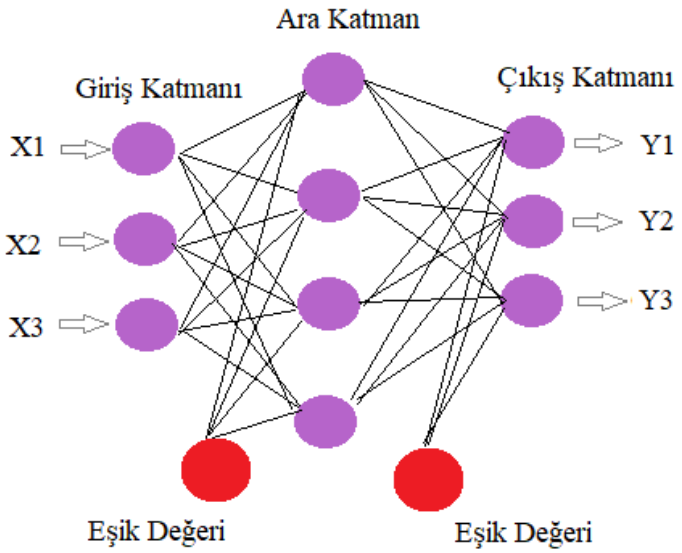
Yapay sinir ağlarında çok çeşitli ağ modelleri vardır. Yapay sinir ağı, Şekil 3.9'da belirtilen bir dizi sinir hücresinin ileri sürümlü ve geri beslemeli bağlantı şekilleri ile birbirine bağlanmasından oluşur [73].

YSA ile yapılan araştırmalar 20. yy'ın başlarında başlamış ve hala çalışmalar sürmektedir. Yapılan her çalışma birbirini takip etmektedir. Warren McCulloch ve Walter Pitts 1943 yılında yaptıkları çalışmalar ile ilk yapay sinir ağı modelini oluşturmuşlardır. İnsan beyninin hesaplama kabiliyetinden faydalanarak elektrik devreleriyle basit bir sinir ağı modellemesi yapılmıştır. Frank Rosenblatt'ın Perceptron'u geliştirmesi ile 1967 yılında YSA ile ilgili yapılan çalışmalar hız kazanmıştır. Bernand Widrow ve Marcian Hoff 1959 yılında ADALINE (Adaptive Linear Neuron) modelini geliştirmişlerdir. Çalışılan bu ADALINE modeli YSA'nın mühendislik alanında ki çalışmaları için başlangıç niteliğinde olup gerçek problemlere uygulanan ilk YSA olma özelliğini kazanmıştır. 1970'li yılların sonlarına doğru Fukushima tarafından şekil ve örüntü tanıma amacıyla NEOCOGNITRON geliştirilmiştir. Hopfield 1982-1984 senelerinde yapmış olduğu çalışmalar ile YSA'nın genelleştirilebileceğini ve çözülmesi güç problemlere çözüm oluşturabileceğini ifade etmiştir. Bu doğrultuda Hinton ve arkadaşları tarafından Boltzman Makinesi geliştirilmiştir. 1988 senesinde Broomhead ve Lowe tarafından geliştirilen radyal tabanlı fonksiyonlar modeli (Radial Basis Functions RBF) ile özellikle filtreleme konusunda başarılı sonuçlar elde edilmiştir. Sonraki yıllarda bu ağların daha gelişmiş modeli olan Genel Regresyon Ağları (GRNN) ve Probabilistik ağlar (PNN) Spect tarafından geliştirilmiştir. Bu çalışmalardan sonra günümüze kadar yapay sinir ağlarına ilişkin pek çok önemli çalışma ve uygulamalar yapılmıştır [74].

3.3.1. Çok Katmanlı Algılayıcılar (Multilayer Perceptron)

Derin öğrenmenin temeli olan Çok katmanlı algılayıcılar Yapay sinir ağının genellikle sinir ağı adı verilen alanını oluşturur. Bu algılayıcılar en az ikiden fazla düğüm katmanından oluşur [75].

YSA modelleri içerisinde en çok kullanılan ağ modeli MLP'dir. Bu ağlarda girdiler katmanlar boyunca ileriye doğru taşınarak çıktı sinyali oluşturmaktadır. Bu şekilde bir ağda bilgi sırasıyla üç tabakadan ileri doğru aktarılmaktadır. Girdi katmanı olarak adlandırılan ilk tabakanın görevi bilgiyi sonraki gizli tabakaya iletmektir. Bu tabakada veriye herhangi bir işlem uygulanmamaktadır. Ara tabaka olarak adlandırılan bir sonraki tabaka yer alan sinir hücreleri veriyi transfer fonksiyonundan geçirerek bir sonraki katman olan çıktı katmanına iletirler. Çıktı katmanı kendisine gelen bu bilgiyi kendi transfer fonksiyonundan geçirerek çıktıyı üretmiş olur. Elde edilen çıktı istenilen çıktı değeriyle karşılaştırılır. Ortaya çıkan hata payı ağ boyunca ağırlıklara geri yayılır. Düzenlemeler yapılarak veri seti ağa tekrar sunulur, başta anlatılan süreç tekrarlanarak çıktı tekrar elde edilir ve istenilen çıktı değeriyle karşılaştırılır. Bu işleme istenilen çıktıya kabul edilir hata değerine yaklaşılana kadar devam edilir. Bu işlem için kullanılan en yaygın kabul görmüş algoritma geri yayılım algoritmasıdır [76]. Şekil 3.10'da Çok Katmanlı Algılayıcı modeli gösterilmektedir.



Şekil 3.10: Çok Katmanlı Algılayıcı Modeli.

Bu tez çalışmasında özellikler çıkartıldıktan sonra Multilayer Perceptron ile veri setinin 66% eğitim için kullanılarak tahmin çalışması yapılmıştır.

3.4. RASTGELE ORMAN (RO)

Rastgele karar ormanları veya Rastgele ormanlar, temelinde eğitim zamanı çok sayıda karar ağacı oluşturarak problemin tipine göre regresyon, sınıflandırma yapılarak öğrenme şeklidir [77]. Rasgele Orman (RO), aynı dağılıma sahip olan ormandaki tüm ağaçların herbiri için ayrı ayrı örneklenir. Her bir ağaç için rasgele belirlenen vektörlerin değerlerine bağlı olarak karar ağaçlarının birleşiminden oluşur [78]. Ormandaki tüm ağaçların herbirine uygulanan girdi vektörleri ile sınıflandırma yapılır. Yani her bir ağaç için birbirinden bağımsız şekilde sınıflandırma yapılır.Sınıflandırmada herbir oy her bir ağacın kararıdır. En çok oya sahip olan sınıflandırma tüm ağaçlar için sonuç olarak değerlendirilir [79]. Bu yöntemle yüksek doğrulukta bir sınıflandırma yapılması amacına yönelik olarak çok sayıda karar ağacı üretilir. Her bir karar ağacının oylarıyla performansı yüksek bir sınıfın belirlenmesi ve ormanı oluşturan ağaçların geliştirilmesi sonucunda sınıflandırma doğruluğu daha da artmış olur [78]. Bu yöntemde verilerin farklı önyükleme örnekleri kullanılarak herbir ağaç oluşturulur.Bu yöntem ayrıca regresyon ağaçlarının oluşturulma şeklini ve ve sınıflandırma performansınıda etkiler. Tüm girdi değişkenleri kullanılarak standart ağaçlardaki her bir düğüm en iyi bölünmeyi sağlayacak şekilde bölünür. Rasgele Alt-Uzay yöntemine dayanılarak, bu yöntemdeki her bir düğüm, seçilen rasgele değişkenler arasından en iyi sonucu veren değişkenlerin kullanılmasıyla bölünür [80].

3.5. DESTEK VEKTÖR MAKİNELERİ (DVM)

Destek vektör makineleri (DVM) istatistiksel analizler için 1995 yılında Vapnik tarafından önerilmiştir. Sınıflandırma ve regresyon analizinde özellikle yapay sinir ağlarının çözüm üretemediği bazı durumlarda istatistiksel sınıflandırmaya yönelik tasarlanmış bir algoritmadır [81]. DVM başka geleneksel öğrenme metotları ile karşılaştırıldığında doğrusal olmayan problemleri çözerken ki yeteneği ve performansı çok daha iyidir. Smola ve diğ. [82] genel olarak sınıflandırma amacıyla kullanılan DVM yöntemini regresyon için kullanmayı bulmuşlardır. Bulunan bu regresyon yöntemi Destek Vektör Regresyonu (DVR) olarak

adlandırılmıştır [83]. DVM'lerde doğrusal ayrılabilme durumu ve doğrusal ayrılamama durumu olarak 2 durum söz konusudur.

3.5.1. Doğrusal Ayrılabilme Durumu

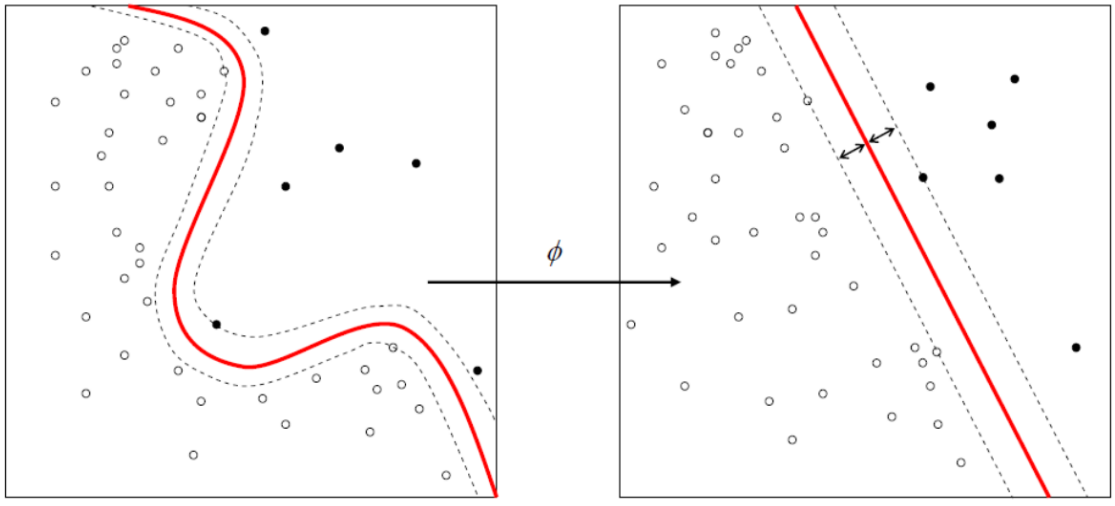
Verileri eğitmek amacıyla kullanılacak N elemandan oluşan veri setinin $\theta = \{x_i, y_i\}$, i = 1, 2,…… N olduğu varsayalım. Burada $y_i \in$ {-1, 1} etiket değerleri ve $x_i \in R^d$ özellikler vektörüdür. Doğrusal olarak ayrılırken bu iki değerli veriler direkt olarak bir düzlem yardımıyla ayrılırlar. Bu düzleme ayırıcı düzlem adı verilir . DVM'lerin amacı bu düzlemin iki ayrı sınıfta bulunan örneklere eşit uzaklıkta olmasını sağlamaktır [84].

3.5.2. Doğrusal Ayrılamama Durumu

Doğrusal olmama durumunda veriler doğrusal bir düzlem ile birbirinden ayrılmayabilir [84]. Verilerin doğrusal olarak ayrılamadığı durumlarda doğrusal sınıflandırıcı yerine doğrusal olmayan sınıflandırıcılar kullanılabilir. Bu kapsamda Doğrusal Olmayan Özellik Uzayı; $x_i \in R_n$ gözlem vektörünü daha yüksek dereceden bir uzayda z vektörüne dönüştürerek, sınıflandırıcıları elde etmek söz konusu olabilir. Bu z vektörünün bulunduğu özellik uzayı F ile ifade edilir. Böylece Ø ifadesi $R^n \rightarrow R^F$ eşlemesini yapmak üzere $z = \emptyset(x)$ şeklinde denklem 3.13'te ifade edilebilir [85].

$$x \in R^n \rightarrow \mathrm{z(x)} = [a1, \emptyset 1(x), \ldots \ldots an, \emptyset n(x)]^T \in R^F \qquad (3.13)$$

Doğrusal ayrılabilen ve doğrusal olarak ayrılamayan veriler Şekil 3.11'de gösterilmiştir.



