

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**KRONİK OBSTRÜKTİF AKCİĞER HASTALIĞI TEŞHİSİ İÇİN
MAKİNE ÖĞRENMESİ TABANLI YENİ BİR YÖNTEM
GELİŞTİRİLMESİ**

DOKTORA TEZİ

Engin MELEKOĞLU

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Bilim Dalı

NİSAN 2023

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

KRONİK OBSTRÜKTİF AKCİĞER HASTALIĞI TEŞHİSİ İÇİN
MAKİNE ÖĞRENMESİ TABANLI YENİ BİR YÖNTEM
GELİŞTİRİLMESİ

DOKTORA TEZİ

Engin MELEKOĞLU

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Bilim Dalı

Tez Danışmanı: Prof. Dr. Ümit KOCABIÇAK

NİSAN 2023

Engin MELEKOĞLU tarafından hazırlanan “KRONİK OBSTRÜKTİF AKCİĞER HASTALIĞI TEŞHİSİ İÇİN MAKİNE ÖĞRENMESİ TABANLI YENİ BİR YÖNTEM GELİŞTİRİLMESİ” adlı tez çalışması 06.04.2023 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Bilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Prof. Dr. İsmail Hakkı CEDİMOĞLU
	Sakarya Üniversitesi
Jüri Üyesi :	Prof. Dr. Ümit KOCABIÇAK (Danışman)
	Sakarya Üniversitesi
Jüri Üyesi :	Prof. Dr. Cemil ÖZ
	Sakarya Üniversitesi
Jüri Üyesi :	Prof. Dr. Murat GÖK
	Yalova Üniversitesi
Jüri Üyesi :	Doç. Dr. Halit ÖZTEKİN
	Sakarya Uygulamalı Bilimler Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “KRONİK OBSTRÜKTİF AKCİĞER HASTALIĞI TEŞHİSİ İÇİN MAKİNE ÖĞRENMESİ TABANLI YENİ BİR YÖNTEM GELİŞTİRİLMESİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(06/04/2023)

(imza)

Engin MELEKOĞLU



TEŞEKKÜR

Çalışmamın her aşamasında bana destek olan, yapmış olduğumuz çalışmanın gerekli şekilde ilerleyebilmesi için yolumu aydınlatan ve gerekli ortamı sağlayan değerli danışman hocam Prof. Dr. Ümit KOCABIÇAK'a, tez süresince bilgi ve tecrübelerini paylaşmaktan hiçbir zaman çekinmeyen yoluma ışık tutan Doç. Dr. Muhammed Kürşad UÇAR'a teşekkür ederim. Ayrıca, veri toplama konusunda Doç. Dr. Cahit BİLGİN'e, kod yazma aşamasında Prof. Dr. Mehmet Recep BOZKURT'a ve makine öğrenmesi modelinin geliştirilmesinde Prof. Dr. Murat GÖK'e katkılarından dolayı teşekkürlerimi sunarım.

Hayatımın her aşamasında olduğu gibi bu meşakkatli süreci de en az hasarla atlatmamı sağlayan değerli eşim Sibel MELEKOĞLU'na, sonsuz sevgi ve motivasyon kaynağım olan kızlarım Sara ve Ada ya, benim bu başarıya ulaşma sürecinde sevgi ve desteklerini esirgemeyen kıymetli aileme, teşekkürlerimi borç bilirim.

Çalışmamızın gelecekte yapılacak araştırmalara ışık tutmasını, bilim yolunda bir meşalenin de bu çalışma tarafından yakılmış olmasını canı gönülden dilerim.

Engin MELEKOĞLU



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SİMGELER	xiii
TABLO LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET	xix
SUMMARY	xxi
1. GİRİŞ	1
1.1. Amaç ve Kapsam	1
1.2. Literatür Araştırması	4
1.3. Hedef ve Katkıları	6
2. KRONİK OBSTRÜKTİF AKCİĞER HASTALIĞI	7
2.1. Giriş	7
2.2. Kronik Obstrüktif Akciğer Hastalığı Nedir ve Nedenleri	7
2.2.1. Kronik obstrüktif akciğer hastalığı belirtileri	8
2.3. Kronik Obstrüktif Akciğer Hastalığı Teşhisi	8
2.4. Kronik Obstrüktif Akciğer Hastalığı İstatistikleri	10
2.5. Kronik Obstrüktif Akciğer Hastalığı (KOA) Tedavisi	10
2.5.1. İlaç tedavisi ve davranışsal değişiklikler	12
2.5.2. Bronkodilatör cihaz tedavisi	12
2.5.3. Kronik obstrüktif akciğer hastalığında psikolojik tedavi yöntemleri	13
2.5.4. Kronik obstrüktif akciğer hastalığında cerrahi tedavisi	13
3. FOTOPLETİSMOGRAFİ SİNYALİ VE İNCELENMESİ	15
3.1. Fotopletismografi Sinyalinin Oluşumu ve Ölçülmesi	15
3.2. Fotopletismografi Sinyallerin Hastalıkla İlişkisi	17
3.3. Fotopletismografi ve Elektrokardiyografi İlişkisi	19
3.4. Fotopletismografi ve Teknolojik Uygulamalar	20
4. FOTOPLETİSMOGRAFİK İLE KRONİK OBSTRÜKTİF AKCİĞER HASTALIĞI TESPİT MODELİNİN GELİŞTİRİLMESİ	23
4.1. Veri Toplama	24
4.2. Fotopletismografi Sinyallerinin Filtrelenmesi	25
4.3. Fotopletismografi Sinyallerinin Epoklanması	26
4.4. Fotopletismografi Sinyalinin Frekans Bantlarına Ayrılması	28
4.5. Özellik Çıkarımı	29
4.6. Özellik Seçimi	31
4.6.1. Fisher algoritması	32
5. MAKİNE ÖĞRENMESİ ALGORİTMALARI VE PERFORMANS DEĞERLENDİRME KRİTERLERİ	35
5.1. Makine Öğrenmesi Algoritmaları	35
5.1.1. Destek vektör makinaları	36

5.1.2. k-en yakın komşuluk algoritması	39
5.1.3. Naive bayes algoritması	41
5.1.4. Rastgele orman algoritması	42
5.1.5. Çok katmanlı algılayıcı ağ.....	42
5.1.6. Ensemble tree	43
5.1.7. Karar ağaçları	44
5.1.8. Hibrit yapay zekâ yöntemi	45
5.2. k-Kat Çapraz Doğrulama Yöntemi	46
5.3. Performans Metrikleri.....	47
5.4. Leave-One Out Yöntemi	49
6. SONUÇLAR	53
6.1. Kronik Obstrüktif Akciğer Hastalığı Minimum Süre Tespiti Modeline Dayalı Sonuçlar.....	53
6.2. Fotopletismografi Alt Frekans Bantları Ayrımına Dayalı Kronik Obstrüktif Akciğer Hastalığının Tahmin Sonuçları.....	57
7. TARTIŞMA VE SONUÇ	71
7.1. Kronik Obstrüktif Akciğer Hastalığı Minimum Süre Tespiti Modeline Dayalı Tartışmalar.....	71
7.2. Fotopletismografi Alt Frekans Bantları Ayrımına Dayalı KOAH Tahmin Tartışmaları.....	71
7.3. Kararlar.....	73
7.4. Bilgilendirme	74
KAYNAKLAR.....	75
EKLER.....	85
ÖZGEÇMİŞ.....	91

KISALTMALAR

AC	: Alternatif akım
ADD	: Ampirik Dalgacık Dönüşümü
AI	: Yapay Zeka
ALL	: Tüm özellikler
AUC	: Area under an receiver operating characteric
BMI	: Vücut Kitle İndeksi
COPD	: Chronic Obstructive Pulmonary Disease
DC	: Doğru akım
EKG	: Elektrokardiyograf
ET	: Ensemble Tree
FN	: Yanlış negatifler
FP	: Yanlış pozitifler
GOLD	: Global İnitative
HF	: Yüksek frekans bandı
HRV	: Heart Rate Variability
HYY	: Hibrit Yapayzeka Yöntemi
KA	: Karar Ağaçları
k-NN	: K-en yakın komşuluk sınıflandırma algoritması
KOAH	: Kronik Obstrüktif Akciğer Hastalığı
LB	: Alt güven aralığı
LF	: Alçak frekans bandı
MDI	: Metered dose inhaler
MF	: Orta frekans bandı
MLFFNN	: Çok katmanlı ileri beslemeli yapay sinir ağıları
PDK	: Performans Değerlendirme Kriterleri
PPG	: Fotopletismografi
ROC	: Receiver operating characteric
SVD	: Singular value decomposition (Tekil değer ayrışımı)
SVMs	: Destek vektör makinaları
TC	: Türkiye Cumhuriyeti

TN : Gerçek negatif
TP : Gerçek pozitif



SİMGELER

A	: Aktivite- Hjort parametresi
C	: Karmaşıklık- Hjort parametresi
CL	: Ortalama eğri uzunluğu
CM	: Merkezi Momentler
E	: Ortalama Enerji
F	: F-score değeri
G	: Geometrik ortalaması
H	: Harmonik ortalama
k	: kNN için en yakın komşu sayısı
M	: Hareketlilik -Hjort parametresi
m	: Metre
m²	: Metre kare
MAD	: Ortalama ya da meydan mutlak sapma
Max	: Maksimum
Min	: Minimum
MHz	: Megahertz
N	: Vektör eleman sayısı
N	: Negatif
n	: Toplam birey sayısı
n1	: Kadın birey sayısı
n2	: Erkek birey sayısı
Ort	: Ortalama
P	: Pozitif
R	: Eta
R	: Aralık
S	: Standart sapma
S²	: Varyans
S_x	: Standart hata
SF	: Şekil faktörü
sn	: Saniye

Std	: Standart sapma
T	: Periyot sayısı
T25	: kırılmış ortalama %25
T50	: kırılmış ortalama %50
TE	: Ortalama teager enerjisi
Y	: N sayıdaki sınıflandırıcıların ortak kararı
Y_{Maks}	: Epok içindeki yerel maksimum sayısı
Y_{Min}	: Epok içindeki yerel minimum
λ	: Dalga boyu
μV	: Mikro volt
®	: Tescillidir (Register)
$\bar{x}$	: Ortalama
x	: Medyan
x_i	: i. özelliğin ortalama değeri
x_+	: Pozitif sınıftaki i. özelliğin ortalama değeri
x_-	: Negatif sınıftaki i. özelliğin ortalama değeri
$X_{k,i}$	: i. özelliğin k. pozitif örneği
$X_{k,i}$	: i. özelliğin k. negatif örneği
X_{kur}	: Basıklık (Kurtosis)
X_{max}	: Maksimum
X_{min}	: Minimum
X_{rms}	: Ortalama karakök değeri (Root mean squared value)
x_{ske}	: Çarpıklık (Skewness)

TABLO LİSTESİ

Sayfa

Tablo 2.1. Hava akımı kısıtlılığının şiddetinin derecelendirilmesi.	12
Tablo 4.1. BMI Vücut Kitle İndeksi.....	25
Tablo 4.2. Epok Dağılımları.....	26
Tablo 4.3. İki saniyelik epok dağılımları.	27
Tablo 4.4. Üç alt frekans bant aralığı.	28
Tablo 4.5. Fotopletismografi sinyaline ait özellikler denklem.....	30
Tablo 4.6. Tüm veri seti için sinyallerden seçilen özelliklerin listesi.	32
Tablo 5.1. Karmaşıklık matrisi.....	47
Tablo 5.2. Kappa katsayıları sınır aralıkları	49
Tablo 5.3. Makine öğrenmesi için süreye bağlı eğitim (%50) ve test (%50) veri seti dağılımı	50
Tablo 5.4. Leave-one-out yöntemine göre makine öğrenmesi için süreye bağlı eğitim ve test veri seti dağılımı.	51
Tablo 5.5. (%50) Eğitim ve (%50) Test.	51
Tablo 6.1. Tüm özellikler için eğitim performans sonuçları	54
Tablo 6.2. Tüm özellikler için test performans sonuçları.....	55
Tablo 6.3. Seçilmiş özellikler için eğitim performans sonuçları.....	55
Tablo 6.4. Seçilmiş özellikler için Test performans sonuçları	56
Tablo 6.5. Leave-one-out için Eğitim Performans Sonuçları.....	56
Tablo 6.6. Leave-one-out için Test Performans Sonuçları.....	56
Tablo 6.7. Tüm kayıtlar için tüm özelliklere göre elde edilen sonuçlar.....	57
Tablo 6.8. PPG sinyalleri özellik seçme performans sonuçları.....	59
Tablo 6.9. PPG LF sinyalleri özellik seçme performans sonuçları	61
Tablo 6.10. PPG MF sinyalleri özellik seçme performans sonuçları	63
Tablo 6.11. PPG HF sinyalleri özellik seçme performans sonuçları.....	65
Tablo 6.12. PPG ALL sinyalleri özellik seçme performans sonuçları	67