Şekil 3.11: Doğrusal Ayrılmayan Doğrusal Olarak Ayrılabilen Veriler [86].

Destek vektör makineleri algoritması ile veriler iki sınıf için bir düzlem boyunca iki gruba ayrılır ve böylelikle veriler iki grupta sınıflandırılmış olur. İki sınıf arasında, iki grubun üyelerine en uzak düzlem en iyi sınır olarak tanımlanır. Başka bir ifadeyle, bu çizgi iki sınıf arasında, tam ortadan geçen bir düzlemdir. DVM bu sınırın nasıl çizileceğini belirler. Sınıflardaki verilerin dağılımı bilinmemesine rağmen bu sınır ile, verilerin en uygun şekilde sınıflandırılması sağlanır. Sınıflandırmayı sağlayan bu sınırlara en yakın olan eğitim vektörleri destek vektörleri olarak adlandırılır [81].

Yapılan bu çalışmada Weka içerisinde bulunan SMOreg seçeneği kullanılmıştır. SMOreg Regresyon analizi uygulamaya yarayan kütüphanedir.

4. BULGULAR

4.1. VERİ KAYITLARI

Bu tez çalışmasında kullanılan veriler Çin Guilin Halk Hastanesinde gerçekleştirilen ölçüm işlemleridir. Veri toplama işlemine ve araştırmaya etik onay verilmiştir. Kayıt işlemi yapılmadan önce ölçüm yapılacak kişiler rahat bir ortamda dinlendirilmişlerdir. Ölçümler 3 parça halinde ve herbir parçası 2,1 saniye şeklinde olup örnekleme frekansı 1 kHz'dir. Veri toplama işlemine % 48 i erkek olan 219 kişi katılmış ve yaşları 21 ile 86 arasında değişmektedir. Ölçüm yapılan kişilerden, 80 kişinin tansiyonu normal olup 139 kişi hipertansiyon hastasıdır. Her biri 2,1 saniye olan toplam 657 veri kaydedilmiştir [87].

4.2.DEĞERLENDİRME ÖLÇÜTLERİ PERFORMANSI (PERFORMANCE EVALUATION METRICS)

Bu çalışmada verilerin 2/3 ü öğrenme için, 1/3 u ise test için kullanılmıştır. Performans ölçümü için ise korelasyon katsayısı, Ortalama Mutlak Hata (Mean Absolute Error), Kök Ortalama Kare Hatası (Root Mean Square Error) gibi parametreler kullanılmıştır.

Korelasyon Katsayısı (KK);

İki değişken arasında hesaplanan korelasyon (r) değeri:

• r<0.20 ve sıfıra yakın değerler çok zayıf ilişkiyi veya ilişkinin olmadığını ifade eder.

• 0.20-0.39 arası düşük ilişkiyi

• 0.40-0.59 arası orta ilişkiyi

• 0.60-0.79 arası yüksek ilişkiyi

• 0.80-1.0 ise çok yüksek ilişkiyi ifade etmektedir [88].

Korelasyon katsayısı istatistiksel olarak denklem 4.1'deki gibi hesaplanır.

$$r = \frac{N\sum xy - \sum x \sum y}{[[N\sum x^2 - (\sum x)^2][N\sum y^2 - (\sum y)^2]]^{1/2}} \quad (4.1)$$

Ortalama Mutlak Hata (OMH);

$$OMH = \frac{1}{m}\sum_{i=1}^{m}|y - \hat{y}| \quad (4.2)$$

Kök Ortalama Kare Hata (KOKH);

$$KOKH = \sqrt{\frac{1}{m}}\sum_{i=1}^{m}|y - \hat{y}|^2 \quad (4.3)$$

şeklindedir.

Burada y gerçek değer, $\hat{y}$ tahmin edilen değeri ifade eder.

4.3. PPG SİNYALLERİ İLE ÖZELLİK ÇIKARTILMASI

PPG sinyallerinden MATLAB programında DT-CWT ve TQWT yöntemleri kullanılarak özellikler çıkartılmıştır. Bu özellikler çıkartılırken iki yöntem içinde aşağıdaki yol izlenmiştir;

1. Her bir alt banttaki katsayıların mutlak ortalaması
2. Alt banttaki dalgacık kat sayılarının ortalama gücü
3. Alt banttaki dalgacık kat sayılarının çarpıklığı
4. Alt banttaki dalgacık kat sayılarının basıklığı
5. Alt banttaki dalgacık kat sayılarının standart sapması
6. Bitişik alt bantların multak ortalama değerlerinin oranı

Tanımlanan istatistiksel değerlerden, dalgacık dönüşümü katsayıları öznitelikleri belirlenmiş ve PPG işaretlerini temsil eden 95 özellik tespit edilmiştir.

Ortalama:

$$\frac{1}{N}\sum_{i=1}^{N} y_i \tag{4.4}$$

Basıklık:

$$\sum_{i=1}^{N} \frac{(y_i-\mu)^4/N}{s^4} \tag{4.5}$$

Gösterilen denklem 4.4 ve 4.5'de N örnek sayısı, $y_i$mevcut örnek, s standart sapma , μ ise ortalama olarak ifade edilmiştir [27].

Çarpıklık:

$$\sum_{i=1}^{N} \frac{(y_i-\mu)^3/N}{s^3} \tag{4.6}$$

Denklem 4.6'da N örnek sayısı, y_i mevcut örnek, s standart sapma, μ ise ortalama olarak tanımlanmıştır [27].

Standart Sapma:

$$\sqrt{\frac{\sum_{i=1}^{N}(y_i-\mu)^2}{N}} \tag{4.7}$$

Ortalama Güç:

$$\frac{1}{N}\sum_{i=1}^{N} y_i^2 \tag{4.8}$$

Ortalama, basıklık, ortalama güç, standart sapma, çarpıklık gibi özellikler kullanılmıştır.

4.3.1. DT-CWT Kullanılarak Özellik Çıkartılması

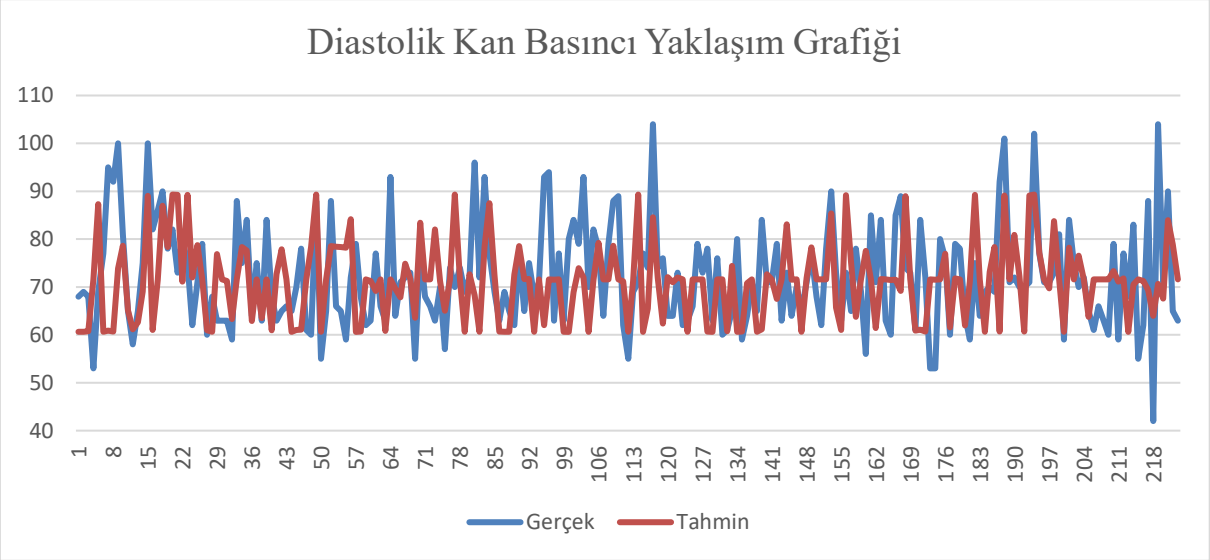
DT-CWT ile özellik çıkartılması istatistiksel özelliklerini hesaplamaya dayanır. Model önemli özelliklere indirgenir. DT-CWT ile sinyal analiz edilirken seviye sayısı yani j parametresi 7 seçilmiştir. Sinyal 7 alt banta ayrılmıştır. Ayrışım sonrası toplam j+1 alt bant oluşur. Her biri Low ve High şeklinde iki bileşene sahiptir. Her bir istatistik için 16 değer üretilir. Mutlak

ortalama değerlerin oranından 15 değer üretilmesinden dolayı toplamda her bir sinyal için 95 tane özellik elde edilmiştir.

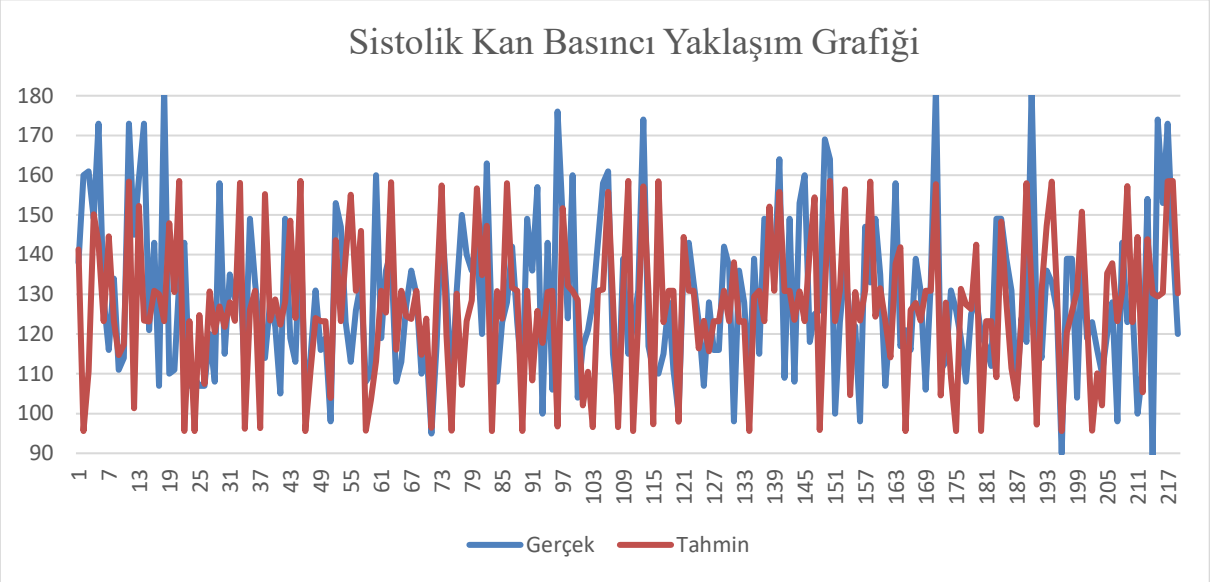
Sinyal 7 alt banta ayrılmıştır. Her bir seviyenin katsayılarının ortalama gücü, mutlak değer ortlaması, çarpıklığı, basıklığı ve katsayıların standart sapması gibi özellikler tespit edilmiştir.

Elde edilen 95 tane özellik Weka programında YSA, RO ve DVM yöntemleri ile analiz edilmiştir ve klasik yöntemle elde edilen sistolik diastolik kan basıncı ve kalp hızı değerlerine ne kadar yaklaştığı gözlemlenmiştir.

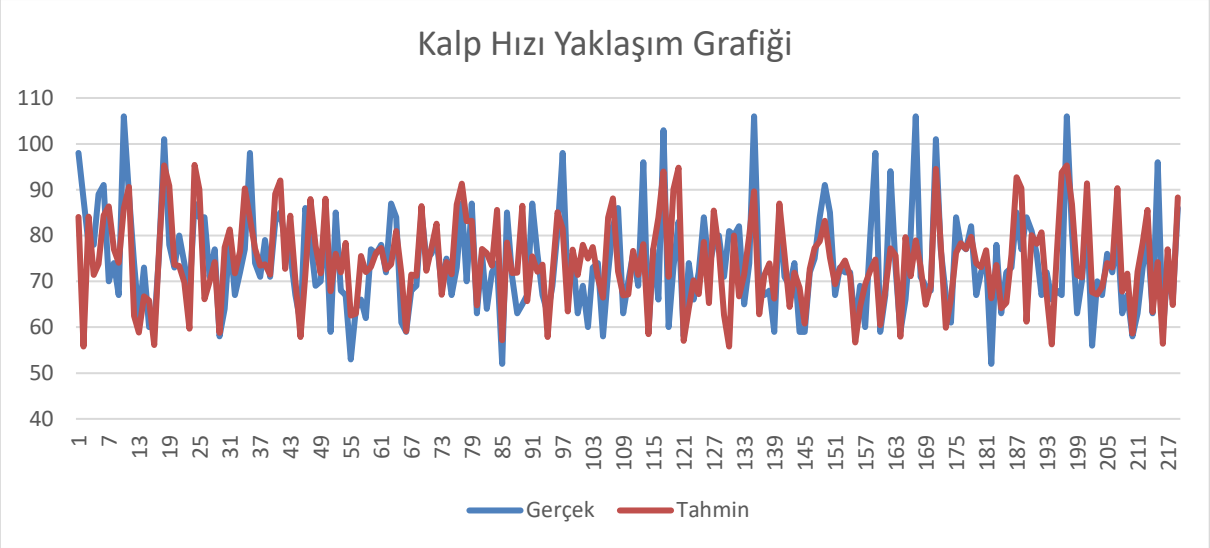
Yapay Sinir Ağları ile yapılan yaklaşımda aşağıdaki sonuçlar elde edilmiştir;



Şekil 4.1: DT-CWT Kullanarak YSA ile Diastolik Kan Basıncı Tahmini

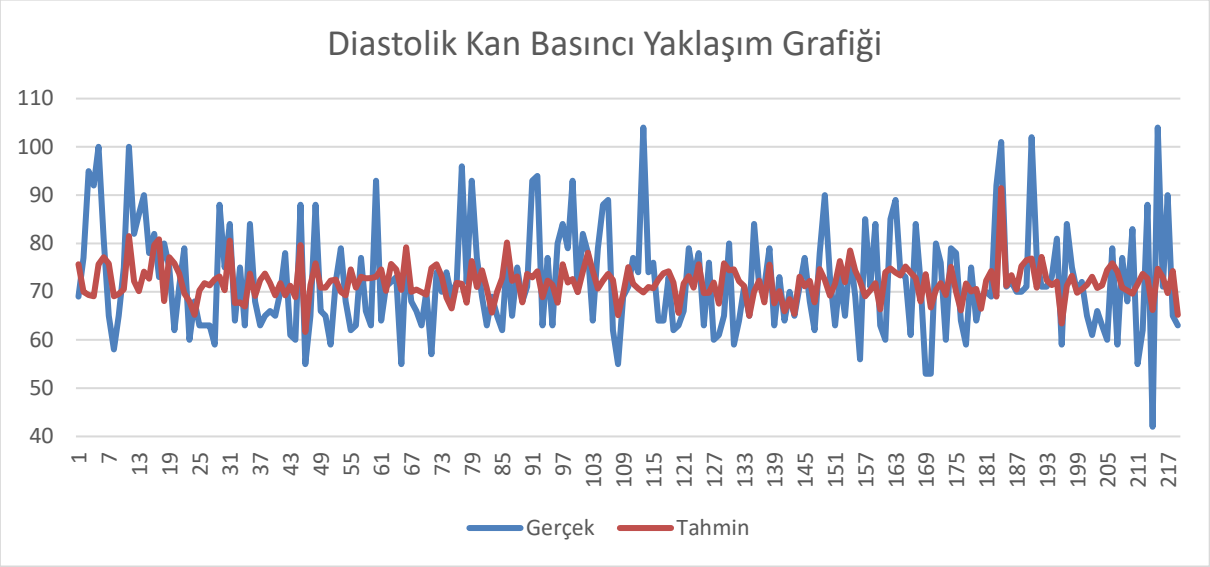


Şekil 4.2: DT-CWT Kullanarak YSA ile Sistolik Kan Basıncı Tahmini

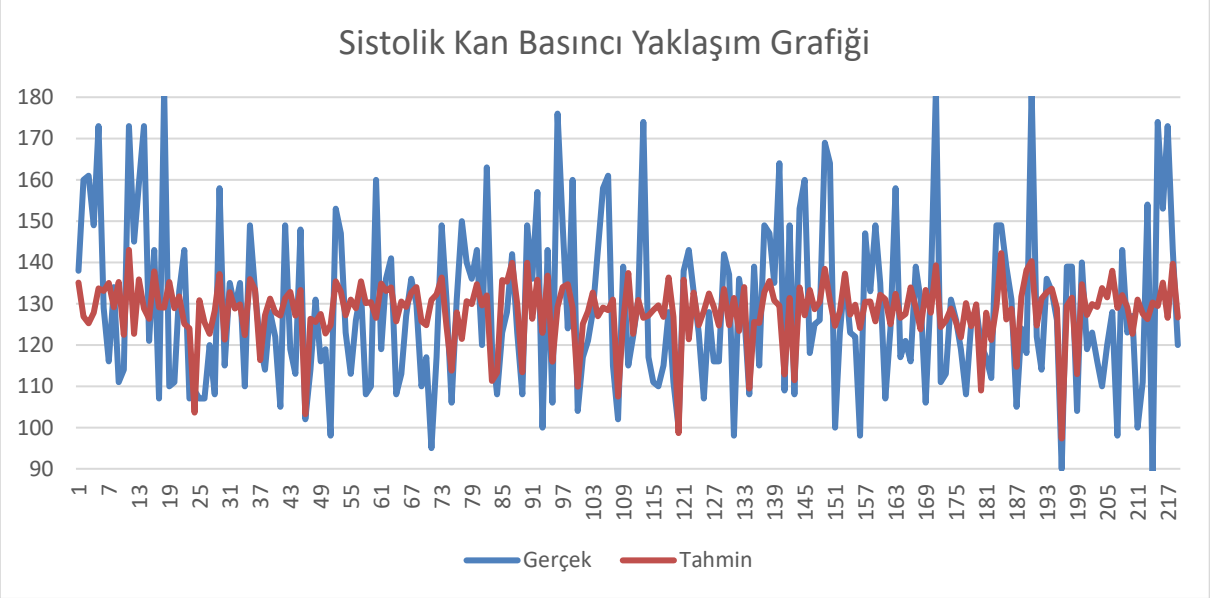


Şekil 4.3: DT-CWT Kullanarak YSA ile Kalp hızı Tahmini

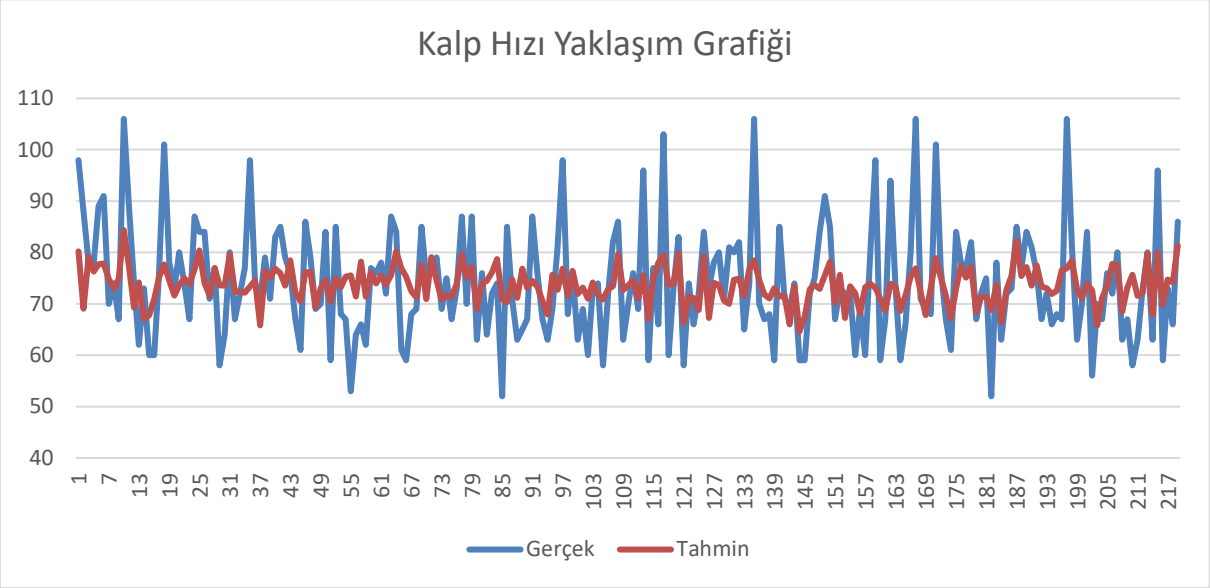
Rastgele Orman ile Yapılan Yaklaşımlar;