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. Normal ve KOAH hastalığı örneği	8
Şekil 2.2. Spirometri kontrolü.....	9
Şekil 2.3. Bronkodilatör cihazı.	13
Şekil 3.1. PPG sinyal ölçümleri için yansıma ve iletim modları	16
Şekil 3.2. Işığın dokularda ve kan damarlarında soğurulması	17
Şekil 3.3. PPG ve EKG sinyalleri.	21
Şekil 3.4. PPG giyilebilir teknolojileri.....	22
Şekil 4.1. KOAH teşhisi için minimum süre tespit akış diyagram.	23
Şekil 4.2. KOAH hastalığının PPG sinyali ile yapay zekâ tabanlı geliştirilmiş bir yöntem akış diyagram.	24
Şekil 4.3. Fotopletismografi (PPG) sinyaline ait periodogram grafiği	29
Şekil 5.1. SVMs algoritması genel akış diyagramı.....	37
Şekil 5.2. kNN algoritması genel akış diyagramı	45
Şekil 5.3. Karar ağaçları genel yapısı.	49
Şekil 5.4. Hibrit Yapay zekâ modeli algoritması genel akış diyagramı.....	46
Şekil 6.1. PPG sinyalleri özellik seçme sonuçları.	68
Şekil 6.2. PPG LF sinyalleri özellik seçme sonuçları.....	69
Şekil 6.3. PPG MF sinyalleri özellik seçme sonuçları.....	69
Şekil 6.4. PPG HF sinyalleri özellik seçme sonuçları.	70
Şekil 6.6. PPG ALL sinyalleri özellik seçme sonuçları.....	70



KRONİK OBSTRÜKTİF AKCİĞER HASTALIĞI TEŞHİSİ İÇİN MAKİNE ÖĞRENMESİ TABANLI YENİ BİR YÖNTEM GELİŞTİRİLMESİ

ÖZET

Geçmiş ve Amaç: Kronik Obstrüktif Akciğer Hastalığı KOAH nefes almayı zorlaştıran ve zamanla kötüleşen bir tür akciğer hastalığıdır. Normalde, ciğerlerimizdeki hava yolları ve hava keseleri elastik veya esnektir. Nefes aldığınızda, hava yolları hava keselerine hava getirir. Hava kesecikleri küçük bir balon gibi hava ile dolar. Nefes verdiğimizde hava keseleri şişer ve hava dışarı çıkar. KOAH'ınız varsa, bir veya daha fazla sorun nedeniyle solunum yollarına daha az hava girer ve çıkar. KOAH kalıcı bir hastalık olarak, zamanla tedavi edilmezse tedavisi zorlaşır, bu hastalığın en büyük nedeni sigara, zararlı partiküller, dışardaki çevresel etkenler ve gazlar sebebi sonucu meydana gelmektedir. Özellikle küçük çocuk, engelli veya ilerlemiş seviyedeki hastaların spirometre aracını kullanma zorlukları ve hastaneye erişimindeki zorlukları, teşhis sürecinin kolaylaştırılması ve kısaltılmasını zorunlu kılmaktadır. Bu sorunların önüne geçebilmek, KOAH'ta erken teşhis ve daha kolay takip için KOAH teşhisinde Fotopletismografi (PPG) sinyalinin kullanımının faydalı olacağı değerlendirilmektedir. PPG, deri yüzeyinden vücudun herhangi bir yerinde ölçülebilen bir biyosinyaldir. Kalbin her atışında oluşan PPG sinyal ölçümü kolay bir sinyaldir. Literatürde PPG sinyalinin vücuda ait oldukça fazla bilgi içerdiği bilgisine yer verilmiştir. Bu çalışmada PPG sinyalinin KOAH teşhisini kullanılabilmesi için makine öğrenmesi yöntemiyle KOAH tahmin modelleri geliştirilmiştir.

Yöntemler: Bu çalışmada PPG sinyalinin KOAH teşhisinde kullanılabilmesi için bir sistem tasarımı yapılmıştır. Çalışmanın amacı "PPG ile KOAH teşhis edilebilir mi?" ve "Edilebilir ise en az kaç saniyelik sinyal yardımı ile bu işlem yapılabilir?" bunu belirlemektir. Bu amaç doğrultusunda çalışma için 14 bireyden (8 KOAH, 6 Sağlıklı) ortalama 7-8 saatlik PPG kaydı alınmıştır. Alınan kayıtlar 2, 4, 8, 16, 32, 64, 128, 256, 512 ve 1024 saniyelik parçalara ayrılmıştır. Her saniye grubu için işlemler yapılmış ve hangi saniyelik sinyallerle daha performanslı teşhis yapılabildiği tespit edilmeye çalışılmıştır. Hasta bireye ait 8 saatlik kayıtlar 2 saniyelik parçalara ayrıldığında her parçaya hasta etiketi verilmiştir. Aynı işlem sağlıklı birey için yapıldığında tüm parçalara Sağlıklı etiketi verilmiştir. Her bir sinyal grubu öncelikle 0.1-20 Hz sayısal filtreleme yöntemiyle temizlenmiştir. Ardından 25 adet zaman domeninde özellik çıkarılmıştır. En sonunda oluşan veri setleri (2, 4, 8. sn) karar ağaçları makine öğrenmesi yöntemleri ile sınıflandırılmıştır.

Çalışmada PPG sinyali gürültüden temizlenmiş ve PPG'nin üç alt frekans bantlarına sahip yeni PPG sinyalleri elde edilmiştir. Dört sinyalden her birinden 25 adet özellik çıkarılmıştır. Toplam 100 adet özellik çıkarılmıştır. Buna ek olarak yaş, kilo ve boy özellik olarak kullanılmıştır. Performansın artırılması amacıyla Fisher özellik seçme algoritması kullanılmıştır.

Sonuçlar: Geliştirilen PPG tahmin modelleri tüm bireyler için doğruluk oranı 0.95 performans değerlerine sahiptir. Özellik seçme algoritmasında kullanılan sınıflandırma algoritmaları performans artışına yardımcı olmuştur.

Çözüm: Elde edilen sonuçlara göre 2 saniyelik veri grubu ile en yüksek performans değerlerine ulaşılmış olup 0.99 duyarlık, 0.99 özgüllük ve %98.99 doğruluk oranı elde edilmiştir.

Elde edilen sonuçlara göre PPG bazlı KOAH tahmin modelleri pratikte kullanılabileceği düşünülmektedir.



DEVELOPMENT OF A NEW MACHINE LEARNING-BASED METHOD FOR THE DIAGNOSIS OF CHRONIC OBSTRUCTIVE PULMONARY DISEASE

SUMMARY

Chronic Obstructive Pulmonary Disease (COPD) is a widespread respiratory disorder disease. COPD is a common disease, characterized by airway and / or persistent respiratory symptoms and airway restriction caused by significant exposure to harmful particles or gases, which can be prevented and treated. COPD constitutes a significant portion of chronic respiratory diseases. COPD is one of the most important causes of morbidity and mortality and with each passing day it continues causing increasing substantial economic and social burden. With the expected prolongation of the life expectancy and increased exposure worldwide, the burden of COPD is predicted to increase further. According to the World Health Organization (WHO) it is the fourth leading cause of death worldwide. Approximately 2.9 million people die annually due to COPD worldwide.

The main pathological characteristic of chronic obstructive pulmonary disease (COPD) is chronic respiratory obstruction. COPD is a permanent, progressive disease and is caused by harmful particles and gases entering the lungs. Chronic coughing and shortness of breath are the most important symptoms of the disease. Cigarette smoke is one of the main casual factors of these symptoms.

The cigarette smoke fills the airways and alveoli with harmful gases and substances, in course of time, these harmful substances cause damage to the structure of the bronchi and alveoli, resulting in the development and progression of COPD.

Since there is not sufficient information about the disease, diagnosis and thus the treatment of the disease are delayed. The diagnosis of the disease is made by the specialist doctor according to the report obtained from the spirometer device, which is the standard method in diagnosis. This method can be applied only in hospitals with the help of a technician. However, monitoring the disease after diagnosis is also important for tracking the damages caused by the disease to the body. Therefore, it is vital to have an early and fast diagnosis process. As COPD is a progressive disease with permanent damages, the earlier it is diagnosed and treated, the less damage it causes to the individuals. Same as with any other disease, monitoring of the disease during the treatment is possible with advanced equipment and only in hospitals. This process is very difficult and time consuming.

At present, COPD diagnosis can be made with an apparatus called a spirometer. After measurement of Forced vital Capacity (FVC) and Forced expiratory volume in one second; (FEV 1), by evaluating the FEV 1/FV C ratio, the person can be diagnosed by a specialist doctor. If the FEV 1/FVC is < 70% the patient is considered to have COPD. The difficulty of using the spirometer apparatus and the difficulties in accessing the hospital, especially for young children, disabled or patients in advanced stages of illness, necessitates facilitating and shortening the diagnosis process. Due to the disadvantages associated with current methods of diagnosing chronic obstructive

pulmonary disease (COPD), it is necessary to develop systems that are easier to use and to follow up with patients. To address these issues and expedite the diagnosis of COPD, the use of photoplethysmography (PPG) signals is being considered. PPG is a biologic signal that can be measured in any location near the heart in the body. Its potential usefulness lies in its ability to facilitate faster diagnosis and easier patient monitoring.

Heart signals convey vital information about the body and illness. Therefore, based on the obtained results, it has been evaluated that it can be used in the diagnosis of COPD. In this study, a PPG signal-based COPD diagnosis algorithm is proposed. It is expected that the developed method will create an infrastructure for the production of the cost-effective portable apparatus for the disease diagnosis. In recent years, in the diagnosis of diseases; various researches areas are being carried out on usability of some new and helpful classifier, decision making software and tools. One of these areas is artificial intelligence applications. It is clear that these systems will provide advantages such as assistance in making the diagnosis, shortening the diagnosis time, efficiency and increased productivity which will be beneficial in the medical field. In this study, the intention is to make diagnosis of COPD disease with the machine learning algorithm only by using the PPG signal belonging to a patient.

One of the general aims of this study is to make easier the diagnosis of COPD by using the machine learning method, to assist in determination of the COPD diagnosis. In addition, the improvement of parameters such as diagnosis duration, efficiency and time are among the objectives. This study was carried out by using the PPG signal in compliance with the principles of the Global Initiative for Chronic Obstructive Lung Disease (GOLD).

Background and Purpose: COPD, which is named with the initials of the words Chronic Obstructive Pulmonary Disease is a main public health issue both globally and in our country, which continues to increase due to poor awareness of the disease and lack of necessary preventive measures. COPD disease is the result of a blockage of the air sacs known as alveoli withinside the lungs; it's miles a persistent sickness that reasons proceedings difficulty in breathing, cough and shortness of breath. COPD is characterised with breathing signs and symptoms and airflow challenge because of anomalies in the airways and alveoli that occurs as the result of significant exposure to the harmful particles and gases. The spirometry test (breath measurement test), which is being used for the diagnosis of the COPD is creating difficulties in reaching the hospitals, especially in patients with disabilities or advanced disease, and in children. With facilitate the diagnostic treat and prevent these problems, it's far evaluated that using Photoplethysmography (PPG) signal in the diagnosis of COPD disease would be beneficial in order to simplify and speed up the diagnosis process and make it more convenient for monitoring. A PPG signal includes numerous components, including volumetric changes in arterial blood that are related to heart activity, fluctuations in venous blood volume that modify the PPG signal, a Direct Current (DC) component that shows the optical properties of the tissues, and modest energy changes in the body. PPG has typically received the usage of a pulse oximeter, which illuminates the pores and skin and measures adjustments in mild absorption. PPG occurring with every heart rate is an easy signal to measure. PPG signal is modeled by machine learning to predict COPD.

Methods: In this study, a system design was made so that the PPG signal can be used in the diagnosis of COPD. The aim of the study was “Can COPD be diagnosed with

PPG?” and “If possible, this operation can be done with the help of at least how many seconds of signal?” is to determine it. For this purpose, an average of 7-8 hours of PPG recording was taken from 14 individuals (8 COPD, 6 healthy) for the study. The received recordings are divided into 2, 4, 8, 16, 32, 64, 128, 256, 512 and 1024 second segments. Operations have been made for each second group and it has been tried to determine which second signals can be diagnosed with better performance. When the 8-hour recordings of the patient were divided into 2-second pieces, each piece was given a patient label. When the same process is done for a healthy individual, all parts are labeled as Healthy. Each signal group was first cleaned with 0.1-20 Hz digital filtering method. Then, features were extracted in 25 time domains. Finally, the resulting data sets (2, 4, 8. sec) were classified by decision trees using machine learning methods.

During the studies, the PPG signal was filtered to remove noise, resulting in a new PPG signal consisting of three (3) low-frequency bands. From each of the four (4) extracted signals, twenty-five (25) features were obtained, resulting in a total of one hundred (100) features. Furthermore, weight, height, and age were also used as characteristics. The Fisher method was employed in the feature selection process to enhance performance. The purpose of using this method is to improve the performance effectiveness of the feature selection process.

Results; According to the results of this study, it was concluded that COPD diagnosis can be made based on machine learning with PPG signal and biomedical signal processing techniques. In addition, it was determined how long a PPG record is needed. Just with only 2 second record the accuracy rate of 95.31% was obtained. These results are an indication that COPD diagnosis has practical diagnostic methods.

According to the results obtained, the highest performance values were achieved with the data group of 2 seconds, and 0.99 sensitivity, 0.99 specificity and 98.99% accuracy rate were obtained.

The enhanced PPG prediction models have demonstrated an impressive accuracy rate of 0.95 for all individuals. The utilization of classification algorithms in the feature selection process has significantly contributed to the improvement in overall performance.

As a conclusion, the important parts of the study can be summarized as, (1) easy-to-use, (2) artificial intelligence-based, (3) very low-cost (4) reliable biomedical system that makes decisions based on signal measurement data has been developed. We hope this study will open up new horizons for COPD diagnosis.