Şekil 4.4: DT-CWT Kullanarak RO ile Diastolik Kan Basıncı Tahmini

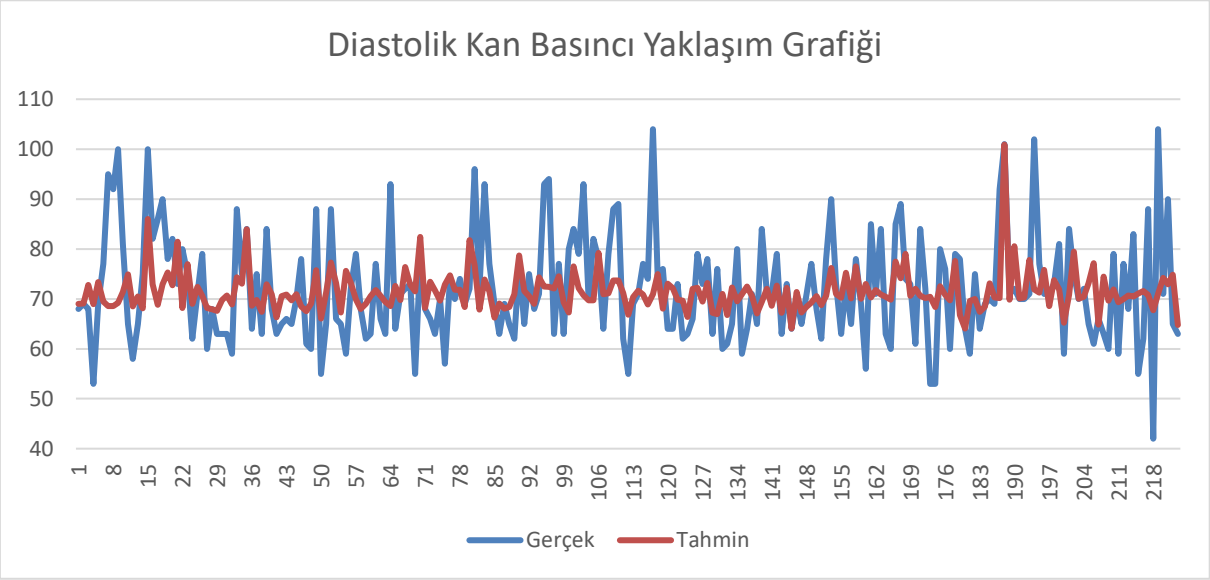


Şekil 4.5: DT-CWT Kullanarak RO ile Sistolik Kan Basıncı Tahmini

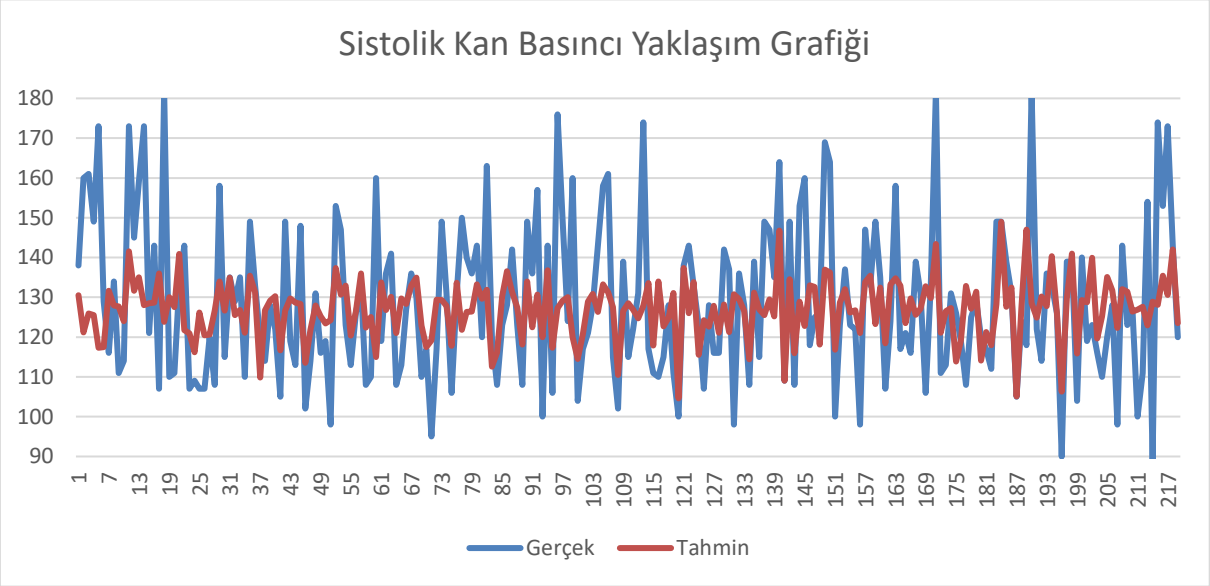


Şekil 4.6: DT-CWT Kullanarak RO Kalp Hızı Tahmini

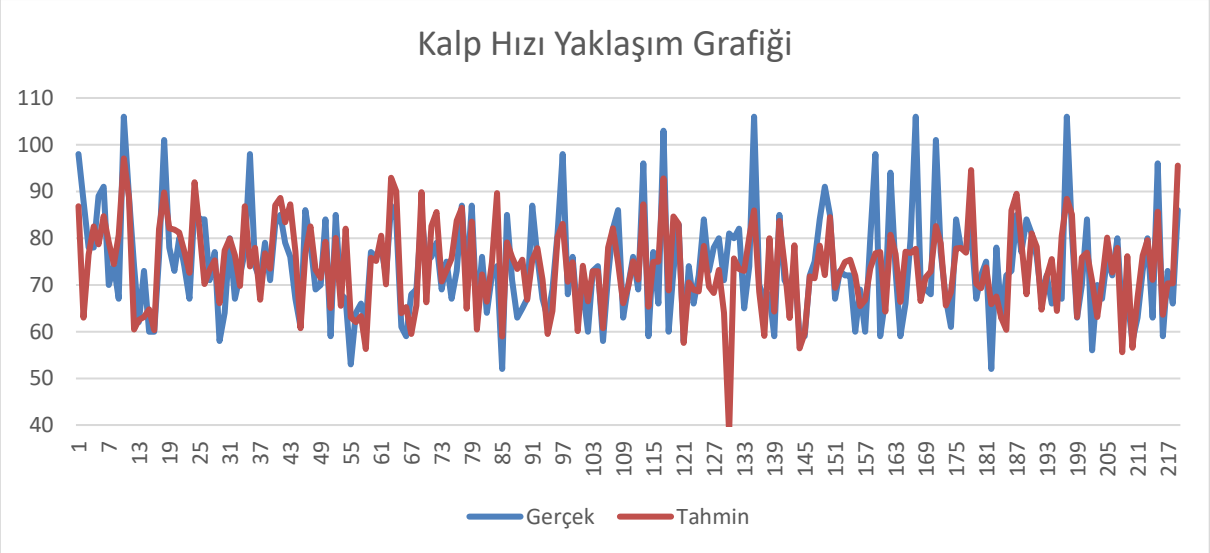
Destek Vektör Makinalari ile yaklaşım;



Şekil 4.7: DT-CWT Kullanarak DVM ile Diastolik Kan Basıncı Tahmini



Şekil 4.8: DT-CWT Kullanarak DVM ile Sistolik Kan Basıncı Tahmini



Şekil 4.9: DT-WCT Kullanarak DVM Kalp Hızı Tahmini

Tablo 4.1: DT-CWT ile Diastolik Kan Basıncı Hata Değerlerinin Karşılaştırılması

Yöntem	KK	OMH	KOKH
YSA	0.2746	9.1433	11.5177
RO	0.3682	7.8386	10.0365
DVM	0.3701	7.6275	10.0281

DT-CWT yöntemi ile YSA, RO ve DVM algoritmaları kullanılarak diastolik kan basıncının tahmin edilmesinde korelasyon katsayılarını ve hata oranlarını gösteren değerler Tablo 4.1'de gösterilmiştir. DVM algoritması kullanılarak yapılan tahminde korelasyon katsayısı, YSA ve RO algoritmaları kullanılarak yapılan tahminlere göre daha yüksek olmasına rağmen 0,3701 gibi oldukça düşük değerlerdedir. Aynı şekilde DVM algoritması kullanılarak yapılan tahminlerdeki hata oranları, diğer algoritmalarla yapılan tahminlerdeki hata oranlarından daha düşük olmasına rağmen yine de DVM algoritması ile yapılan tahminlerdeki hata oranları yüksek değerlerdedir.

Tablo 4.2: DT-CWT ile Sistolik Kan Basıncı Hata Değerlerinin Karşılaştırılması

Yöntem	KK	OMH	KOKH
YSA	0.3397	17.0354	21.574
RO	0.4421	13.8426	17.8299
DVM	0.422	13.9667	18.0726

DT-CWT yöntemi ile YSA, RO ve DVM algoritmaları kullanılarak sistolik kan basıncının belirlenmesinde korelasyon katsayılarını ve hata oranlarını gösteren değerler Tablo 4.2'de verilmiştir. RO algoritması kullanılarak yapılan tahminlerdeki korelasyon katsayısı, YSA ve DVM algoritmaları kullanılarak yapılan tahminlere göre daha yüksek değerlerde çıkmaktadır. RO algoritması kullanılarak yapılan tahminlerdeki hata oranları, diğer algoritmalarla yapılan tahminlerdeki hata oranlarından daha düşük olmasına rağmen yinede RO algoritması ile yapılan tahminlerdeki hata oranları yüksek çıkmaktadır.

Tablo 4.3: DT-CWT ile Kalp Atış Hızı Hata Değerlerinin Karşılaştırılması

Yöntem	KK	OMH	KOKH
YSA	0.6246	6.6758	8.8685
RO	0.5825	6.9826	9.278
DVM	0.6636	6.0964	8.3124

DT-CWT yöntemi ile YSA, RO ve DVM algoritmaları kullanılarak kalp atış hızının tahmin edilmesinde korelasyon katsayılarını ve hata oranlarını gösteren değerler Tablo 4.3'te gösterilmiştir. DVM algoritması kullanılarak yapılan tahminlerdeki korelasyon katsayısı, YSA ve RO algoritmaları kullanılarak yapılan tahminlerdeki korelasyon katsayılarından daha yüksek değerlerdedir. DVM algoritması kullanılarak yapılan tahminlerdeki hata oranları, YSA ve RO algoritmaları ile yapılan tahminlerdeki hata oranlarından daha düşüktür. Tablodaki değerlerden korelasyon katsayısı yükseldikçe hata oranlarının düştüğü yani tahminlerdeki doğruluk oranlarının arttığı görülmektedir.

4.3.2. TQWT Kullanılarak Özellik Çıkartılması

Hedeflenen fonksiyonun bir fonksiyonu olarak kolayca ayarlanabilir yapıya sahiptir. Birincil ayarlanabilir parametreleri Q, r ve J dir.

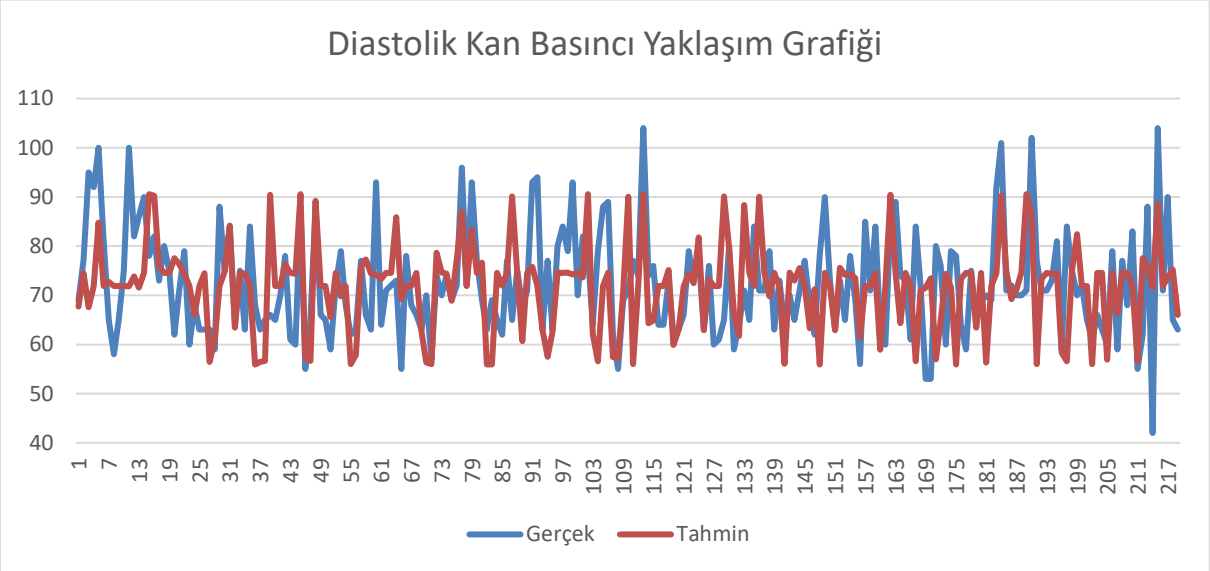
Q = Dalgacık salınımlarının sayısı

J = Ayrışma Seviyeleri

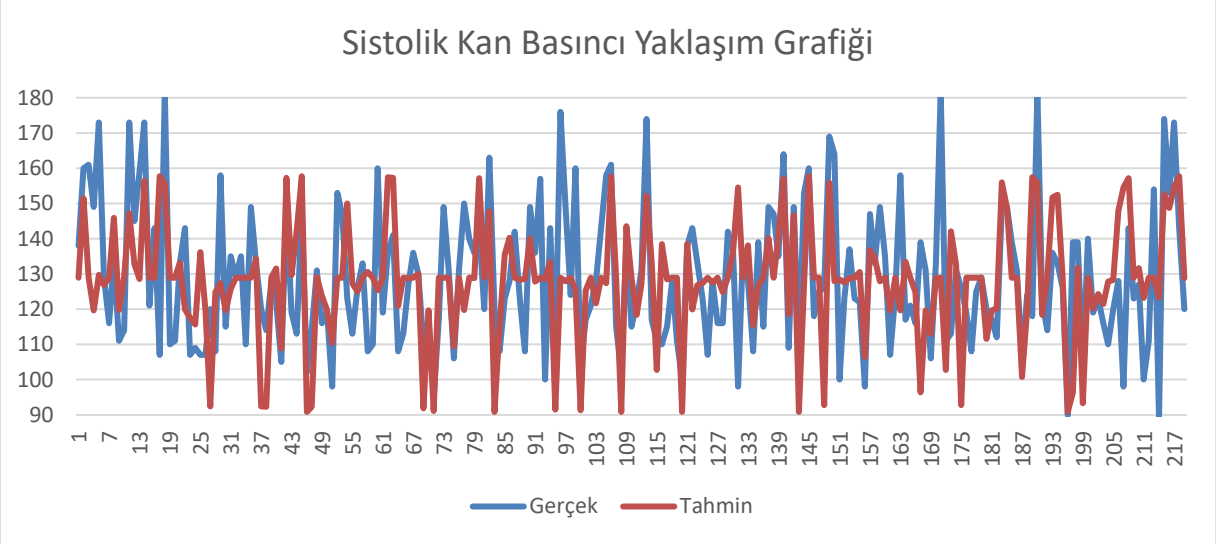
Bu çalışmada, Q = 3; r = 4; J = 15 şeklinde seçilmiştir. Bu değerler en iyi sonucu bulmak için deneme yoluyla seçilmiştir. Ayrışım sonrası oluşan j+1=16 alt bant için 6 istatistik değer bulunmuştur. Aynı şekilde her bir sinyal için 95 tane özellik elde edilmiştir.

Bulunan özellikler Weka'da YSA , RO ve DVM algoritmaları kullanılarak analiz edilmiş ve gerçek değerlere ne kadar yaklaştığı incelenmiştir.

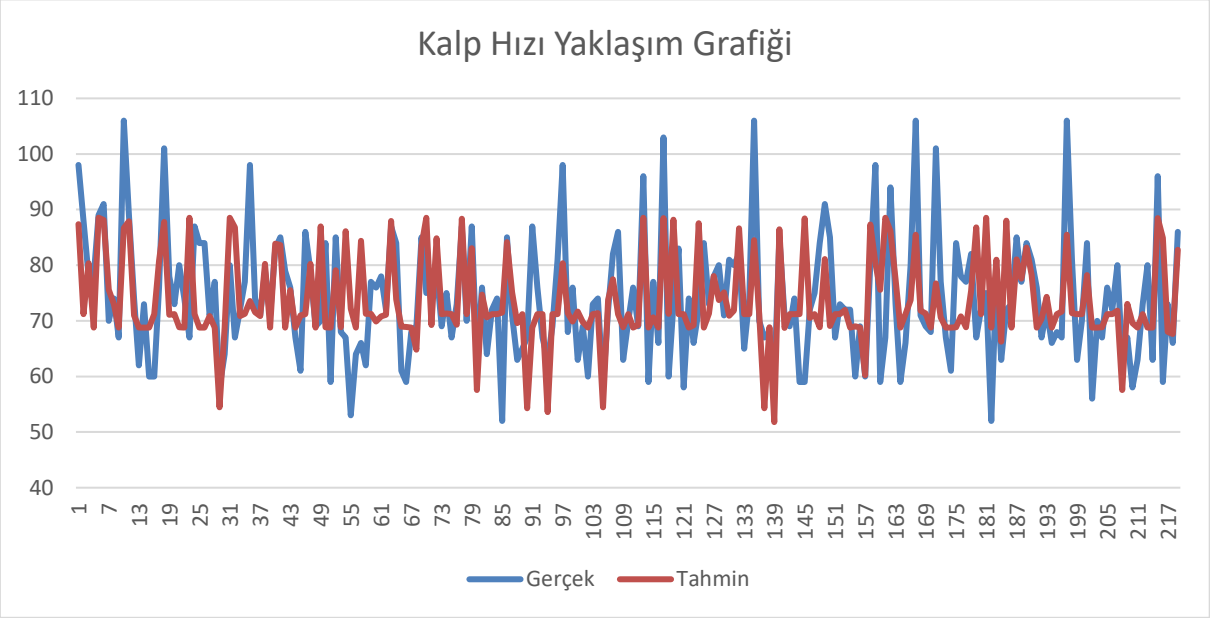
YSA ile yaklaşım ;



Şekil 4.10: TQWT Kullanarak YSA ile Diastolik Kan Basıncı Tahmini

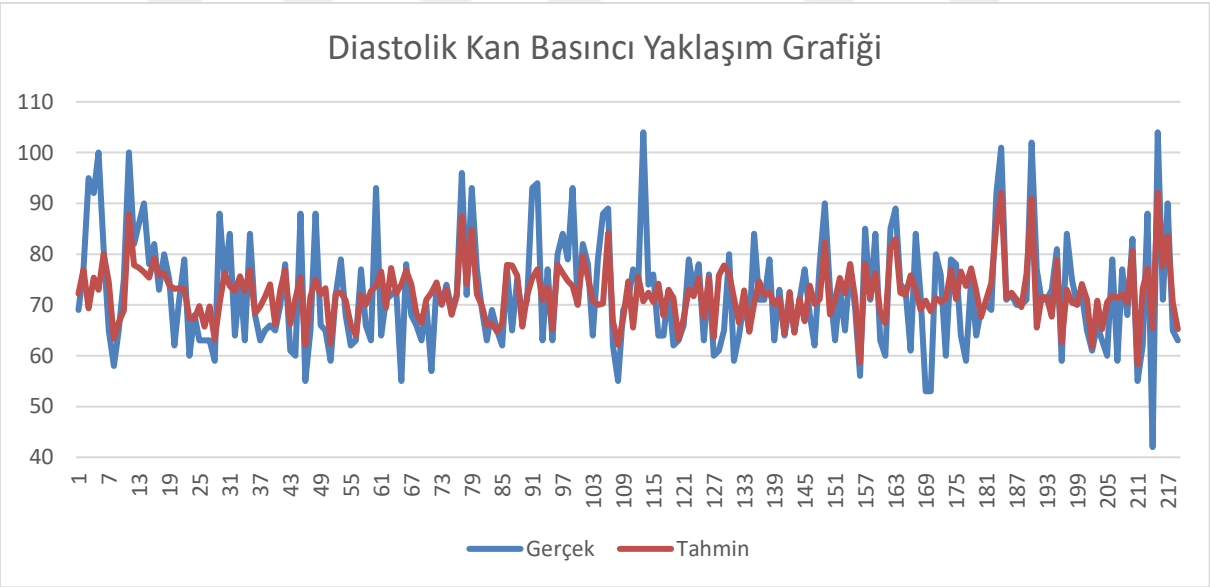


Şekil 4.11: TQWT Kullanarak YSA ile Sistolik Kan Basıncı Tahmini

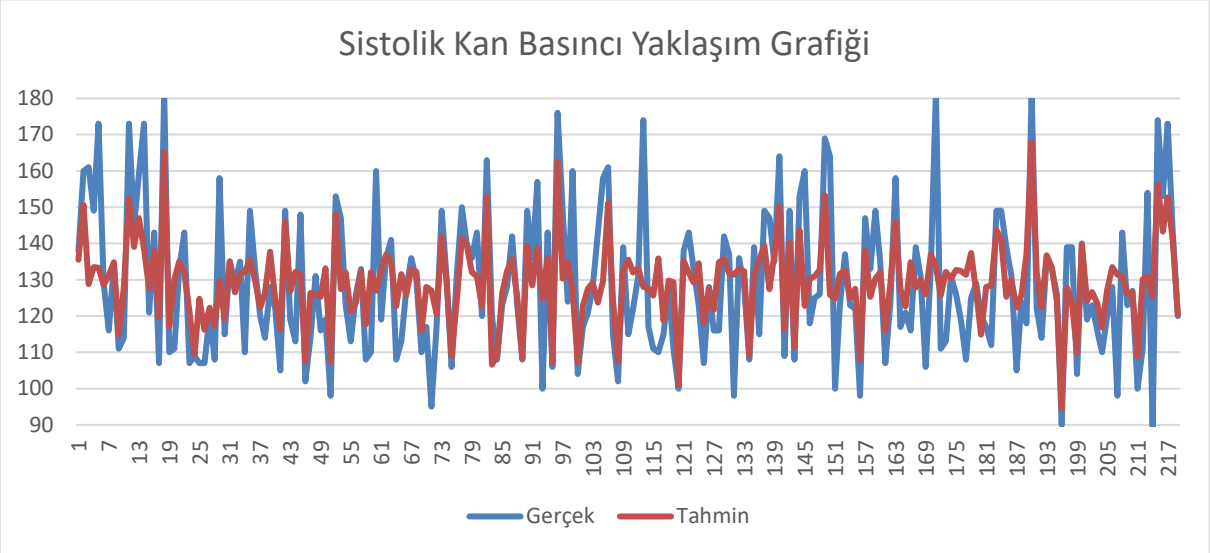


Şekil 4.12: TQWT Kullanarak YSA ile Kalp Hızı Tahmini

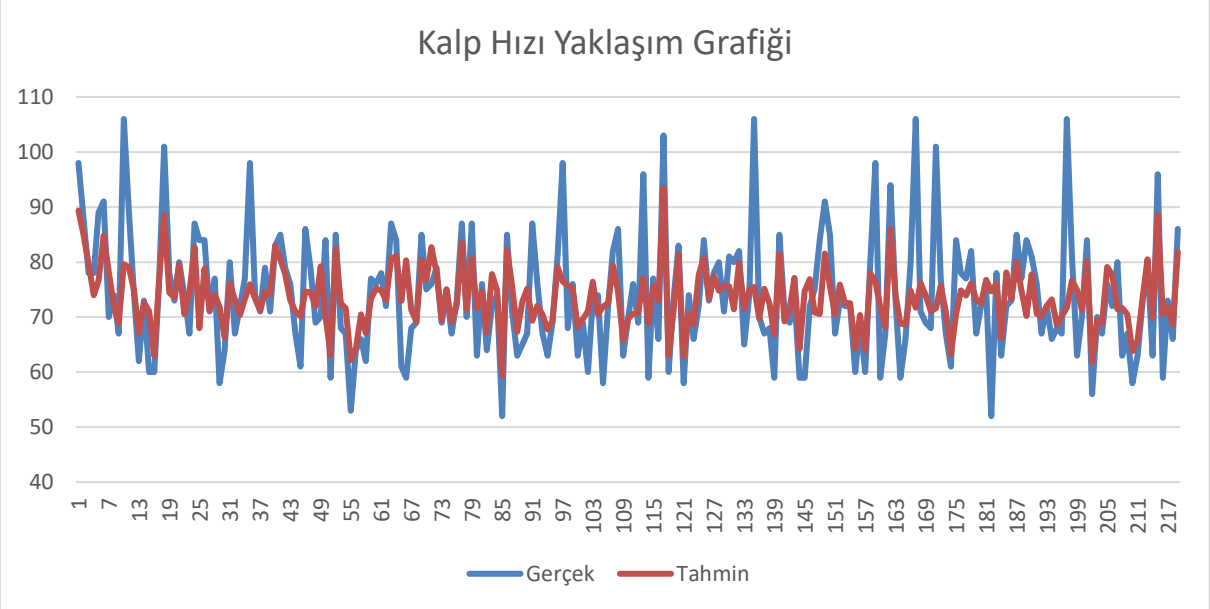
RO ile Yaklaşım;