1. GİRİŞ

1.1. Amaç ve Kapsam

Kronik Obstrüktif Akciğer Hastalığı (KOAH), nefes almakta güçlük çekme ve zamanla kötüleşen bir tür akciğer hastalığıdır. Zamanında tedbir alınırsa hastalığın önlenmesi ve tedavisi daha kolay olan bir akciğer hastalığıdır. KOAH'lı kişiler nefes almak için daha çok çalışmak zorundadır, bu da nefes darlığına ve/veya yorgun hissetmeye yol açabilir. Hastalığın erken döneminde, KOAH'lı kişiler egzersiz yaptıklarında nefes darlığı hissedebilirler. Hastalık ilerledikçe, nefes vermek hatta nefes almak zorlaşabilir, yaygın olan diğer belirtiler arasında balgamlı öksürük ve hırıltı yer alır. Kronik Obstrüktif Akciğer Hastalığı (KOAH) olan bir kişinin, hastalığın farklı türleri olan obstrüktif bronşiolit (bronşi-oh-lite-is), amfizem (akciğerlerdeki hava keseciklerinde (alveollerde) hasar ve genişlemeye neden olan bir akciğer hastalığı) veya her iki türün kombinasyonuna sahip olabileceğini belirtiyor. Bu koşulların her birinin miktarı kişiden kişiye değişir. KOAH kalıcı bir hastalık olarak, zamanla tedavi edilmezse tedavisi zorlaşır, bu hastalığın en büyük nedeni sigara, zararlı partiküller, dışardaki çevresel etkenler ve gazlar sebebi sonucu alveollerde gelişen anomalilere bağlı solunumsal semptomlar ve hava akımı kısıtlanması ile meydana gelmektedir [1–4].

Normalde, ciğerlerimizdeki hava yolları ve hava keseleri elastik veya esnektir. Nefes aldığınızda, hava yolları hava keselerine hava getirir. Hava kesecikleri küçük bir balon gibi hava ile dolar. Nefes verdiğimizde hava keseleri şişer ve hava dışarı çıkar. KOAH'ınız varsa, bir veya daha fazla sorun nedeniyle solunum yollarına daha az hava girer ve çıkar. Yaşanan sorunlar genel olarak Akciğerlerimizdeki hava yolları ve hava keseleri daha az elastik hale gelir, Hava keselerinin birçoğu arasındaki duvarlar yıkılmıştır, Hava yollarının duvarları kalınlaşır ve iltihaplanır ve Hava yolları normalden daha fazla mukus yapar ve tıkanabilir. KOAH'lı bazı kişiler, soğuk algınlığı ve grip gibi sık sık solunum yolu enfeksiyonlarına yakalanır. Şiddetli vakalarda KOAH kilo kaybına, alt kaslarınızda güçsüzlüğe ve ayak bilekleri, ayaklar veya bacaklarda şişmeye neden olabilir. Belirtiler en önemli özelliklerinden bir sigara dumanıdır.

Sigarayı aktif olarak içenler ve etrafında pasif olarak sigara dumanına maruz kalanlar, KOAH'tan etkilenebilirler. KOAH genellikle, zararlı maddelere uzun süre maruz kalan kişilerin akciğerleri ve solunum yollarına zarar vermesi nedeniyle oluşur. Bu hastalığı en çok tetikleyen ana nedenlerden biri sigara dumanıdır. Pipo, puro ve diğer tütün dumanı türleri de özellikle onları solursanız, KOAH'a neden olabilir. Soluk almakta tahriş edici maddelere maruz kalma KOAH'a katkıda bulunabilir [5–7]. KOAH hastalığı Ülkemizde olduğu gibi Dünyada da önemli bir sağlık sorunlarından biridir, yeterince tespit edilmemesi ve gerekli koruyucu önlemlerin alınmaması nedeniyle artarak devam etmektedir. KOAH adını Kronik Obstrüktif Akciğer Hastalığı kelimesinin baş harfinden almaktadır, bronş ismi verilen akciğerlerdeki hava keseciklerde tıkanma sonucu ortaya çıkıyor. Nefes almada güçlük, nefes darlığı ve öksürük ya da balgamlı öksürük gibi belirtilere neden olan kronik bir hastalıktır. KOAH hastalığının teşhisi için, çocuklarda, engelli kişilerde ve ileri aşamada olan hastalarda kullanılan spirometre (nefes ölçüm testi) gibi cihazların kullanımı, hastaneye ulaşım zorlukları nedeniyle sınırlıdır. Teşhis süreci kolaylaştırılması için ve bu sorunların önüne geçebilmek için KOAH hastalığında teşhis sürecini kolaylaştırmak için süreci hızlandırmak ve takibini kolaylaştırmak için teşhisinde Fotopletismografi (PPG) sinyalinin kullanımının faydalı olacağı değerlendirilmektedir.

Fotopletismografi (PPG), her kalp atışıyla dokunun mikrovasküler yatağındaki kandaki hacmi değişikliklerini belirlemek için kullanılabilen basit, maliyeti düşük bir optik tekniğidir. Genellikle cilt yüzeyinde non-invaziv olarak veya görüntüleme PPG'si kullanılarak uzaktan kullanılır. Kalbin her atımında Oluşan PPG ölçümü kolay bir sinyaldir. KOAH teşhisi için kullanılan PPG sinyalinin makine öğrenmesi yöntemiyle KOAH tahmini modellenmiştir[6]. Dünya Sağlık Örgütüne (DSÖ) göre dünyada en yaygın dördüncü ölüm sebebidir. Dünya çapında, her sene 2,9 milyon kişi KOAH'tan ölmektedir.

İnsanlar tarafından KOAH hastalığı yeterince anlaşılamaması nedeniyle tanısını koymak ve dolayısıyla tedavisinde gecikmektedir. Hastalığın tanısı uzmanlar tarafından spirometre cihazlarından alınan raporlara göre konur ve standart tanı yöntemidir. Bu yöntem sadece hastanelerde bir teknisyen yardımıyla kullanılabilir. Ancak hastalığın teşhisi konulduktan sonraki takip, hastalığın vücuda verdiği hasarın takibi için de önemlidir. Bu nedenle, erken ve zamanında teşhis süreci çok önemlidir. KOAH kalıcı

hasara neden olduğunda erken tanıda tedavi edilirse organlara daha az zarar verebilir. Bu hastalığın tedavisi zaman alıcı ve zahmetli bir iştir. Süreci izlemek içinde sadece hastanede gelişmiş ekipmanlarla mümkündür [2]. Günümüzde KOAH teşhisi, spirometre adı verilen cihaz ile yapılabilir.

Günümüzde KOAH teşhisi, spirometre adı verilen cihaz ile yapılabilir. FVC zorlu vital kapasite olarak da bilinen maksimum nefes hacmi dışarı verildiğinde ölçülen bir değerdir. FEV1 değeri ise kronik obstrüktif akciğer hastalığının (KOAH) değerlendirilmesi ve hastalığın ilerlemesinin izlenmesinde önemli bir gösterge olarak kullanılmaktadır. FEV, zorlu ekspirasyon hacminin kısaltmasıdır. FEV1, ciğerlerimizden bir saniyede çıkarabileceğiniz hava miktarıdır. Olgun kişilerde FEV1/FVC oranı %70 ile %80 arasındadır; %70'in altındaki bir değer hava akımı sınırlamasını ve KOAH olasılığını gösterir [3, 8–10]. Özellikle küçük çocuk, engelli veya ilerlemiş seviyedeki hastaların spirometre aracını kullanma zorlukları ve hastaneye erişimindeki zorlukları, teşhis sürecinin kolaylaştırılması ve kısaltılmasını zorunlu kılmaktadır [3, 11, 12]. Bu dezavantajlar sebebiyle KOAH teşhisinin daha pratik bir şekilde yapılabilmesi için kullanımı ve takibi kolay sistemlerin geliştirilmesine ihtiyaç vardır [9, 13]. Bu sorunların önüne geçebilmek, KOAH tanısını kısa sürede yapıp hastalığın tedavisine başlamak ve takibi kolaylaştırmak için KOAH teşhisinde Fotopletismografi PPG sinyalinin kullanımının faydalı olacağı değerlendirilmektedir [3]. PPG (fotopletismografi) vücudun herhangi bir yerinde ölçülebilen bir sinyaldir, ancak kılcal damarların yoğun olduğu bölgelerde ölçülmesi daha doğru sonuçlar verir. Kılcal damarların yoğun olduğu bölgelerin başında ise parmak ve kulak memesidir. Bu nedenle, PPG ölçümleri genellikle parmakta veya kulak memesinde yapılır. Bu bölgeler, yüzeydeki kan akışını yansıtan ışık sinyallerinin algılanması için uygun bir konumdadır. Bu nedenle, PPG ölçümleri, nabız, kan basıncı ve diğer kardiyovasküler ölçümler için yaygın olarak kullanılan bir yöntemdir. Kalp sinyalinin, insan vücudunda hastalıkla ilgili önemli bilgiler barındırdığı ve elde edilecek çalışma sonuçlarına göre, KOAH teşhisinde kullanılabileceği değerlendirilmektedir. Bu çalışmada, PPG sinyali tabanlı KOAH teşhis algoritması önerilmektedir. Geliştirilen yöntemin hastalığın teşhisi için maliyeti düşük ve giyilebilir cihazların üretimi için de bir altyapı oluşturması beklenmektedir.

Son senelerde KOAH ve diğer hastalıkların tanısında sınıflandırma algoritmaları, çeşitli yazılımlarla cihazlar üzerinde kullanılabilirliği üzerinde çeşitli çalışmalar

yapılmaktadır. Bu alanlardan biri de yapay zekâ uygulamalarıdır. Tanının konulmasında yardımcı olabilecek, tanının süresinin kısalması, gayret tasarrufu ve verimlilik artışı gibi faydalar sağlayacak sistemlerin medikal alanda yararlı olacağı açıktır. Bu çalışmada KOAH, sadece hastaya ait PPG sinyali kullanılarak makine öğrenmesi algoritmaları ile teşhis edilmesi amaçlanmaktadır.

1.2. Literatür Araştırması

Her geçen gün hızla kirlenen atmosfer, artan çevre kirliliği, zorlu şehir hayatı ve tütün ürünlerinin kullanımı nedenleriyle; göğüs hastalıkları günümüzün en büyük sağlık problemlerindendir [14, 15].

Önlenebilir ve tedavi edilebilir yaygın bir hastalık olan KOAH, genellikle ilerleyici özellikteki kalıcı hava akımı kısıtlanması ile karakterize edilmekte, zararlı gaz/partiküllere karşı havayolları ve akciğerin artmış kronik inflamatuvar yanıtı ile ilişkilendirilmektedir.

Dünyanın farklı bölgelerinde değişkenlik göstermekle beraber, nüfusun %5 ile %20 aralığında KOAH görülmektedir. Dünya Sağlık Örgütü verilerine göre dünyada en sık öldüren dördüncü hastalıktır ve 2030 yılında üçüncü hastalık olması beklenmektedir. DSÖ'ne göre KOAH dünyada en sık sakat bırakan hastalıklar arasında 13. sıradadır. Çok sık görülen bir hastalık olmasına rağmen hastaların doktora başvuruda gecikmesi, doktorların spirometreye ulaşma ve yorumlama güçlükleri nedeniyle, KOAH hastalarının ancak 1/3-1/10'u KOAH tanısı almaktadır.

KOAH için risk faktörleri; genetik durum, sigara dumanı, organik ve inorganik mesleki toz ve kimyasallar, ev içi ve dış ortam hava kirliliği, akciğerlerin büyüme ve gelişmesindeki sorunlar, cinsiyet, yaş, solunum yolu enfeksiyonları, sosyo-ekonomik düzey, kronik bronşit, astım / bronşial hiper-reaktivite olarak ortaya çıkmaktadır [16].

Semptomlar ise; kronik öksürük, balgam çıkarma ve nefes darlığıdır. Risk grubunda olmasına rağmen hastalar semptomatik olmayabilmekte veya hastalık belirtilerini doktora başvuracak kadar önemsemeyebilmektedir. KOAH'ta orta şiddetten itibaren, hava akımı kısıtlılığı belirginleştiği için hastalar sıklıkla günlük aktivitelerini etkileyen nefes darlığından yakınırlar. Genellikle bu evrede semptomların belirginleşmesi nedeniyle doktora başvurularak KOAH tanısı konulur. Hafif KOAH'ta, temel semptomlar kronik öksürük ve balgam çıkarmadır.

KOAH tanısı spirometri ölçümü ile doğrulanmaktadır. Literatürde yapılan çalışmalara bakıldığında; Ashizawa 1999'da yaptığı çalışma ile akciğer grafisinde yapay sinir ağlarını (YSA) interstisyel (dokular arası) akciğer hastalığının ayrımsal teşhisinde kullanmıştır. Üç katmanlı, geri yayınlı algoritma ile ileri beslemeli YSA kullanılan çalışmada YSA, 11 interstisyel akciğer hastalığı arasındaki ayrım için göğüs radyologları tarafından çıkarılan 10 klinik parametre ve 16 radyolojik bulgu baz alınarak tasarlanmıştır. Sonuçta pozitif bulgular elde edilmiştir [17].

Er ve Temurtaş, 2008 yılında çok katmanlı YSA kullanarak KOAH teşhisi üzerine bir çalışma gerçekleştirmiştir. Çalışmada, KOAH ve normal olmak üzere iki sınıf bulunmakta, iki farklı YSA yapısı kullanılarak (bir gizli katmanlı ve iki gizli katmanlı), sinir ağının eğitimi için ise momentum ve Levenberg–Marquardt algoritmaları geri yayılım kullanılmış, başarılı sonuçlar elde edilmiştir [11].

2009 yılında Er, Radyal Tabanlı YSA kullanarak KOAH teşhisine çalışmış, bir uzmanın görüşü alınarak epikriz raporlarından 38 parametre elde etmiş ve uygulamada özellik olarak kullanmışlardır. Sonuçta KOAH'ın teşhisinde %90,20'lik bir doğruluk oranı ile YSA'nın teşhiste kullanılabileceği kanısına varmışlardır [15].

Er tarafından 2009 yılında yapılan diğer bir çalışmada, YSA ve yapay bağışıklık sistemleri kullanılarak KOAH ve zatürre hastalıklarının teşhisi üzerine karşılaştırmalı bir çalışma gerçekleştirilmiş, başarılı sonuçlar elde edilmiştir [12].

2010 yılında yapılan çalışmada Er, YSA kullanarak göğüs hastalıkları (KOAH, zatürre, astım, tüberküloz, akciğer kanseri) teşhisi üzerinde, çok katmanlı, olasılıksal, öğrenen vektör nicemlemesi (learning vector quantization) ve genelleştirilmiş regresyon sinir ağları kullanarak karşılaştırılmalı bir göğüs hastalıkları teşhisi gerçekleştirmiştir [18].

2010 yılında yapay bağışıklık sistemi kullanılarak göğüs hastalıklarının teşhisi üzerine çalışılmış ve sonuçta %93,84 sınıflandırma doğruluğuna ulaşılmıştır [19].

2014 yılında Bhuvaneswari, genetik algoritma kullanılarak akciğer hastalıklarının sınıflandırılması için yeni bir model üzerine çalışmış, başarılı sonuçlara ulaşmıştır [20].

2014 yılında Goryński, erken akciğer kanseri teşhisinde YSA yaklaşımına çalışmış, YSA'nın akciğer kanseri prognozunda kullanılabileceği ve akciğer kanseri şüphesi

olan hastaların teşhisinde uzman doktora yardımcı olabileceği sonucuna ulaşmıştır [17].

Yapılan literatür taramasında, bugüne kadar yapılan çalışmalar içerisinde, KOAH hastalarına ait kalp sinyalleri toplanarak üzerinde teşhis veya inceleme yapılan herhangi bir çalışmaya rastlanılmamıştır. Önerilen tez çalışmasında, bugüne kadar yapılan çalışmalardan farklı olarak, PPG sinyali ve yapay zeka yöntemleri kullanılarak KOAH hastalığı teşhisini sağlayan bir yöntem geliştirilecektir.

1.3. Hedef ve Katkılar

Bu araştırmanın genel amaçlarından biri KOAH tanısını kolaylaştırmak ve makine öğrenimi yöntemlerini kullanarak KOAH'ı saptamaktır. Ayrıca teşhis süresi, verimlilik, süre gibi parametrelerde iyileştirmeler yapılması da hedefler arasında yer alıyor [8]. Yapılan çalışmada Global Girişim (GOLD) prensiplerine göre uygun olup Kronik Obstrüktif Akciğer Hastalığı için PPG sinyali kullanılarak gerçekleştirilmiştir.

Son yıllarda, hastalıkların teşhisinde; yeni ve yardımcı bazı sınıflandırıcı, karar verici yazılımlar ve araçların kullanılabilirliği üzerine çeşitli çalışmalar yapılmaktadır. Bu alanlardan biri de yapay zeka uygulamalarıdır. Teşhisin konulmasında yardımcı olabilecek, teşhis süresinin kısılması, gayret tasarrufu ve verimlilik artışı gibi faydalar sağlayacak sistemlerin medikal alanda faydalı olacağı açıktır. Bu çalışmada Kronik Obstrüktif Akciğer Hastalığının, sadece hastaya ait Fotopletismografi (PPG) sinyali kullanılarak yapay zeka uygulamaları ile teşhis edilmesi amaçlanmaktadır.

KOAH, Dünya Sağlık Örgütü'ne göre, ciddi bir küresel sağlık sorunu olmakla beraber, dünyadaki ölümlerin dördüncü nedenidir. 2030 yılında ise, dünyadaki mortalite oranının üçüncü en yüksek hastalığı olacağı tahmin edilmektedir.

KOAH hastalığı teşhisi için ilk defa olarak Fotopletismografi (PPG) verisini kullanarak Makine öğrenme tabanlı biyomedikal sinyal işleme teknikleri ile yapay zeka yöntemleri birleştirilerek yeni bir teşhis yöntemi geliştirilecektir.


2. KRONİK OBSTRÜKTİF AKCİĞER HASTALIĞI

2.1. Giriş

Kronik Obstrüktif Akciğer Hastalığı (KOAH), nefes almakta sıkıntı yaşaması ve zamanla kötüleşen ve hava akışının kısıtlanmasına neden olan bir tür akciğer hastalığıdır. Belirtileri egzersiz sırasında nefes almada zorlanmaktadır, uyurken nefes almakta zorlanmaktadır, öksürük, balgam(mukus) ve hırıltı gibi insanın yaşam kalitesini düşüren belirtiler ortaya çıkmaktadır. Genel olarak en çok bu hastalığa yakalananlar sigara içenler ve sigara dumanına uzun zaman maruz kalanlar, tahriş eden gazlar veya parçacıklar, çevresel etkenler gibi diğer etkenlerden oluşmaktadır. KOAH hastalığı olan kişilerde akciğer hastalığı olan solunum sıkıntısı haricinde farklı hastalıklarda ortaya çıkmaktadır ki bunların başında kalp hastalığı, böbrek hastalığı, akciğer kanseri ve başka hastalıkların riski yüksektir.

2.2. Kronik Obstrüktif Akciğer Hastalığı Nedir ve Nedenleri

Kronik Obstrüktif Akciğer Hastalığı kelimesinin baş harflerinden türetilen KOAH, akciğerlerde yer alan bronş adındaki hava keseciklerinin tıkanması sonucu ortaya çıkan, nefes darlığı, geçmeyen öksürük ve solunum güçlüğü gibi belirtilerle kendini gösteren bir hastalıktır. Nefes aldığımızda akciğerlerimize giren hava bronşlarına çekilir ve havadaki oksijen kanınızla birlikte dokularınıza girer. Tekrarlayan KOAH'ta bronşiyal obstrüksiyona bağlı olarak akciğer fonksiyonu hızla azalır. Bunun sonucunda soluduğunuz temiz hava akciğerlerden gerektiği oranda emilemez ve kanla birlikte dokulara yeterli oksijen ulaştırılmaz.



Şekil 2.1. Normal ve KOAH hastalığı örneği.

Birçok faktörün KOAH'a neden olabileceği bilinmektedir. Ancak, KOAH hastalığının en önemli nedeni sigaradır. KOAH hastalığına sahip kişilerin %90'ı sigara içmiş veya hala sigara içmektedir. KOAH'a katkıda bulunan diğer faktörler arasında tozlu havaya uzun süre maruz kalma (odun kesme atölyelerinde, taş ocaklarında ve kümes hayvanı çiftliklerinde çalışma), kostik temizleyiciler gibi toksik maddelere kronik maruz kalma, hava kirliliği, yaş ve cinsiyet, genetik yatkınlık, önceki tıbbi Akciğer iltihabı veya diğer akciğer hastalığı ve tedavi edilmemiş astım gibi faktörler KOAH'a neden olabilir.


2.2.1. Kronik obstrüktif akciğer hastalığı belirtileri

KOAH genellikle kalıcı akciğer hasarı oluşana kadar hiçbir belirti göstermez. Bununla birlikte, semptomlar ortaya çıktıktan sonra, sigara içmek gibi sebep ortadan kaldırılmadıkça, semptomlar giderek kötüleşecektir. Nefes darlığı, hırıltılı solunum, özellikle fiziksel aktivite nedeniyle nefes darlığı gibi belirtiler, KOAH hastalığının en yaygın semptomları arasındadır. Ayrıca, nefes alırken ısıklık sesi veya gıcırtı sesi, beyaz, sarı veya yeşil balgam gibi özellikle mukus üreten bir öksürük, göğüste sıkışma, siyanoz (ağız, göz ve tırnak çevresinde mavimsi cilt), solunum yollarında sık enfeksiyonlar, sürekli yorgunluk ve halsizlik hissi, depresyon, ilerleyen zamanlarda kilo kaybı, ayak bileği veya bacak şişmesi de KOAH hastalığının belirtileri arasında yer alabilir.

2.3. Kronik Obstrüktif Akciğer Hastalığı Teşhisi

KOAH tanısı, semptomlara dayanarak test sonuçlarına göre konulur. Doktorunuz, KOAH tanısı koymak için çeşitli testler kullanabilir. Bunlar arasında geçmiş tıbbi ve sağlık sorunları ile ilgili bilgilerin alınması, ailede KOAH hastalığına sahip kişilerin

olup olmadığının sorgulanması, akciğer fonksiyon testleri, göğüs röntgeni veya BT taraması, tam kan sayımı, biyokimya, arteriyel kan gazı ölçümü ve nefes testi yer alır. Gerekli görüldüğü takdirde, tomografi de istenebilir. Solunum fonksiyon testleri (spirometri), KOAH tanısını doğrulayan testlerdir. Uzun süreli nefes darlığı, öksürük, balgam sorunları ve sigara öyküsü olan hastalarda KOAH tanısı ve solunum hacminin ve solunum hızının ölçülmesi, KOAH'ı diğer akciğer hastalıklarından ayırt etmek için kritik öneme sahiptir. FVC (zorunlu hayati kapasite): dışarı verilen maksimum hava hacmi zorunlu vital kapasite, FEV1 değeriniz, kronik obstrüktif akciğer hastalığını (KOAH) değerlendirmenin ve durumun ilerlemesini izlemenin önemli bir parçasıdır. FEV, zorlu ekspirasyon hacminin kısaltmasıdır. FEV1, ciğerlerimizden bir saniyede çıkarabileceğiniz hava miktarıdır. Olgun kişilerde FEV1/FVC oranı %70 ile %80 arasındadır; %70'in altındaki bir değer hava akımı sınırlamasını ve KOAH olasılığını gösterir [3, 8, 9].



Şekil 2.2. Spirometri Kontrolü

Akciğer röntgeni ve kan testleri, özellikle bir akciğer enfeksiyonundan şüpheleniliyorsa kullanılır. Solunum yetmezliğinin derecesini ve tipini belirlemek için arteriyel kan gazları kullanılır.

2.4. Kronik Obstrüktif Akciğer Hastalığı İstatistikleri

GOLD 2022 Raporuna göre KOAH dünya çapında ilk üç ölüm nedeninden biri ve ölümlerin çoğu düşük ve orta gelirli ülkelerde meydana gelmektedir. Üstelik önlenabilir ve tedavi edilebilir bir halk sağlığı sorunu. Gelişmiş ülkelerde yapılan son araştırmalar, ekonomik durumu düşük olan insanların KOAH hastalığına yakalanma riskinin yüksek olduğunu göstermektedir. Üstelik risk faktörlerine sürekli maruz kalınması ve nüfusun yaşlanması nedeniyle hastalığın yükünün önümüzdeki on yıllarda küresel olarak artacağı tahmin edilmekte. Ulusal ve uluslararası sağlık kuruluşları, KOAH hastalığının ciddiyetinin daha fazla fark edilmesi ve sosyoekonomik eşitsizliklerden kaynaklanan risk faktörlerinin ve maruziyetlerin ortadan kaldırılması için çalışmaktadır. Az ve orta gelirli ülkelerde, kalabalık ortamlar, hava kirliliği, enfeksiyonlar, sık alevlenmeler, beslenme bozuklukları, ucuz tütüne kolay ulaşım, tanısal spirometrik testlerin yaygın kullanımının olmayışı, sağlık hizmetlerine ulaşımın zorluğu gibi ciddi sorunlar bulunmaktadır. Tüm bunlar, KOAH hastalığının gelişimini artıran ve geç tanınmasına, kötü sonuçlanımlara neden olan durumlar olarak belirtilmektedir.

Türkiye’de yapılmış bir araştırmada hastaların (%61,6) çoğunlukla erkeklerden oluşmaktadır, %67,1’i yaş aralığı 62-83, %79,5’i ise evlilerden oluşmaktadır, %58,9’i okur yazar olmayan, %46,6’sı işçi olarak çalışan ve %60,3 ‘ünü gelir düzeyi orta düzeyde olanlardan oluşturmaktadır.

Hastaların %97,3’ünün aileleriyle birlikte yaşadığı ve %84,9’unun aile bireylerinin de hastalıktan etkilendiği belirlenmiştir. Araştırmaya katılan hastaların %56,2’si günlük yaşam aktivitelerini hiçbir yardıma ihtiyaç duymadan yerine getirebilirken, %76,7’si 0 ila 11 yıl arasında KOAH teşhisi konmuş hastalardır. Bu hastaların %46,6’sı üçüncü evredeyken, %67,1’i KOAH hastalığı dışında başka bir kronik hastalığa sahiptir. Bu kronik hastalıkların %27,4’ü hipertansiyon olarak belirlenmiştir. Araştırmalar, KOAH hastalarının %87,7’sinde ağrı, %84,9’unda boğazda yanma, %78,1’inde soluk almada güçlük ve %39,7’sinde mide yakınmaları olduğunu göstermiştir [21].

2.5. Kronik Obstrüktif Akciğer Hastalığı (KOAH) Tedavisi

KOAH hastalığının tedavisinde birçok yöntem kullanılmaktadır. Bu yöntemler arasında oksijen tedavisi, ilaç tedavisi ve cerrahi müdahaleler yer almaktadır. İlaç tedavisi, hastaların semptomlarını azaltmak ve sağlıklarını iyileştirmek için kullanılır.