Şekil 4.13: TQWT Kullanarak RO ile Diastolik Kan Basıncı Tahmini

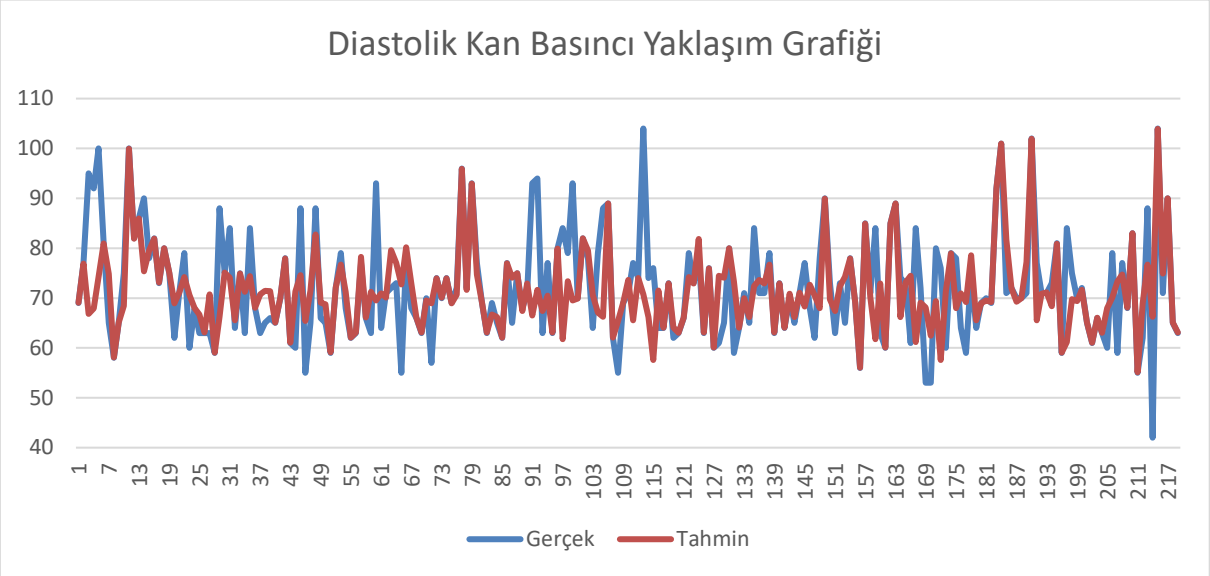


Şekil 4.14: TQWT Kullanarak RO ile Sistolik Kan Basıncı Tahmini

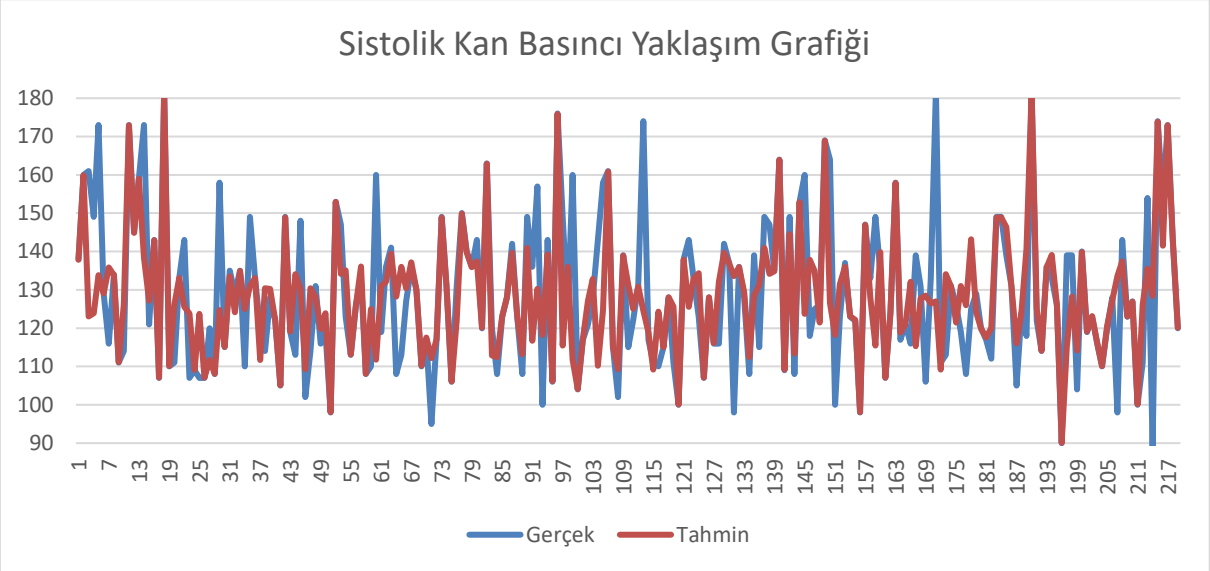


Şekil 4.15: TQWT Kullanarak RO ile Kalp Hızı Tahmini

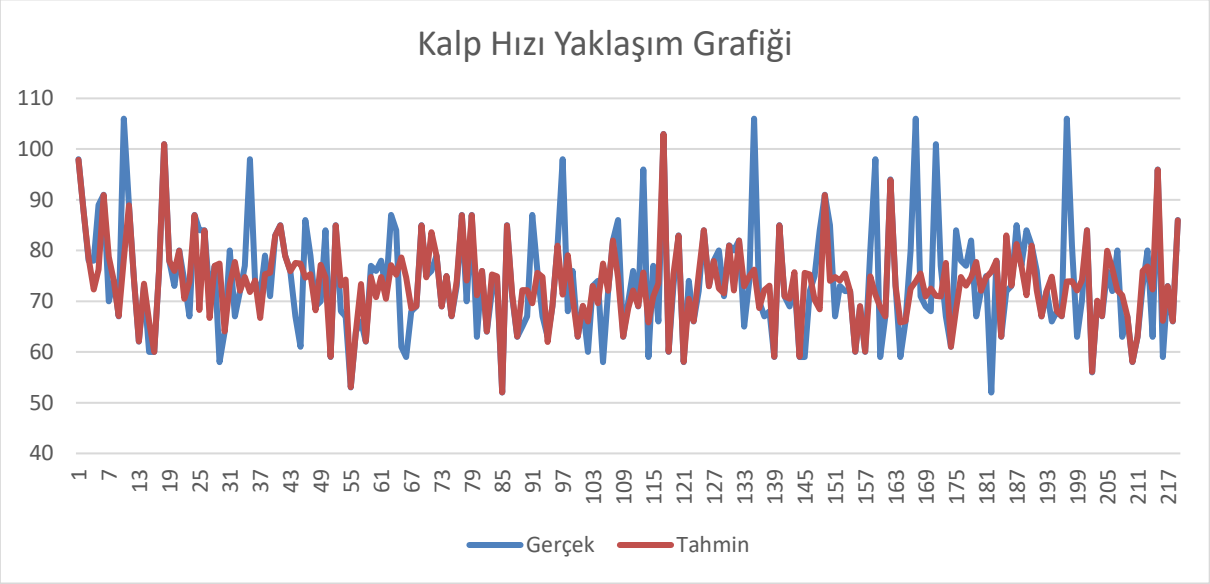
DVM ile Yaklaşım;



Şekil 4.16: TQWT Kullanarak DVM ile Diastolik Kan Basıncı Tahmini



Şekil 4.17: TQWT Kullanarak DVM ile Sistolik Kan Basıncı Tahmini



Şekil 4.18: TQWT Kullanarak DVM ile Kalp Hızı Yaklaşım Tahmini

Tablo 4.4: TQWT ile Diastolik Kan Basıncı Hata Değerlerinin Karşılaştırılması

Yöntem	KK	OMH	KOKH
YSA	0.3889	8.4578	10.8862
RO	0.6793	5.9829	8.1384
DVM	0.6303	4.9082	8.4865

TQWT yöntemi ile YSA, RO ve DVM algoritmaları yardımıyla diastolik kan basıncının belirlenmesinde korelasyon katsayılarını ve hata oranlarını gösteren sayısal değerler Tablo 4.4'te gösterilmiştir. RO algoritması kullanılarak yapılan tahminlerdeki korelasyon katsayısı, YSA ve DVM algoritmaları kullanılarak yapılan belirlemelerdeki korelasyon katsayılarından daha yüksek değerlerde çıkmaktadır. RO ve DVM algoritmaları kullanılarak yapılan tahminlerdeki hata oranları ise birbirine yakın değerlerdedir. YSA algoritması kullanılarak yapılan tahminlerdeki hata oranları ise diğer algoritmalardan daha yüksek değerlerde çıkmaktadır.

Tablo 4.5: TQWT ile Sistolik Kan Basıncı Hata Değerlerinin Karşılaştırılması

Yöntem	KK	OMH	KOKH
YSA	0.4983	8.4578	10.8862
RO	0.7273	10.5937	14.0732
DVM	0.7097	8.0443	14.0163

TQWT yöntemi ile YSA, RO ve DVM algoritmaları kullanılarak sistolik kan basıncının tahmin edilmesinde korelasyon katsayıları ile hata oranlarını gösteren sayısal değerler Tablo 4.5'te verilmiştir. Diastolik kan basıncı tahminlerinde olduğu gibi RO algoritması ile yapılan tahminlerdeki korelasyon katsayısı, YSA ve DVM algoritmaları kullanılarak yapılan belirlemelerdeki korelasyon katsayılarından daha yüksek değerlerde çıkmaktadır. RO ve DVM algoritmaları kullanılarak yapılan tahminlerdeki hata oranları arasında büyük farklar bulunmamaktadır.

Tablo 4.6: TQWT ile Kalp Hızı Hata Değerlerinin Karşılaştırılması

Yöntem	KK	OMH	KOKH
YSA	0.5228	7.1816	9.4639
RO	0.682	5.622	8.2107
DVM	0.659	4.6072	8.1961

TQWT yöntemi ile YSA, RO ve DVM algoritmaları kullanılarak kalp atış hızının tahmin edilmesinde korelasyon katsayılarını ve hata oranlarını gösteren değerler Tablo 4.6'da gösterilmiştir. RO algoritması kullanılarak yapılan tahminlerdeki korelasyon katsayısı, YSA ve DVM algoritmaları kullanılarak yapılan tahminlerdeki korelasyon katsayılarından daha yüksek değerlerdedir. DVM algoritması ile yapılan tahminlerdeki korelasyon katsayısının RO algoritması kullanılarak yapılan tahminlerdeki korelasyon katsayısına oldukça yakın değerde olduğu görülmektedir. YSA algoritması ile yapılan tahminlerde ise korelasyon katsayısı diğer yöntemlere göre odaha düşük ve hata oranları ise daha yüksek değerlerde çıkmaktadır. Bu da YSA algoritmasının kalp atış hızının belirlenmesinde çok uygun bir yöntem olmadığını göstermektedir.

5. TARTIŞMA VE SONUÇ

PPG sinyallerinden kan basıncı ve kalp atış hızlarının belirlenmesinde DT-CWT ve TQWT dalgacık dönüşümü yöntemlerine uygulanan YSA, RO ve DVM algoritmaları yardımı ile bulunan sonuçlar Tablo 4.1, 4.2, 4.3, 4.4, 4.5 ve 4.6' da gösterilmiştir.

Tablo 4.1'de görüldüğü gibi DT-CWT yöntemi ile DVM algoritması kullanılarak diastolik kan basıncının tahmin edilmesinde korelasyon katsayısı, YSA ve RO algoritmaları kullanılarak yapılan tahminlere göre daha yüksek olmasına rağmen yine de 0,3701 gibi oldukça düşük değerlerdedir. DVM algoritması ile yapılan tahminlerdeki hata oranları yüksek olmasına rağmen diğer YSA ve RO algoritmaları ile yapılan tahminlerdeki hata oranlarından daha düşük değerlerdedir.

YSA, RO ve DVM algoritmaları kullanılarak DT-CWT yöntemi ile sistolik kan basıncına ilişkin parametrelerin gösterildiği Tablo 4.2'de görüldüğü gibi RO algoritması kullanılarak yapılan tahminlerdeki korelasyon katsayısı diğer algoritmalar kullanılarak yapılan tahminlerdeki korelasyon katsayısından daha yüksek çıkmaktadır. Kullanılan üç algoritma yöntemi ile yapılan tahminlerdeki hata oranları yüksek değerlerde çıkmaktadır. RO algoritması kullanılarak yapılan tahminlerdeki hata oranları, diğer algoritmalarla yapılan tahminlerdeki hata oranlarından daha düşük değerdedir.

Kalp atış hızının belirlenmesinde DT-CWT yöntemi ile YSA, RO ve DVM algoritmalarından DVM algoritması kullanılarak yapılan tahminlerdeki korelasyon katsayısı, diğer algoritmalar kullanılarak yapılan tahminlerdeki korelasyon katsayılarından daha yüksek değerlerde çıkmaktadır. Tablo 4.3'te görüldüğü gibi YSA ve RO algoritmaları kullanılarak yapılan tahminlerdeki hata oranları DVM algoritması ile yapılan tahminlerdeki hata oranlarından daha yüksek değerlerdedir. Tablodaki değerler korelasyon katsayısı ile hata oranları arasında ters bir ilişkinin olduğunu göstermektedir. Yani hata oranları düştükçe korelasyon katsayısı yükselmektedir.

Diastolik kan basıncının tahmin edilmesinde TQWT yöntemi ile RO algoritması kullanılarak yapılan tahminlerdeki korelasyon katsayısı, YSA ve DVM algoritmaları kullanılarak yapılan tahminledeki korelasyon katsayısından daha yüksek değer elde edilmektedir. Tablo 4.4'te görüldüğü gibi her üç algoritma kullanılarak yapılan tahminlerde hata oranları bakımından

önemli bir fark çıkmamaktadır. Ancak YSA algoritması kullanılarak yapılan tahminlerdeki hata oranları diğer algoritmalardaki hata oranlarından daha yüksek çıkmaktadır.