Solunum yetmezliđi olan hastalarda cerrahi müdahaleler uygulanabilir. Oksijen tedavisi ise, hastaların oksijen ihtiyacını karşılamak için kullanılan bir yöntemdir. Bu tedavi yöntemleri, hastalığın seyrini yavaşlatmak ve hastaların yaşam kalitesini artırmak için kullanılmaktadır [16].

Kronik solunum yetmezliđi hastalığına sahip olan KOAH hastalarının tamamen iyileştirilmesi mümkün olmadığından, KOAH hastalığının kontrol edilmesi de tedavi kadar önemlidir. KOAH kontrolünün ana hedefleri arasında, aktivite kısıtlamalarının azaltılması, fiziksel performansın artırılması, alevlenmelerin önlenmesi ve hastalığın ilerlemesinin yavaşlatılması bulunmaktadır [22].

Erken evre KOAH hastaları (solunum fonksiyonlarında geri dönüşümsüz patoloji oluşmayan) tam olarak iyileşebilir. İleri evre KOAH'ta ise tamamen düzelme olmazsa da hastalık stabil hale gelebilir [26].

KOAH semptomları dört (4) aşamadan oluşmaktadır. Bu aşamalar şiddetine göre hafif aşaması, orta aşaması, şiddetli aşaması ve çok şiddetli aşaması olmak üzere ayrılmaktadır [16].

1. Hafif aşamasında olan KOAH hastalar: Bu aşama, efor ve yoğunluk gerektiğinde nefes darlığı belirtileri olarak kendini gösteren, hastalığın başlangıç aşaması olarak tanımlanır
2. Orta aşamasında olan KOAH hastalar: Hastalığın bu evresinde gece uykularında nefes darlığı görülmemektedir ancak günlük işler esnasında nefes darlığı görülmektedir.
3. Şiddetli aşamasında olan KOAH hastalar: Bu aşamada ise gece uykusunda nefes darlığı görülmektedir akabinde solunum sıkıntısı na bağı nefes almakta zorlandığı için gelişen halsizlikler günlük hayatını da etkilemektedir.
4. Çok Şiddetli aşamasında olan KOAH hastalar: Bu aşamada nefes almak aşırı derecede zorlaşır ve hasta evin içinde yürümekte bile zorlanır. Dokulara yeterince oksijen gitmediğı için bazı organlarda çeşitli sorunlar ortaya çıkabilmektedir. Bu aşamada hasta, kalp yetmezliğine kadar gidebilecek ilerleyici akciğer hastalığı nedeniyle oksijen desteğı olmadan yaşamını sürdüremez.

Tablo 2.1. Hava akımı kısıtlılığının şiddetinin derecelendirilmesi.

Hava akımı kısıtlılığının şiddetinin derecelendirilmesi	
FEV ₁ /FVC<0.70 olan hastalarda	
Hafif aşamada	FEV₁ beklenenin %80 ve üzerinde
Orta aşamada	FEV₁ beklenenin ≥ %50'si ile < %80' i arasında
Şiddetli aşamada	FEV₁ beklenenin ≥ %30'si ile < %50' i arasında
Çok Şiddetli aşamada	FEV₁ beklenenin < %30'u

2.5.1. İlaç tedavisi ve davranışsal değişiklikler

KOAH'ın tedavisi yoktur. Bununla birlikte, tedaviler semptomlara yardımcı olabilir, hastalığın ilerlemesini yavaşlatabilir ve aktif kalma yeteneğini geliştirebilir. Hastalığın komplikasyonlarını önlemeye veya tedavi etmeye yönelik tedaviler de vardır [16, 26].

2.5.2. Bronkodilatör cihaz tedavisi

Bronkodilatörler, solunum yollarınızın etrafında sıkışan kas bantlarını gevşeten ilaçlardır. Bu, hava yollarını açarak akciğerlere daha fazla hava girip çıkmasına izin verir. Bu daha kolay nefes almanıza yardımcı olacaktır. Bronkodilatörler ayrıca ciğerlerinizden mukusun çıkarılmasına yardımcı olur. Açık hava yolları, mukusun da daha serbestçe hareket edebileceği ve öksürebileceğiniz anlamına gelir. Bronşiyal astımın önlenmesinde ve KOAH ile ilişkili bronkospazm için faydalıdır. Kronik obstrüktif akciğer hastalığı (KOAH) ile yaşayan kişilerde genellikle daha iyi nefes almanıza yardımcı olmak için hava kanallarını gevşetmek için kullanılan bir ilaç türü olan bir bronkodilatör reçete edilir. İlaçlar tipik olarak ölçülü bir doz inhaleri (MDI) kullanılarak ağızdan solunur , aynı zamanda sıvı, hap, enjektör veya süpozituar formülasyonlarda da bulunur. En çok tercih edilen bronkodilatörler; antikolinerjikler, β_2 agonistler ve teofilindir [23].

Bronkodilatörler ya ihtiyaç duyulduğunda ya da KOAH semptomlarını önlemek ya da azaltmak için günde iki kez reçete edilir. KOAH tedavisinde yaygın olarak kullanılan üç bronkodilatör sınıfı şunlardır:

- Beta-adrenerjik agonistler
- Antikolinerjikler
- Methylxanthines



Şekil 2.3. Bronkodilator Cihazı.

2.5.3. Kronik obstrüktif akciğer hastalığında psikolojik tedavi yöntemleri

Bunun yanı sıra hastalar uzun bir tanı koyma sürecine dahil olurken birçok psikolojik ve fizyolojik sıkıntılara maruz kalmışlardır. Hastalarda anksiyete seviyesinin arttığı ve hastalarda depresyona yol açtığı belirtilmiştir [24, 25].

KOAH hastalarında zaman içerisinde depresyon ve anksiyete gelişebilir, çünkü bu hastalıkla yaşamının zorlukları vardır. Zor solunum yapmak hastayı endişe ve strese sokabilir. Dolayısıyla KOAH hastaların zaman içinde psikiyatriste görünmeleri gerekebilir. KOAH hastaların hastalığı gecikmiş üçüncü ve dördüncü evrelerde olan hastalarda psikolojik çöküntüye uğradıkları görülmüştür.

2.5.4. Kronik obstrüktif akciğer hastalığında cerrahi tedavisi

Hastalığın son evresinde olan hastalarda bazen ilaçlarında etkisi olmadığı görülmektedir bu nedenle hastaya Cerrahi müdahale yapılmaktadır. En önemli tedavi ameliyat olması önerilmektedir. Bu en önemli opsiyonlardan bir tanesi öngörülmektedir. İleri evrelerde, hasarlı akciğerler, akciğer hacmini küçültme ameliyatı veya akciğer nakli gibi cerrahi tedavi gerektirebilir. Tersinir Blokaj Yöntemleri Bir endobronşiyal kapak (EBV), tipik olarak bir Nitinol stenti üzerine yerleştirilen bir silikon implanttır. Bir de Organ nakli yapılarak hasta eski haline döndürmeye amaçlanmıştır [26].



3. FOTOPLETİSMOGRAFİ SİNYALİ VE İNCELENMESİ


3.1. Fotopletismografi Sinyalinin Oluşumu ve Ölçülmesi

Dünyada sağlık uygulamalarına artan ilgi, biyomedikal mühendisliğini son yıllarda en hızlı büyüyen disiplinlerden biri haline getirmiştir. Fotopletismografi (PPG), kalp hızı, solunum hızı, kan oksijen doygunluğu ve kan basıncı gibi yaşamsal belirtilerin invazif olmayan (non-invaziv) bir şekilde izlenmesine yönelik çok yönlülüğü nedeniyle son yıllarda popülerlik kazanmıştır [27]. Fotopletismografi PPG, ışık anlamına gelen “foto” kelimesinden oluşan bileşik bir kelimedir; hacim anlamına gelen “plethysmo” ve kayıt anlamına gelen “grafi” den oluşmaktadır [28, 29]. PPG sinyali, “pulse oksimetre” tekniğinin temelidir [30].

Fotopletismografi (PPG) sinyalleri, kullanım kolaylığı, erişilebilirliği, güvenilirliği, gizliliği ve düşük maliyeti nedeniyle biyosinyaller arasında öne çıkmaktadır. PPG sinyallerinin bir fizibilite çalışması, PPG sinyallerinin insan tanımlaması için önemli özellikler içerdiğini ve biyometrik sistemlerde kullanılabileceğini göstermiştir [31].

PPG, çevresel dolaşımdaki kan hacmi değişikliklerini tespit etmek için kullanılan optik bir tekniktir. Vücudun herhangi bir yerinden ölçülebilen bir sinyaldir. PPG ölçümlerin daha iyi sonuçlar alabilmek için kılcal damarların yoğun olduğu bölgelerde yapılması öngörülmektedir. Yapılan ölçümler genel olarak kılcal damarların yoğun olduğu bölgelerde yapılmaktadır. Yoğunluk bölgeler ise genel olarak deri üzerinden kulak memesi, parmakta veya parmak uçlarında bulunmaktadır. Ölçümlerin bu bölgelerde kolaylıkla yapıldığı gibi bilekte de yapılabilmektedir [32]. Bu ölçüm tekniği yaygın oldukça kolaylık sağlamaktadır ve yaygın olarak kullanılmaktadır. PPG ölçüm sistemi temel olarak iki parçadan oluşur. PPG yönteminde, hücrelerin ışık geçirgenliğine ve farklı hücrelerin ışık soğurmalarına göre, parmağın veya kulak memesinin bir ucuna λ dalga boyuna sahip bir ışık kaynağı, diğer ucuna da bir fotodedektör yerleştirilir. İletilen ışığı algılamak ve yakalamak için ışık kaynağı kullanılır.

PPG ölçümü, kalp atış hızının ölçülmesinde kullanılan bir yöntemdir ve mikrodenetleyici tabanlı bir sistem kullanır. Bu yöntemde, parmak ucundaki kan hacmindeki değişiklikler optik sensörler tarafından ölçülür. Parmağın ucuna yerleştirilen IR LED, kızılötesi ışık yayarak, fototransistör aracılığıyla yansıyan ışığın geri dönüş oranını algılar. Yansıtılan ışığın yoğunluğu, parmak ucundaki kanın hacmine bağlı olarak değişir. Her kalp atışında yansıyan kızılötesi ışık miktarı biraz değişir ve bu fototransistör tarafından algılanabilir. Bu küçük değişiklik, uygun sinyal koşullandırma ile darbeye dönüştürülebilir. Kalp atış hızını belirlemek için mikrodenetleyiciler ve nabız darbeleri sayılabilir. Bu ölçümlerin temeli kalp atış hızı ve kalbin düzenidir. Aynı zamanda kan dolaşımını sağlayan damarlarda da önemli rol oynar. Kalbin kan pompalama fonksiyonundan kaynaklanan, atardamarlardan yayılan periyodik şişkinlik olarak tanımlanabilir [33, 34].




Şekil 3.1. PPG sinyal ölçümleri için yansıtma ve iletim modları [30].

Bir PPG sinyalinin bir (AC) alternatif akım bileşeni ve bir (DC) doğru akım bileşeni vardır. AC bileşeni, kalp atışı nedeniyle kan hacmindeki kalp atışı ile senkronize değişikliklere karşılık gelir. DC bileşeni, solunum, sempatik sinir sistemi ve vücut sıcaklığının düzenlenmesi gibi faktörlerden oluşur. AC bileşeni, kardiyak aktivitenin neden olduğu kan hacmindeki sistolik ve diyastolik değişiklikleri temsil eder.

PPG sinyali olan, kan damarlarından geçmeden deri, kaslar ve kemiklerden geçen büyük bir DC bileşeninden ve deri, kaslar ve kemikleri terk ederek doğrudan kan damarlarına geçen küçük bir AC bileşenden oluşur. Ancak bireye özgü bilgileri içeren bu AC bileşenin genel sinyal üzerinde çok az etkisi vardır. Bu nedenle, verimli bir amplifikatör devresi, AC sinyalinden istenen bilgilerin çıkarılmasında hayati bir rol oynar. Bunun için sinyalin DC kısmının azaltılıp AC kısmının

güçlendirilmesi sağlanmaktadır. Esas ölçüm alanında sinyalin %99'u deri, kas ve kemikten, %0,9'u damarlardan ve %0,1'i arterlerden gelir [35]. Kalp kasıldıktan hemen sonra atardamarlardaki kan hacmi artar dolayısıyla alınan ışık şiddeti de azalır. Diyastol sırasında arterlerdeki kan hacmi azalırken ışık iletimi artar.



Şekil 3.2. Işığın dokularda ve kan damarlarında soğurulması [30].

3.2. Fotopletismografi Sinyallerin Hastalıkla İlişkisi

Kalp atış hızı, kalbin dakikadaki kasılma sayısı ile ölçülen bir değerdir ve birim olarak bpm (beats per minute) kullanılır. Oksijen doygunluğu ise kandaki toplam hemoglobine bağlanmış oksijen miktarını ifade eder ve doymamış hemoglobin oranı ile birlikte oksijenle doymuş hemoglobinin fraksiyonunu belirler. Kan basıncı, atardamar duvarlarındaki kan damarlarından geçen kanı gösterir ve insanların sağlıklı olduğunun gözlenmesinde önemli bir parametre olarak kullanılır. Normal düzeyi değişebiliyorsa kalp hastalığı, böbrek yetmezliği, hipertansiyon ve inme gibi herhangi bir hastalığı gösterebilir. Ayrıca, yüksek tansiyon kan damarlarının patlamasına neden olurken, düşük tansiyon baş dönmesine ve hatta bilinç kaybına neden olabilir [36, 37]. Ayrıca yüksek tansiyon, felç, kalp büyümesi, kalp krizi, göz damarlarında kanamalar ve hatta bacaklarda kan dolaşımının durmasına neden olan periferik damar hastalığına, topallamada kramp ağrılarına veya anevrizmalara da yol açabilir. Ayrıca, ameliyat

öncesi ve sonrasında stabil olduklarından emin olmak için peri-operatif hastaların kan basıncını gözlemlemek hayati önem taşır [36].

Fotopletismografi (PPG) sinyalleri, oksijen doygunluk seviyesinden (SpO₂) daha fazla bilgi taşımaktadır ve ekonomik, hızlı ve non-invaziv bir yöntem olarak kullanılabilir.

PPG giyilebilir ürünleri tıbbi uygulamaların birçok alanında yaygınlaşmaktadır ve ana alanlar kardiyoloji, solunum, nöroloji ve spor uygulamaları içerir. Ana operasyon zorlukları, performans ve sağlamlık engelleri dahil olmak üzere belirlenir [38].

Yapılan araştırmalarda zaman alıcı ve maliyetli yöntemlere bir alternatif olarak uygulanabilirliği yüksek olan yöntemler aramaktadırlar ve bu yöntem en iyi çözümün PPG sinyallerin olduğu düşünülmektedir [39].

İnvaziv olmayan ve kullanımı kolay bir yöntemi olan fotopletismografi, küçük boyutu ve giyilebilir teknolojiye entegre edilebilmesi nedeniyle birçok tıbbi sistemde kullanılmaktadır. Bir kişinin egzersiz veya uyku sırasındaki biyometrik verileri PPG sinyalleri aracılığıyla takip edilebilir. Ayrıca bazı kardiyovasküler hastalık tespit ve teşhis ve sağlık izleme sistemlerinde kullanılmaktadır. PPG'nin bazı önemli uygulama alanları şu şekilde sıralanabilir:

PPG uygulama alanları

- Klinik fizyolojik izleme
- Kalp atış hızı ve kalp döngüsünün takibi
- Kan oksijen doygunluğu
- Solunum
- Kardiyak çıkışı
- Vasküler değerlendirme
- Arter hastalığı
- Arter uyumu ve yaşlanma
- Venöz değerlendirme
- Vazomotor fonksiyon ve termoregülasyon
- Endotel fonksiyon izleme
- Ortostaz
- Kan basıncı ve kalp atış hızı değişkenliği izleme

- Kan oksijen saturasyonu takibini yapmak
- Mikrovasküler kan akışını izleme
- Hipovolemi izleme

3.3. Fotopletismografi ve Elektrokardiyografi İlişkisi

Elektrokardiyograf kısaltımı olarak EKG (ECG) adı verilir. Elektrokardiyograf kalpteki elektriksel sinyalleri kaydeden tıbbi cihaza verilen isimdir. Elektrokardiyogram, bir kişinin kalp sağlığı hakkında bilgi sağlayan bir işlemdir. Cilde yerleştirilen elektrotlar, kalbin belirli bir süre boyunca elektriksel aktiviteler oluşarak Grafik bir görüntü elde edilerek kaydedilir. Bu görüntü, kalbin kasılma için gerekli olan elektriksel aktivitesinin kaydına karşılık gelir. Bir EKG, kalp sağlığı hakkında anında bilgi sağlar. Elektrokardiyogramlar, göğüs ağrısı ve bazı kardiyovasküler durumlar dahil olmak üzere çeşitli nedenlerle kullanılır ve hızlı ve güvenlidir. Bu testin yardımıyla doktor kalp ritmini kontrol edebilir. Kalp kasına zayıf kan akışı olup olmadığına bakılır.

Fotopletismografi PPG ve Elektrokardiyografi EKG ile ilişkili yapılan ölçümler daha güvenilir sonuçlar verildiği görülmüştür. Yapılmış çalışmalarda Hipertansiyon veya Kardiyovasküler hastalıkları önemli sağlık sorunlarından biridir. Hipertansiyon hastalığı olan hastaların yüksek tansiyon, kalp krizi, inme ve ölüm riski olan faktörlerdir. Bunun takibi devamlı yapılmalıdır veya ilaç kullanılarak takibi yapılmalıdır. Kan basınç hesaplanması için PPG ve EKG sinyalleri yoğunlukla kullanılmaktadır [40, 41]. Kalp kası ve nörotransmitter sisteminin işlevini incelemek için kalpte meydana gelen elektriksel aktiviteyi kaydetmek için bir elektrokardiyografi kullanılır. Yapılan araştırmalarda PPG sinyalleri incelendiğinde EKG sinyallerin birtakım özellikleri içerdiği görülmektedir [32, 42].

PPG teniği kullanılarak EKG'nin kalp hızı değişkenliği (HRV) incelemesinde kullanılır. EKG'den PPG ölçümü yapmak daha uygundur. PPG ışık geçirgenliği ölçülerek kalbin hacimsel değişimini ölçer.

HRV, PPG sinyalinin ardışık tepe noktaları arasındaki zaman aralığının doğru tahminini gösterir. Bu nedenle, PPG tepe noktaları arasındaki zaman aralığı çok hassastır, tepe noktadaki zaman aralığı yanlış ölçüm yapılırsa yanlış HRV tahminlerine yol açabilir. PPG, kalp atış hızını ölçmek için kolay bir yöntemdir. Ancak

R-R aralıklarını güvenilir bir şekilde tespit etmek için EKG sinyalinden yararlanmak gereklidir. Daha az müdahaleci durumlarda kalp atışı aralığının ölçümü için PPG bir alternatiftir [43].

3.4. Fotopletismografi ve Teknolojik Uygulamalar


Teknolojinin hızla ilerlediği günümüzde, sağlık sektörü de hızla gelişmektedir ve insanlığa hizmet etmeye devam etmektedir. Tıp bilimi, ölümsüzlüğe her zamankinden daha fazla yaklaştıkça, sosyal ve doğa bilimlerinden aldığı ilhamla yeniden yönlendirme sürecindedir ve önemi giderek artmaktadır.

Vücudun her değişimini, anomalisini ve dinamiklerini kılcal damar seviyesinde bile takip edebilen biyotıp, yapay zekâ teknolojisi ile iç içe olduğundan, gerekli koşullar sağlandığında tüm fütüristik fikirler çok normal görünüyor. Özellikle son yıllarda, tıbbi görüntüleme teknolojisinin tıp alanına katkısı oldukça yenilikçi olmuştur. Sağlık sektörü hâlihazırda yarı özerk alt sektörler haline gelmektedir.

Yapılan bilimsel çalışmaların çoğu Teknolojik sağlık konusunda her geçen gün daha fazla artmaktadır. Yapılan çalışmaların insanın yaşamını kolaylaştıracak ve erken teşhisin yapılması ve müdahale edilmesi açısından çok önemli. Geliştirilen akıllı cihazlar yardımıyla (solunum, kan basıncı, nabız atışı, tansiyon ve SpO2 oranları) takip etme olanağı sunmaktadır [44]. Akıllı saatlerin hayatımıza girmesiyle birlikte, akıllı telefonlardan sonra temel hayat fonksiyonlarının anlık takibi ve kayıt altına alınması hayatı kolaylaştırmaktadır. Bu dijital bilezikler kolda takılır ve kişisel sağlık koçu olarak sizin günlük hayatınızda ne yapmanız gerektiği konusunda önerilerde bulunur. Bu öneriler arasında, sağlık konularıyla ilgili öneriler ve bilgilendirici mesajlar yer alabilir. Bu akıllı cihazlar, sağlık bilgilerini toplayarak ve analiz ederek, kullanıcıların sağlık durumlarını daha iyi yönetmelerine yardımcı olabilir.

Fotopletismografi teknolojisinin uygulamaları gün geçtikçe artmaktadır. Bugün, acil klinik oksimetreleri- kanınızdaki oksijen seviyelerini anında izlemek için parmağınıza veya kulağınıza takılan küçük, invaziv olmayan cihazlar- esas olarak fotopletismografi teknolojisini kullanır. Kalp atış hızınızı, perfüzyon indeksini ve oksijen saturasyonunu doğruluk oranı yüksek sonuçlar vermektedir.

PPG sinyalleri kalple ilişkili EKG sinyalleri kadar detaylı bilgi vermese de birçok kardiyovasküler hastalığın habercisidir. Bu sinyallerin (temelde iki farklı kısımda incelenen) statik bileşeni kan damarı aktivitesine bağlı olarak değişiklik gösterebilirken, dinamik bileşeni kan hacmi ve kalp aktivitesi hakkında sağlık bilgisi sağlar. Gelişmiş yarı iletken teknolojisi sayesinde, oksimetrelerde kullanılan düşük maliyetli malzemeler, cilt yüzeyine gönderilen farklı dalga boylarındaki radyasyonun dokular ve altındaki kan ile etkileşimini analitik olarak incelememize olanak tanır [45].



Şekil 3.3. PPG ve EKG sinyalleri.

Şekil 3.3'te aynı zaman diliminde EKG ve PPG sinyaller gösterilmiştir. Yukarıdaki şekilden, her kalp atışından sonra dokudaki kan hacmindeki değişiklikleri takip etmek zor değildir. Gördüğünüz gibi, birisinin 60 saniyelik bir PPG sinyali varsa, sadece toplam dalga sayısına bakarak kalp atış hızını (dakikadaki atım sayısı) hesaplayabilirsiniz [45, 46]. Tek bir ışık kaynağının etkileşimi bile, kalp atış hızını hesaplamak için yeterli olabilir. Oksimetreler, kan oksijen oranını doğru bir şekilde ölçmek için cildin farklı yerlerine, farklı dalga boylarındaki iki ışık kaynağı gönderir; bu ışık kaynakları kırmızı ve kızılötesi ışınlarıdır. Hemoglobin moleküllerindeki oksijen taşıma kapasitesinin emilim oranları bilindiğinden, kandan yansıyan iki ışının emilmemiş miktarının kalibre edilmesiyle SpO2 oranı hızlı bir şekilde hesaplanabilir [44].

Temassız PPG’lerde oksijen satürasyon ölçümleri biraz daha zorlaşıyor. Ölçümler yapılırken bulunduğu yerin ışık yoğunluğu, gün ışığı, derinin rengi, kameranın merceğine durduğu uzaklık, kamera kalitesi gibi diğer etkenler ölçümlerin doğruluğunu etkilemektedir. Yapılan araştırmalarda yeterli seviyede algoritmalar geliştirildiği takdirde başarılı sonuçlar elde edileceği düşünülmektedir [47–49].

Morfolojik özellikleri eğilimli olan bir araştırma konusu olan fotopletismografik sinyallerin incelenmesi önemlidir. Bu sinyal olasılıklarını analiz etmek için yapay zekanın bir alt dalı olan yapay sinir ağları sıklıkla kullanılmaktadır. Şimdiye kadar, yapay sinir ağları kulak, parmak ve yüz videolarının kamera tarafından yakalanmasıyla toplanan fotopletismografik verileri analiz etmektedir ve bu verilerin kalp hastalığı semptomlarıyla ilişkilendirilmesi amaçlanmaktadır [49].


Tahminlere göre yapılan araştırmalar ve uygulamalar başarılı sonuçlar elde ederse, insanların hastanelere muayene için gitmesine gerek kalmadan, kendi kişisel bilgisayarlarında yüz taramasıyla aynı sonuçları vererek hastalık hakkında erken teşhis edilmesi ve müdahale edilmesi mümkün olacaktır. Bu, doktorların zamanından tasarruf edilmesine, hastaların evlerinde kalmalarına ve tıbbi müdahalelerin daha hızlı bir şekilde yapılmasına olanak sağlayacaktır [47, 48].



Şekil 3.4. PPG giyilebilir teknolojileri.

4. FOTOPLETİSMOGRAFİK İLE KRONİK OBSTRÜKTİF AKCİĞER HASTALIĞI TESPİT MODELİNİN GELİŞTİRİLMESİ


Çalışma için Şekil 4.1'deki akış diyagramı takip edildi. Verilerin toplanması ile birlikte, sayısal filtrelemeler yapılarak ön işlemler gerçekleştirilmiştir. Verilerin filtrelenmesinden sonra veriler belli saniyelerde (2-1024) epoklanmıştır. Veri setinde dengeleme işlemi yapıp ilgili nitelik gruplarına ayırdı. Oluşturulan veri grupları özellik seçme algoritması ile en ilgiliden en ilgisize doğru sıralandı. Belirli miktarda özellik seçildikten sonra sınıflandırma işlemi gerçekleştirilmiştir. Özellik seçme algoritması opsiyonel olup tüm özellikler ayrıca sınıflandırılmıştır.



Şekil 4.1. KOAH tespiti için minimum süre tespit akış diyagramı.

Çalışma için Şekil 4.2'deki akış diyagramı takip edildi. Verilerin toplanması ile birlikte, bireylerde toplanan PPG sinyalleri sayısal filtrelemeler yapılarak ön işlemler gerçekleştirilmiştir. Daha sonra, PPG ve 3 alt frekans bant sinyali PPG_LF, PPG_MF, PPG_HF elde edilmiştir. Sonraki adımda elde edilen 4 sinyalden sonra veriler 2 saniyelik epoklama yapılmıştır. Epoklanmış veriler Özellik çıkarım işlemi yapılmış ve özellikler birleştirilmiştir. Birleştirilmiş veriler sınıflandırma işlemleri 4 farklı özellik grubu oluşturulmuştur. Özellik seçme algoritması yardımıyla birleştirilmiş özellikler azaltılmıştır. Sınıflandırma algoritması olarak k-En Yakın Komşuluk Algoritması (kNN), Destek Vektör Makineleri (SVMs) ve Ensemble Tree algoritmalar kullanılmıştır. Üç algoritma birleştirilecek hibrit makine öğrenmesi algoritması modeli

oluşturulmuştur. Elde edilen sonuçlar gerçek değerler ile karşılaştırılarak sistem performansı kontrol edilmiştir.