TQWT yöntemi ile YSA, RO ve DVM algoritmaları kullanılarak sistolik kan basıncının belirlenmesinde korelasyon katsayısı, RO algoritması ile yapılan tahminlerde diğer algoritmalarla yapılan tahminlerden daha yüksek değerlerde çıkmaktadır. Tablo 4.5'de görüldüğü gibi her üç algoritma ile yapılan tahminlerde hata oranları arasında önemli farklar görülmemiştir.

YSA, RO ve DVM algoritmaları kullanılarak TQWT yöntemi ile kalp atış hızının tahmin edilmesinde korelasyon katsayılarını ve hata oranlarını gösteren değerler Tablo 4.6'da gösterilmiştir. RO algoritması kullanılarak yapılan tahminlerdeki korelasyon katsayısı, diğer algortimalar kullanılarak yapılan tahminlerdeki katsayılardan daha yüksek değerlerdedir. YSA algoritması kullanılarak yapılan tahminlerde korelasyon katsayısı diğer yöntemlere göre oldukça düşük ve hata oranları da oldukça yüksek çıkmaktadır. Kalp atış hızının belirlenmesinde YSA algoritmasının kullanılabilecek uygun bir algortima olmadığı görülmektedir

Tablolarda görüldüğü gibi TQWT yöntemi ile elde edilen özellikler kullanılarak yapılan kan basıncı ve kalp atış hızı tahmin çalışmasında, Korelasyon Katsayısı, Ortalama Mutlak Hata, Kök Ortalama Kare Hata değerlerini her bir yöntem için tek tek karşılaştırdığımızda doğruluğu yüksek en iyi sonucu Rastgele Orman yönteminin verdiği görülmektedir. Rastgele Orman yönteminde Korelasyon Katsayısı diastolik kan basıncı için 0.6793, sistolik kan basıncı için 0.7273, ve Kalp Hızı için 0.682 olduğu görülmektedir.

TQWT yöntemiyle yapılan kan basınçları ve kalp atış hızı tahminlerinde Korelasyon Katsayılarının, DT-CWT yöntemi ile bulunan değerlerdeki korelasyon katsayılarına oranla daha yüksek çıktığı, hata oranlarının da TQWT yönteminde, DT-CWT yöntemine göre daha düşük değerlerde çıktığı görülmüştür. PPG sinyallerinden kan basınçları elde etmek için kullanılan iki yöntem arasınadan TQWT yöntemini kullanmak daha uygun olduğu görülmüştür. WEKA yazılım programında uygulanan YSA, RO ve DVM algoritmalarından YSA algoritması ile yapılan hesaplamalarda, diğer algoritmalara oranla Korelasyon Katsayısı daha düşük ve hata oranı daha yüksek çıkmaktadır. Korelasyon Katsayıları yükseldikçe hata oranlarının düştüğü ve tahminlerdeki doğruluk oranlarının arttığı tablolardaki sayısal

değerlerden görülmektedir. Sonuç olarak; PPG sinyallerinden kan basıncı ve kalp atış hızı tahminlerinde TQWT yöntemine, RO ve DVM algoritmaları uygulanarak PPG sinyallerinden kan basıncı ve kalp atış hızı tahminleri yapmak daha başarılı sonuçlar vermektedir. Özellikle, TQWT yöntemine RO algoritması uygulanarak yapılan tahminlerde, daha yüksek Korelasyon Katsayısı ile daha düşük hata oranlı kan basıncı ve kalp atış hızı değerleri elde edilmektedir.

Günümüzde koruyucu hekimlik ve insan sağlığının izlenmesine yönelik yapılan çalışmalar yoğun ve hızlı bir şekilde devam etmektedir. Bu çalışmada bazı yöntem ve algoritmalar kullanılarak PPG sinyallerinden kan basıncı ve kalp atış hızının belirlenmesine yönelik çalışmalar yapılmış, tahmin edilen değerlerin Korelasyon Katsayıları ve hata oranları analiz edilmiştir. Halihazırda PPG ölçüm teknikleri ile kalp atış hızı ve EKG ölçen elektronik cihazlar kullanılmaya başlanmıştır. İleriye dönük farklı yöntem ve algoritmalar üzerine yapılacak çalışmalar ile kan basıncı ve kalp atış hızlarının kolay uygulanabilir, non-invazif ve hızlı ölçümler ile belirlenmesinin yaygın bir şekilde günlük hayatta kullanılabileceği düşünülmektedir.

KAYNAKLAR

[1]. Kraitl, J., Hartmut E.,2005, Optical non-invasive methods for characterization of the human health status, *1st International Conference on Sensing Technology*, 21-23 November 2005 Palmerston North, New Zealand.

[2].Hertzman A.B.,1938,The blood supply of various skin areas as estimated by the photoelectric plethysmograph, *American Journal of Physiology*,24(2), 328– 340.

[3]. Allen, J.,2007, Plethysmography and its application in clinical physiological Measurement, *Physiological Meaurement*, 28(3), 1-39.

[4]. Bagha, S., & Shaw, L. ,2011, A real time analysis of PPG signal for measurement of SpO2 and Pulse Rate, *International Journal of Computer Applications, 36*(11),45-50.

[5]. Nafisi, V. B.,& Shahabi, M. ,2018, Intradialytic hypotension related episodes identification based on the most effective features of photoplethysmography signal. *Comput. Methods Programs Biomed. 157* (4), 1–9.

[6]. Übeyli, E. D., Cvetkovic, D., & Cosic, I.,2010, Analysis of Human PPG, ECG and EEG Signals by Eigenvector Methods, Digit. Signal Process, 20 (3), 956–963.

[7]. Yıldırım, Ö.,2017, *Kalp aritmisinin çift dalgaboylu PPG sinyalleri kullanılarak belirlenmesi*, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü.

[8]. Allen, J., & Murray, A.,2003, Age-related changes in peripheral pulse shape characteristics at various body sites, *Physiological Meaurement ,24(2)*, 297–307.

[9]. Shin H. S., Lee C., & Lee M.,2009, Adaptive threshold method for the peak detection of photoplethysmographic waveform, *Computers in Biology and Medicine*, 39(12), 1145-1152.

[10].McDuff D., Gontarek S. & Picard R. W.,2014,Remote detection of photoplethysmographic systolic and diastolic peaks using a digital camera, *IEEE Transactions on Biomedical Engineering*, 61(12), 2948-2954.

[11]. Yousef Q., Reaz M. B. I., Ali, M. A. M. ,2012, The analysis of PPG morphology: investigating the effects of aging on arterial compliance, *Measurement Science Review*,

12(6),266-271.

[12].Johnston,W.,2006, *Development of a Signal Processing Library for Extraction of SpO2, HR, HRV, and RR from Photoplethysmographic Waveforms*,Thesis(Msc) Worcester Polytechnic Institute.

[13]. Foo, J.Y.,& Lim, C. S.,2006, Pulse transit time as an indirect marker for variations in cardiovascular related reactivity, *Technology and health care : official journal of the European Society for Engineering and Medicine*, 14(2), 97-108.

[14]. Peng, F.,Zhang, Z., Gou, X., H. Liu, & Wang,W.,2014,Motion artifact removal from photoplethysmographic signals by combining temporally constrained independent component analysis and adaptive filter, *BioMedical Engineering OnLine*, 13,50.

[15]. M. K. Diab ,2009, Signal Processing Apparatus. U.S. Patent 7,496,393, Masimo Corporation, Irvine, CA.

[16]. Kim, B.S., & Yoo S. K.,2006, Motion artifact reduction in photoplethysmography using independent component analysis,*IEEE Transactions on bio-medical engineering*, 53 (3),566–568.

[17]. Krishnan, R., Natarajan, B, & Warren, S., 2010, Two-stage approach for detection and reduction of motion artifacts in photoplethysmographic data, ,*IEEE Transactions on bio-medical engineering*,57(8),1867–1876.

[18]. Salehizadeh, S. M., Dao, D. K., Chong, J. W., McManus, D., Darling, C., Mendelson, Y., & Chon, K. H.,2014, Photoplethysmograph signal reconstruction based on a novel motion artifact detection-reduction approach. Part II: Motion and noise artifact removal, *Annals of biomedical engineering*, *42*(11), 2251–2263.

[19]. Murray, W. B., & Foster, P. A.,1996, The peripheral pulse wave: information overlooked, *Journal of clinical monitoring*, *12*(5), 365–377.

[20]. Şentürk,Ü., Yücedağ, İ.,& Polat,K.,2018, Cuff-less continuous blood pressure estimation from Electrocardiogram(ECG) and Photoplethysmography (PPG) signals with artificial neural network, *2018 26th Signal Processing and Communications Applications*

Conference (SIU),1-4.

[21]. Suzuki,T., Kameyama, K.,& Tamura, T.,2009, Development of the irregular pulse detection method in daily life using wearable photoplethysmographic sensor *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference*,6080-6083.

[22]. Pham, T. D., Thang, T.C., & Oyama-Higa, M.,& Sugiyama,M.,2013, Mental-disorder detection using chaos and nonlinear dynamical analysis of photoplethysmographic signals, *Chaos, Solitons & Fractals*,51, 64-74.

[23]. Arnold, M. A., Liu, L.,& Olesberg, J. T.,2007, Selectivity assessment of noninvasive glucose measurements based on analysis of multivariate calibration vectors, *Journal of Diabetes Science and Technology*, 1(4), 454–462.

[24]. Lázaro, J., Gil, E., Vergara, J. M., & Laguna, P. ,2014, Pulse rate variability analysis for discrimination of sleep-apnea-related decreases in the amplitude fluctuations of pulse photoplethysmographic signal in children. *IEEE journal of biomedical and health informatics*, 18(1), 240-246.

[25]. Kavsaoğlu, A.R., Polat, K., Bozkurt, M.R.,2014, Temaslı ve temassız PPG sinyallerinin biyometrik tanımada kullanımı ve performans karşılaştırılması, Tıp Teknolojileri Ulusal Kongresi, 26 Eylül 2014 Kapadokya, 167-171.

[26]. Koç, K. O.,& Polat, K.,2017,MATLAB GUI design for heart rate monitoring using smart phone camera, *2017 Medical Technologies National Congress (TIPTEKNO 2017)*, 12-14 Ekim 2017 Trabzon, ISBN: 978-1-5386-0634-6,1-4.

[27]. Korkmaz, O. E. , & AYDEMİR, Ö., 2017, Fotopletismografi İşaretleri Kullanarak Sigara Kullanımının, Cinsiyet ve Açlık–Tokluk Durumunun Belirlenmesi, *IEEE 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*,Antalya,Turkey,1-4.

[28]. Webster,J.G.,1997,*Design of Pulse Oximeters*, Taylor & Francis,New York, ISBN 9780750304672.

[29]. Uçar, M. K., Bozkurt, M. R., Polat, K., & Bilgin, C., 2016, Alternatively new signal for sleep staging processing in patients with Obstructive Sleep Apnea: Photoplethysmography signal, *2016 24th Signal In Signal Processing and Communication Application Conference (SIU)*, 257-260,

[30]. Bailey,J., Fecteau, M., Pendleton, N. L.,2008, *Wireless Pulse Oximeter*, Thesis (BSc), Worcester Polytechnic Institute.

[31]. Jahan E., Barua T., Salma U.,2014, An overview on heart rate monitoring and pulse oxımeter system, *International Journal of Latest Research in Science and Technology*, 3(5),148-152.

[32]. Büyüköztürk, K., 1999, *Türk kardiyoloji derneği ulusal hipertansiyon tedavi ve takip kılavuzu* , https://tkd.org.tr/kilavuz/k03.htm , [Ziyaret tarihi: 13 Mart 2021].

[33]. Cook, S., Togni, M., Schaub, M. C., Wenaweser. P.,& Hess, O.M.,2006, High Heart Rate: A Cardiovascular Risk Factor?, *European Heart Journal*,27(20), 2387-2393.

[34]. Wei C., Sheng L., Lihua G., Yuquan C., & Min P.,2011, Study on conditioning and feature extraction algorithm of photoplethysmography signal for physiological parameters detection, *2011 4th International Congress on Image and Signal Processing*,15-17 october 2011,4,2194-2197.