Şekil 4.2. KOAH hastalığının PPG sinyali ile yapay zeka tabanlı geliştirilmiş bir yöntem akış diyagramı.

4.1. Veri Toplama

Çalışmanın verileri, Sakarya Hendek Devlet Hastanesi Uyku Laboratuvarı'ndan sağlanmıştır. Bu veriler, uzman bir doktor tarafından incelenerek KOAH kriterlerine göre tanı konulan hastalar ve sağlıklı bireyler olarak etiketlenmiştir. Veri kullanımı için gerekli olan etik kurul raporu Sakarya Üniversitesi Tıp Fakültesi'nden 1614662/050.01.04/70 numaralı rapor ile, T.C. Sağlık Bakanlığı Türkiye Kamu Hastaneler Birliği Genel İşler Dairesi Başkanlığı'ndan 94556916/904/151.5815 sayılı veri kullanım izni edinilmiştir.

Çalışma kapsamında, KOAH teşhisi konulmuş 8 (sekiz) hasta ve sağlıklı 6 (altı) birey olmak üzere toplam 14 birey üzerinde çalışmalar yürütülmüştür. Bireylerin demografik bilgileri ve KOAH kayıt bilgileri Tablo 4.1'de yer almaktadır. Bu bilgiler, çalışmanın yürütülmesi ve sonuçlarının analiz edilmesi için kullanılmıştır.

Tablo 4.1. BMI Vücut Kitle İndeksi

	Kadın			Erkek			Tüm Bireyler		
	n1=2			n2=12			n=n1+n2=14		
	ort		std	ort		std	ort		std
Yaş (Yıl)	55,50	±	4,95	53,17	±	9,43	53,50	±	8,82
Ağırlık (kg)	105,50	±	6,36	101,92	±	8,08	102,43	±	7,75
Boy (cm)	170,00	±	7,07	173,42	±	6,52	172,93	±	6,43
Vücut Kitle İndeksi (kg/m²)	36,70	±	5,23	33,75	±	2,54	34,17	±	2,96
Fotopletismografi Kayıt Süre Dağılımları (Sn)									
	ort		std	ort		std	ort		std
KOAH Grubu	-	±	-	28643,50	±	11082,52	28643,50	±	11082,52
Kontrol Grubu	26041,00	±	4963,89	32611,00	±	5351,56	30421,00	±	5798,47

n -Toplam birey sayısı, **ort** – Ortalama, **std** - Standart Sapma, **sn** – Saniye, **KOAH**- Kronik Obstrüktif Akciğer Hastalığı

4.2. Fotopletismografi Sinyallerinin Filtrelenmesi

Verilerin toplanması doğrultusunda çalışma için 14 bireyden (8 KOAH, 6 Sağlıklı) ortalama 7-8 saatlik PPG kaydı alınmıştır. Alınan PPG sinyalleri için filtreleme işlemi yapılmıştır. PPG sinyalleri gürültüden temizlenmiş olarak işleme alınmıştır.

4.3. Fotopletismografi Sinyallerinin Epoklanması

PPG sinyalini epoklamadaki temel amaç, her bir gizli durumla ilişkili veri dağılımını tanımlayan parametrelerin yanında her bir zaman aralığındaki gözlenemeyen durumları ortaya çıkarmaktır. Zaman serileri ayırık zaman segmentlerine bölünerek epoklama gerçekleştirilmektedir.

Bu amaç doğrultusunda çalışma için 14 bireyden (8 KOAH, 6 Sağlıklı) ortalama 7-8 saatlik PPG kaydı alınmıştır. Alınan kayıtlar 2, 4, 8, 16, 32, 64, 128, 256, 512 ve 1024 saniyelik parçalara ayrılmıştır. Her saniye grubu için işlemler yapılmış ve hangi saniyelik sinyallerle daha performanslı teşhis yapılabildiği tespit edilmeye çalışılmıştır. Hasta bireye ait 8 saatlik kayıtlar 2 saniyelik parçalara ayrıldığında her parçaya hasta etiketi verilmiştir. Aynı işlem sağlıklı birey için yapıldığında tüm parçalara Sağlıklı etiketi verilmiştir. Elde edilen epok bilgileri Tablo 4.2.'de gösterilmiştir.

Tablo 4.2. Epok dağılımları.

BireyNo Grup	Epok (süre- saniye)									
	2	4	8	16	32	64	128	256	512	1024
1	14323	7160	3578	1788	892	445	221	109	53	25
2	22213	11105	5551	2774	1385	691	344	171	84	40
3	2248	1122	560	278	138	67	32	15	6	1
4	16228	8112	4055	2026	1011	504	251	124	60	29
5	13978	6987	3492	1745	871	434	215	106	52	24
6	15673	7835	3916	1956	977	487	242	119	58	28
7	14428	7212	3605	1801	899	448	222	110	53	25
8	13093	6545	3271	1634	815	406	202	99	48	23
Toplam	112184	56078	28028	14002	6988	3482	1729	853	414	195
9	17263	8630	4313	2155	1076	537	267	132	64	31
10	19393	9695	4846	2421	1209	603	300	149	73	35
11	15463	7730	3863	1930	964	480	239	118	57	27
12	15463	7730	3863	1930	964	480	239	118	57	27

Tablo 4.2.(Devamı) Epok dağılımları

BireyNo Grup	Epok (süre- saniye)									
	2	4	8	16	32	64	128	256	512	1024
13	11263	5630	2813	1405	701	349	173	85	41	19
14	14773	7385	3691	1844	920	459	228	112	55	26
Toplam	93618	46800	23389	11685	5834	2908	1446	714	347	165
Genel Toplam	205802	102878	51417	25687	12822	6390	3175	1567	761	360

Elde edilen sonuçlara göre 2 saniyelik veri grubu ile en yüksek performans değerlerine ulaşılmış olup 0.99 sensitivity, 0.99 specificity ve %98.99 doğruluk oranı elde edilmiştir.

Filtreleme işlemleri sonunda elde edilen sinyaller (PPG, PPG_LF, PPG_MF, PPG_HF) T=2 saniyelik epoklara bölünmüştür ve her bölünmüş epok için zaman alanından 25 öznitelik elde edilmiştir. Elde edilen epok bilgileri Tablo 4.3.'de iki saniyelik Epok dağılımları gösterilmiştir.

Tablo 4.3. İki saniyelik epok dağılımları.

	No	Cinsiyet	Epok Sayısı
KOAH	1	K	14323
	2	K	22213
	3	E	2248
	4	E	16228
	5	E	13978
	6	E	15673
	7	E	14428
	8	E	13093
	Toplam		112184
Kontrol	9	E	17263
	10	E	19393
	11	E	15463
	12	E	15463

Tablo 4.3. (Devamı) İki saniyelik Epok dağılımları

No	Cinsiyet	Epok Sayısı
13	E	15463
14	E	14773
Toplam		97818


K-Kadın, E-Erkek

4.4. Fotopletismografi Sinyalinin Frekans Bantlarına Ayrılması

Çalışmanın bir parçası olarak, PPG sinyali gürültüden arındırılmış ve PPG'nin alt frekans bantlarına sahip yeni PPG sinyalleri elde edilmiştir. Gürültüyü azaltmak için 0,1 ile 20 Hz arasında bir frekans aralığına sahip bir Chebyshev tip II bant geçiren filtre ve gürültüsüz PPG sinyali elde etmek için "Moving Average" filtresi kullanılmıştır [50]. Şekil 4.3.'de KOAH ve kontrol gruplarının PPG kayıtlarını ve hızlı Fourier dönüşümlerini içeren periodogram grafikleri gösterilmektedir. Şekilden de görülebileceği gibi, sinyallerin genliklerinde bir fark vardır. Bu çalışmada PPG sinyaline üç alt frekans bantı elde edilmiştir. Bunlar: LF alt bandı (0,04- 0,15 Hz), MF orta bant (0,09 - 0,15) Hz, HF yüksek bant (0,15 - 6 Hz)'dir [51]. Filtreleme işlemleri sonunda elde edilen sinyaller PPG, PPG_LF, PPG_MF, PPG_HF T=2 saniyelik epoklara bölünmüştür ve her bölünmüş epok için zaman alanından 25 öznitelik elde edilmiştir. Üç alt frekans bant aralığı Tablo 4.4.'e gösterilmiştir.

Tablo 4.4. Üç alt frekans bant aralığı.

PPG	Band Range
PPG_LF	0,04-0,15 Hz
PPG_MF	0,09-0,15
PPG_HF	0,15-6 Hz



Şekil 4.3. Fotopletismografi (PPG) sinyaline ait periodogram grafiği.

4.5. Özellik Çıkarımı

Önceki süreçte dört sinyal elde edilmiştir. Dört sinyalin her biri 25 adet özellik çıkarılmıştır. Yapılan çalışmada PPG sinyali için oldukça fazla özellik kullanılmıştır [30, 52, 53].

Bu çalışmada literatürle paralel olarak PPG sinyallerinden toplam 25 öznelik çıkarılmıştır. Çıkarılan özellikler Tablo 4.5.'de özellik numarası, özellik adı ve formül bilgileri olmak üzere 3 sütunda gösterilmiştir. Formüllerle gösterilen x, sinyali temsil etmektedir. Bu işlemler MATLAB kütüphanesi yardımıyla hesaplanmış [46–48]. Dört sinyalden toplam 100 adet özellik çıkarılmıştır. Her bir sinyalden 25 adet özellik çıkarımı yapıldıktan sonra akış diyagramda belirtildiği gibi kNN, SVMs ve Ensemble Tree sınıflandırma algoritması kullanılarak işlemler MATLAB üzerinden gerçekleştirilmiştir. Ayrıca, bu üç algoritma birleştirilerek hibrit makine öğrenmesi algoritması oluşturulmuştur.

Tablo 4.5. Fotopletismografi sinyaline ait özellikler denklem.

Numara	Özellikler	Denklem
1	Basıklık	$x_{kur} = \frac{\sum_{i=1}^n (x(i) - \bar{x})^4}{(n-1)S^4}$
2	Çarpıklık	$x_{ske} = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)S^3}$
3	* Çeyrekler Arası Açıklık	$IQR = iqr(x)$
4	Varyans Katsayısı	$DK = (S / \bar{x})100$
5	Geometrik Ortalaması	$G = \sqrt[n]{x_1 + \dots + x_n}$
6	Harmonik Ortalama	$H = n / \left(\frac{1}{x_1} + \dots + \frac{1}{x_n} \right)$
7	Aktivite- Hjort Parametresi	$A = S^2$
8	Mobilite- Hjort Parametresi	$M = S_1^2 / S^2$
9	Karmaşıklık- Hjort Parametresi	$C = \sqrt{(S_2^2 / S_1^2)^2 - (S_1^2 / S^2)^2}$
10	* Maksimum	$x_{max} = \max(x_i)$
11	Medyan	$\tilde{x} = \begin{cases} x_{\frac{n+1}{2}} & : x \text{ odd} \\ \frac{1}{2}(x_{\frac{n}{2}} + x_{\frac{n}{2}+1}) & : x \text{ even} \end{cases}$
12	* Ortalama Mutlak Sapma	$MAD = mad(x)$
13	* Minimum	$x_{min} = \min(x_i)$
14	* Merkezi Momentler	$CM = moment(x, 10)$
15	Ortalama	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} (x_1 + \dots + x_n)$
16	Ortalama Eğri Uzunluğu	$CL = \frac{1}{n} \sum_{i=2}^n x_i - x_{i-1} $

Tablo 4.5. (Devamı) Fotopletismografi sinyaline ait özellikler denklem

Numara	Özellikler	Denklem
17	Ortalama Enerji	$E = \frac{1}{n} \sum_{i=1}^n x_i^2$
18	Ortalama Karakök Değeri	$X_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i ^2}$
19	Standart Hata	$S_{\bar{x}} = S / \sqrt{n}$
20	Standart Sapma	$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
21	Şekil Faktörü	$SF = X_{rms} / \left(\frac{1}{n} \sum_{i=1}^n \sqrt{ x_i } \right)$
22	* Tekil değer ayrışımı	$SVD = \text{svd}(x)$
23	* %25 kırılmış ortalama	$T25 = \text{trimmean}(x, 25)$
24	* %50 kırılmış ortalama	$T50 = \text{trimmean}(x, 50)$
25	Ortalama Teager enerjisi	$TE = \frac{1}{n} \sum_{i=3}^n (x_{i-1}^2 - x_i x_{i-2})$

4.6. Özellik Seçimi

Özellik sayısı, makine öğrenimi performansını hem olumlu hem de olumsuz etkiler [56]. Özellik seçimi, olumsuz etkileri izole etmek için kullanılır. Bu süreç, etiket tahmin etme özelliklerinin gücüne göre alakalıdan alakasızlığa doğru sıralanır. Araştırmacılar, en ilgili olandan en az ilgili olana doğru sıralanmış bu veri kümesindeki çalışmalarına istedikleri kadar özellik ekleyebilirler. Bu nedenle gereksiz veri kullanmadan daha doğru sonuçlar alabilir ve program döngüsünü hızlandırmaktadır.