[35]. Bhoi,A. K.,Sherpa, K. S.,Tamang, J. S., Phurailatpam, D. & Gupta, A. K.,2015,Real time acquisition and analysis of PCG and PPG signals,*2015 International Conference on Communications and Signal Processing (ICCSP)*, April 2-4 2015, India,ISBN 978-1-4799-8080-2,0062-0065,

[36]. Barschdorff, D., Zhang, W., 1994, Respiratory rhythm detection with photoplethysmographic methods, *Proceedings of 16th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2,912-913.

[37]. Epstein, L.J., Kristo, D., Strollo JR, P.J., Friedman, N., Malhotra, A., Patil, S.P., Ramar, K., Rogers, R., Schwab, R. J., Weaver, E. M., Weinstein, M. D., & Adult Obstructive Sleep Apnea Task Force of the American Academy of Sleep Medicine ,2009, Clinical guideline for the evaluation, management and longterm care of obstructive sleep apnea in adults *Journal of clinical sleep medicine : JCSM : official publication of the American Academy of Sleep Medicine*, *5*(3), 263–276.

[38]. Kushida, C. A., Littner, M. R., Morgenthaler, T., Alessi, C. A., Bailey, D., Coleman, J., Jr, Friedman, L., Hirshkowitz, M., Kapen, S., Kramer, M., Lee-Chiong, T., Loube, D. L., Owens, J., Pancer, J. P., & Wise, M.,2005,Practice parameters for the indications for polysomnography and related procedures: an update for 2005,*Sleep*, *28*(4), 499–521.

[39]. Bin, S.,Wang,C., Xiaohui, C., Yongfang, Z., Hanyu, S.,2019,PPG signal motion artifacts correction algorithm based on feature estimation,*Optik*,176,337-349.

[40]. Durand, S., & Froment, J., 2001, Artifact Free Signal Denoising With Wavelets, *IEEE International Conference on Acoustics, Speech, and Signal Processing*, 6, 3685 - 3688.

[41]. Zhang, Y., Zhao, X., Yuan, H., & Zhang, W.,2009, wavelet packet threshold approach to denoising piezoelectricity gyro signal, *2009 International Conference on Computer Engineering and Technology*, 22-24 January, Singapore, 266 - 269.

[42]. Gümüş, İ., 2003, *EKG sinyallerinin wavelet analizi*, Lisans Tezi, Uludağ Üniversitesi Mühendislik Mimarlık Fakültesi Elektronik Mühendisliği Bölümü.

[43]. Taswell, C., 2000, The what, how, and why of wavelet shrinkage denoising, *Computing in Science & Engineering,2(3),12-19.*

[44]. Arı, N., Özen, S., & Çolak, Ö. H., 2008, *Dalgacık teorisi*, Palme Yayıncılık, Ankara.

[45]. Daubechies, I.,1990, The wavelet transform, time-frequency localization and signal analysis", *IEEE Transactions on Information Theory*, 36(5),961- 1005.

[46]. Zhang, Y., Wang, Y.,Wang, W., Liu, B.,2001, doppler ultrasound signal denoising based on wavelet frames, *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 48 (3),709-716.

[47]. Öner, V. İ., Yeşilyurt, M. K., Yılmaz, E. Ç., 2017, wavelet analiz tekniği ve uygulama alanları,*Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 7(1),42-56.

[48]. Fugal, D. L., 2016, *Conceptual wavelets in digital signal processing*, Space & Signals Technical Publishing, USA, ISBN:978-0-9821994-5-9.

[49]. Lu, C.S., Chung, P.C., ve Chen, C.F.,1997, Unsupervised texture segmentation via wavelet transform, *Pattern Recognition*, 30 (5), 729-742.

[50]. Stollnitz, E.J., DeRose, T.D., ve Salesin, D.H., 1995, Wavelets for computer graphics: a primer, *IEEE Computer Graphics and Applications*, 15 (3), 75-85.

[51]. Busch, C., 1995, Wavelet based texture segmentation of multi-modal tomographic images, *Computers & Graphics*, 21 (3), 347-358.

[52]. Polat, H. & Özerdem, M.S.,2016, Farklı Hikayelerden Kaynaklı Oluşan Duyguların EEG İşareti Üzerine Yansıması, *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 9(1),11-18.

[53]. Selesnick, I. W., 2011, Wavelet transform with tunable Q-factor, *IEEE Transactions on Signal Processing*, 59(8), 3560–3575.

[54]. Kong, Y., Wang, T., & Chu, F., 2018, Adaptive TQWT filter based feature extraction method and its application to detection of repetitive transients, *Science China Technological Sciences*, 61, 1556–1574

[55]. Selesnick, W.,Baraniuk, R.G., & Kingsbury, N., 2005, The dual tree complex wavelet transform- a coherent framework for multiscale signal and image processing, *IEEE Signal Processing Magazine*, 22(6),123- 151.

[56]. Kingsbury, NG (1998) The dual-tree complex wavelet transform: a new technique for shift invariance and directional filters, *IEEE Digital Signal Processing Workshop DSP*, August 1998 Bryce Canyon USA, 2543-2560.

[57]. Bal, U.,2012, Dual tree complex wavelet transform based de-noising of opticalmicroscopy images, *Biomedical Optics Express*, 3 (12), 3231–3239.

[58]. Kingsbury, N.,2000, A dual-tree complex wavelet transform with improved orthogonality and symmetry properties, *The IEEE International Conference on Image Processing (ICIP'00)*, September Vancouver, Canada,375 - 378.

[59]. Zhang, Y., Han, T., Lang, B., Li, Y., & Lai, F. (2019). Detection and extraction of shockwave signal in noisy environments,*Journal of Intelligent & Fuzzy Systems, 37*, 4499-4510.

[60]. Hassan, A. R.,2015, A comparative study of various classifiers for automated sleep apnea screening based on single-lead electrocardiogram, *2015 International Conference on Electrical & Electronic Engineering (ICEEE),* November 2015, 45-48.

[61]. Hassan A. R., & Haque M. A.,2015, Computer-aided sleep apnea diagnosis from single-lead electrocardiogram using dual tree complex wavelet transform and spectral features, *2015 International Conference on Electrical & Electronic Engineering (ICEEE)*, November 2015, 49-52.

[62]. Engel, T.A., Charao, A.S., Pinheiro, M.K., & Steffenel, L.A.,2014, Performance İmprovement Of Data Mining İn Weka Through GPU Acceleration, *Procedia Computer Science*, 32, 93 – 100.

[63]. Naik, A.,& Samant, L., 2016, Correlation review of classification algorithm using data mining tool: WEKA , Rapidminer , Tanagra ,Orange and Knime, *Procedia Computer Science*, 85,662 – 668.

[64]. Coşkun, C., & Baykal, A.,2011, Veri Madenciliğinde Sınıflandırma Algoritmalarının Bir Örnek Üzerinde Karşılaştırılması, *XIII. Akademik Bilişim Konferansı*, 2-4 Şubat 2011,İnönü Üniversitesi, Malatya,51-58.

[65]. Yıldız, M., & Şeker, Ş.E.,2016,Veri Madenciliği Araçları (Data Mining Tools), *YBS Ansiklopedi*, 3(4),10-19.

[66]. Demir, G., & Zengin, K.,2016, Weka Yazılımı Kullanılarak Anemi (Kansızlık) Hastalığı Sınıflandırılması, *Elektrik-Elektronik ve Bilgisayar Sempozyumu* .

[67].Gündüz, A. B.,2016, *Adım Adım Weka Kullanımı*, http://www.aysebilge.com/2016/02/adm-adm-weka-kullanm.html, [Ziyaret tarihi:13 Mayıs 2021].

[68]. İşler, Y., Narin, A.,2012,Weka yazılımında k-ortalama algoritması kullanılarak konjestif kalp yetmezliği hastalarının teşhisi,*Teknik Bilimler Dergisi*, 2(2), 21-29.

[69]. Aytaç, M.B.,2013, *Doğrudan pazarlama aracı olarak tele pazarlama için veri madenciliği çözümleri: Banka müşterileri üzerine bir uygulama*, Yüksek Lisans Tezi, Gazi Üniversitesi, Bilişim Enstitüsü, Ankara.

[70]. FAUSETT, L. ,1993, *Fundamentals of neural networks: architectures, algorithmsand applications,* Pearson Education, USA.

[71]. ÖZTEMEL, E.,2003, *Yapay Sinir Ağları*, Papatya Bilim, İstanbul.

[72]. Uslu, M.,2016, *Yapay sinir ağları (YSA) nedir ?,* http://kod5.org/yapay-sinir-aglari-ysa-nedir/, [Ziyaret tarihi:13 Mayıs 2021].

[73]. Kaynar, O , Taştan, S , Demirkoparan, F . ,2012, Yapay sinir ağları ile doğalgaz tüketim tahmini , *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi* ,25 (0) , 464-474.

[74]. Gönül, Y., Ulu, Ş., Bucak, A., Bilir, A.,2015,Yapay sinir ağları ve klinik araştırmalarda kullanımı, *Genel Tıp Dergisi*, 25(3),104-111.

[75].Perner, P.,2009, Machine learning and data mining in pattern recognition, *6th International Conference,* July 23-25 Leipzig, Germany.

[76]. Altaş, D., Gülpınar, V .,2012, Karar ağaçları ve yapay sinir ağlarının sınıflandırma performanslarının karşılaştırılması ,*Trakya Üniversitesi Sosyal Bilimler Dergisi* , 14 (1) , 1-22.

[77]. Fischetti, T., Mayor, E., Forte, R. M., 2017, *R: Predictive Analysis*, Packt Publishing Ltd, ISBN:978-1-78829-037-1.

[78]. Breiman, L.,2001, Random forests, *Machine learning*, 45(1), 5-32.

[79].Breiman, L., Cutler, A., 2004, *Random forest-manual*, http://www.stat.berkeley.edu/~breiman/RandomForests/cc_manual.htm, [Ziyaret tarihi:13 Mayıs 2021].

[80]. Liaw, A., Wiener, M.,2002, Classification and regression by randomForest,*R news*, 2(3), 18- 22.

[81]. Sezer, O. G., Erçil, A., & Keskinöz, M., 2005, Independent component based 3D object recognition using support vector machines, *Proceedings of the IEEE 13th Signal Processing and Communications Applications Conference*, 16-18 May 2005 Kayseri, 99-102.

[82]. Smola, A.J., Schölkopf, B. A.,2004, A tutorial on support vector regression, *Statistics and Computing*, 14, 199–222.

[83]. Acikkar, M., Akay, M.F., Akturk, E.,& Gulec, M.,2013, Intelligent regression techniques for non-exercise prediction of VO(2)max, *2013 21st Signal Processing and Communications Applications Conference(SIU)*, 24-26 April Girne-K.K.T.C., 1-4 ,

[84]. Yakut, E., Elmas, B., Yavuz, S.,2014, Yapay sinir ağları ve destek vektör makineleri yöntemleriyle borsa endeksi tahmini, *Suleyman Demirel University Journal of Faculty of Economics & Administrative Sciences*, 19 (1), 139-157,.

[85].Yakut, E.,2012, *Veri madenciliği tekniklerinden C5.0 algoritması, destek vektör makineleri ile yapay sinir ağlarının sınıflandırma başarılarının karşılaştırılması: İmalat sektöründe bir uygulama*, Doktora Tezi, Atatürk Üniversitesi, Sosyal Bilimleri Enstitütüsü.

[86].Şirin, E.,2021, *Kernel support vector machine (SVM) ile sınıflandırma: R ile örnek uygulama*,https://www.veribilimiokulu.com/kernel-support-vector-machine-svm-ile-siniflandirma-r-ile-ornek-uygulama/,[Ziyaret tarihi:8 Mayıs 2021].

[87].Liang, Y., Chen, Z., Liu, G., & Elgendi, M., 2018, A new short-recorded photoplethysmogram dataset for blood pressure monitoring in China, *Scientific Data*, 5.

[88].Şen, S.,2018, *Korelasyon*, https://sedatsen.files.wordpress.com/2016/11/7-sunum.pdf, [Ziyaret tarihi:22 Nisan 2021].