Özellik seçme yöntemleri tipik olarak, sınıflandırma performansını iyileştirmek için daha küçük bir özellik alt kümesini seçmek için kullanılır [57–59]. Bu çalışmada, yüksek performansından dolayı, özellik seçme algoritması olarak Fisher'in öznelilik seçme algoritması kullanılmıştır. Bu çalışmada, yüksek performansa sahip olması sebebiyle özellik seçme algoritması olarak Fisher özellik seçme algoritması kullanılmıştır. Çalışmada seçilen özellikler Tablo 4.6.'te özetlenmiştir. Tabloda R özelliklere ait ilişki düzeyini, F özellik numaralarını göstermektedir.

Tablo 4.6. Tüm veri seti için sinyallerden seçilen özelliklerin listesi.

S	PPG		PPG_LF		PPG_MF		PPG_HF	
Nr	F	R	F	R	F	R	F	R
1	17	0,082	2	0,027	2	0,029	8	0,081
2	8	0,062	1	0,021	1	0,022	1	0,060
3	25	0,041	11	0,021	6	0,022	25	0,042
4	11	0,039	4	0,021	11	0,022	14	0,042
5	14	0,039	8	0,019	8	0,020	7	0,042
6	22	0,039	16	0,019	25	0,020	3	0,041
7	2	0,039	6	0,018	18	0,019	24	0,040
8	9	0,038	25	0,018	20	0,018	9	0,039
9	3	0,033	22	0,018	14	0,018	18	0,039
10	19	0,032	17	0,003	17	0,007	19	0,037
11	1	0,017	13	0,003	13	0,007	11	0,021
12	21	0,007	15	0,002	15	0,002	4	0,005
13	16	0,005	14	0,002	4	0,002	13	0,005
14	6	0,003	20	0,001	3	0,001	21	0,003
15	4	0,003	3	0,000	16	0,000	6	0,002
16	7	0,001	12	0,000	7	0,000	20	0,002
17	12	0,001	7	0,000	22	0,000	17	0,002
18	13	0,001	21	0,000	12	0,000	12	0,001
19	15	0,001	19	0,000	21	0,000	15	0,001
20	10	0,000	5	0,000	5	0,000	5	0,001
21	20	0,000	18	0,000	19	0,000	16	0,001
22	23	0,000	10	0,000	10	0,000	2	0,000
23	5	0,000	23	0,000	23	0,000	10	0,000
24	18	0,000	24	0,000	24	0,000	22	0,000
25	24	0,000	9	0,000	9	0,000	23	0,000

S Sinyal, F Özellik, R Korelasyon Katsayısı

4.6.1. Fisher algoritması

Sınıflandırma işlemi için en uygun özellikleri belirleyen yöntem olarak Fisher algoritmasıdır [60]. Fisher Score, denetimli bir doğrusal özellik çıkarma yöntemidir. Her özellik/değişken için, sınıflar arası varyansın sınıf içi varyansa oranı olan Fisher

puanını hesaplar. Algoritma, en yüksek Fisher Score sahip deęişkenleri seçer ve bir gösterge projeksiyon matrisi döndürür. Kullanıcı istedięi miktarda özellięi alarak sınıflandırma yapabilir. Özellikler Fisher Algoritmasının deęeri büyükten küçüęe doğru sıralanır.

Çalışmada PPG sinyali gürültüden temizlenmiş ve PPG'nin üç alt frekans bantlarına sahip yeni PPG sinyalleri elde edilmiştir. Dört sinyalden her birinden 25 adet özellik çıkarılmıştır. Toplam 100 adet özellik çıkarılmıştır. Buna ek olarak yaş, kilo ve boy özellik olarak kullanılmıştır. Performansın artırılması amacıyla Fisher özellik seçme algoritması kullanılmıştır.





5. MAKİNE ÖĞRENMESİ ALGORİTMALARI VE PERFORMANS DEĞERLENDİRME KRİTERLERİ

5.1. Makine Öğrenmesi Algoritmaları

Yapay zekâ (AI), insan zekasının, insanlar gibi düşünmeye ve eylemlerini taklit etmeye programlanmış makinelerde simülasyonunu ifade eder. Terim, öğrenme ve problem çözme gibi insan zihniyle ilişkili özellikler sergileyen herhangi bir makineye de uygulanabilir [61, 62]. Makine Öğrenmesi (machine learning) yöntemleri, problem çözmek için geliştirilmiştir. Bu yöntemler sayesinde birçok sorun çözülebilmektedir. Sınıflandırma problemleri de bu sorunlardan biridir ve günümüzde birçok problem bu şekilde tasarlanıp çözülebilmektedir [63]. Makine öğrenimi, geniş uygulama alanlarına sahip sınıflandırma problemlerinin çözümünde kullanılabilen bir yöntemdir. Günümüzde birçok problem, sınıflandırma problemleri olarak tasarlanabilir ve bir şekilde çözülebilir. Bu çalışmada kNN, SVMs, Ensemble Karar ağaç modelleri kullanılmıştır. Yöntemlerin seçilme sebepleri eğitim sürelerinin kısa ve doğruluk oranları yüksek olmasıdır [64, 65]. Yapılan analizlerde hataların önüne geçmek için hibrit makine öğrenmesi algoritma yapısı oluşturulmuştur [59–61]. Bu yöntemler, literatürde başarılı sonuçların elde edilmesi nedeniyle sıklıkla kullanılan makine öğrenme algoritmalarıdır. Ayrıca, bu kullanılan algoritmalar, gömülü sistemlere aktarılması için uygun olarak kabul edilir [69–71]. Modellerin eğitim için kullanılan veriler %50 eğitim %50 test aşamasında kullanılmıştır.

Makine öğrenmesi kullanım alanları

- Tıbbi teşhis
- Konuşma tanıma
- Trafik tahmini
- Görüntü Tanıma
- Sanal Kişisel Asistan
- Karar desteği ve Otomatik Dil Çevirisi vs.


5.1.1. Destek vektör makinaları

Destek vektör makineleri (SVMs), doğrusal ve doğrusal olmayan sınıflandırma problemlerinin çözümünde kullanılan ve önemli başarılar elde edilen bir makine algoritmasıdır yaygın olarak kullanılan denetimli makine öğrenme yöntemlerinden biridir. 1995 senesinde Vapnik ve Cortes tarafından geliştirilmiştir [30, 72]. Kalkülüs, vektör geometrisi ve kısıtlı en iyileme gibi matematik konularına dayanan bir makine öğrenmesi yöntemi olan destek vektör makineleri, temel olarak iki sınıf arasındaki maksimum mesafeyi belirleyen ve sınıf sınırlarını tanımlayan destek vektörleri kullanmaktadır. Bu yöntem, lineer olarak ayrılabilen sınıfları sınıflandırmak için kullanılabilir ve literatürde başarılı sonuçlar elde edilmesi nedeniyle sıkça tercih edilen bir yöntemdir. Ayrıca, bu yöntem, gömülü sistemlere aktarılması açısından da uygun bir seçenek olabilir. Mesafenin maksimize edilmesi, ikinci dereceden kısıtlanmış bir optimizasyon problemi olarak belirlenir ve ikili forma dönüştürülmektedir. Bu yaklaşım doğrusal problemler için geliştirilmiştir ve çekirdek dönüşümleri kullanılarak doğrusal olmayan ayrıştırma problemlerine genelleştirilebilir [73, 74].

Sınıflandırma problemlerini çözmek için geliştirilen bir makine öğrenmesi algoritması seçilirken dikkate alınması gereken en önemli kriterlerden biri, algoritmanın genelleme performansısıdır [75]. Bir düzlemde yer alan noktaların ayrıştırılması için kullanılan bir yöntem, doğru çizerek bu noktaları iki ayrı bölgeye ayırmaktır (Şekil 5.1). Bu yöntem, sınıflandırma problemlerinin çözümünde sıklıkla kullanılan bir tekniktir. Bu doğrunun, iki sınıfının noktaları için de maksimum uzaklıkta olmasını amaçlar. Sınır çizmek için iki grup için birbirine yakın ve paralel iki çizgi çizilir ve bu çizgiler birbirine yaklaştırılarak sınır çizgisi oluşturulur. SVM yöntemi, verileri birbirinden ayırmak için en uygun fonksiyonu tahmin etmeye dayanır. SVM, basit yapısı ve yüksek performansı nedeniyle pratik uygulamalarda çok kullanışlıdır. SVM'de kullanılan örnek sayısı önemli değildir. SVM'ler, eğitim sırasında görmediği verileri de sınıflandırmakta sorun yaşamazlar. Bu, SVM'nin genelleştirme yeteneğini gösterir. Genelleştirme yeteneği, SVM'leri diğer tekniklere iyi bir alternatif yapar [76].

Çalışmada tüm sınıflandırma işlemleri için özellikler 10 farklı özellik kümesine (5, 10, 15, 20, 25, 30, 35, 40, 45, 50) ayrılarak yapılmıştır. SVMs uygulanırken parametreler

için optimizasyon metodu kullanılmıştır. Bu metodun kullanılması performansı artırmıştır.



Şekil 5.1. SVMs algoritması genel akış diyagramı

5.1.1.1. Doğrusal destek vektör makineleri

Doğrusal destek vektör makineleri (DVM), hem doğrusal olarak ayrılabilen hem de doğrusal olarak ayrılamayan veriler için kullanılabilen güçlü ve popüler bir sınıflandırma algoritmasıdır. İki sınıfı en büyük marjla ayıran hiper düzlemi bularak çalışır. Marj, hiper düzlem ile her bir sınıfın en yakın veri noktaları arasındaki mesafedir.

İkili sınıflandırma probleminde, doğrusal DVM'nin amacı iki sınıfı ayırabilen bir hiper düzlem bulmaktır. Hiper düzlem $w \cdot x + b = 0$ olarak tanımlanır; burada w ağırlık vektörü, x özellik vektörü ve b yanlılık terimidir. Ağırlık vektörü w ve yanlılık terimi b eğitim süreci sırasında öğrenilir [81].

Optimum hiper düzlem aşağıdaki optimizasyon problemi çözülerek bulunur:

$$w = y_i(w \cdot x_i + b) \geq 1 \quad (5.1)$$

olacak şekilde $\|w\|$ 'yi en aza indirmektedir. Burada y_i i. veri noktasının etiketi, x_i i. veri noktasının özellik vektörü ve $\|w\|$ ağırlık vektörünün normudur. Eşitsizlik kısıtı,

hiper düzlemin tüm eğitim veri noktalarını doğru şekilde sınıflandırmasını sağlar. Optimum hiper düzlem bulunduğunda, $w \cdot x + b$ hesaplanarak ve hiper düzlemin hangi tarafına düştüğü kontrol edilerek yeni bir veri noktası sınıflandırılabilir. Sonuç pozitifse, veri noktası bir sınıfa ait olarak sınıflandırılır ve sonuç negatifse, diğer sınıfa ait olarak sınıflandırılır [82].

Doğrusal DVM'ler hesaplama açısından verimlidir ve yüksek boyutlu verilerle başa çıkabilir. Ayrıca gürültülü verilere ve aykırı değerlere karşı da dayanıklıdır. Ancak, çok sayıda özellik içeren veya karar sınırının yüksek oranda doğrusal olmadığı veri kümelerinde iyi performans göstermeyebilirler. Bu durumlarda, doğrusal olmayan DVM'ler veya diğer algoritmalar daha uygun olabilir.

5.1.1.2. Radyal taban fonksiyonu destek vektör makineleri

Radyal Temelli Fonksiyon (RBF) DVM, hem doğrusal olarak ayrılabilen hem de doğrusal olarak ayrılamayan veriler için kullanılabilen popüler bir sınıflandırma algoritmasıdır. RBF çekirdeğini kullanarak giriş verilerini yüksek boyutlu bir özellik uzayına eşleyerek ve iki sınıfı en büyük marjla ayıran hiper düzlemi bularak çalışır. RBF çekirdeği şu şekilde tanımlanır:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (5.2)$$

Burada x_i ve x_j iki veri noktası, $\|x_i - x_j\|$ aralarındaki Öklid mesafesi ve γ da çekirdeğin genişliğini kontrol eden bir hiperparametredir. Çekirdek, yüksek boyutlu özellik uzayında iki veri noktası arasındaki benzerliği hesaplar. Benzerlik ne kadar yüksek olursa, noktalar özellik uzayında o kadar yakın olur.

RBF DVM'nin amacı, özellik uzayında iki sınıf arasındaki marjı maksimize eden hiper düzlemi bulmaktır. Marjin, hiper düzlem ile her bir sınıfın en yakın veri noktaları arasındaki mesafe olarak tanımlanır. Optimum hiper düzlem aşağıdaki optimizasyon problemi çözülerek bulunur:

$$R = 1/2 * \|w\|^2 + C * \sum_{i=1}^n (x_i) \quad (5.3)$$

$$RBF = y_i(w * \phi(x_i) + b) \geq 1 \quad (5.4)$$

Burada y_i birinci veri noktasının etiketi, x_i giriş verisi, $\phi(x_i)$ yüksek boyutlu uzayda dönüştürülmüş özellik vektörü, w ağırlık vektörü, b sapma terimi ve C marjı maksimize etme ile sınıflandırma hatasını minimize etme arasındaki dengeyi kontrol

eden bir hiperparametredir. Amaç fonksiyonundaki toplam, yanlış sınıflandırılan veri noktalarını cezalandırır.

Optimum hiper düzlem bulunduğunda, $w \cdot \phi(x) + b$ hesaplanarak ve hiper düzlemin hangi tarafına düştüğü kontrol edilerek yeni bir veri noktası sınıflandırılabilir. Sonuç pozitifse, veri noktası bir sınıfa ait olarak sınıflandırılır ve sonuç negatifse, diğer sınıfa ait olarak sınıflandırılır [83, 84].

RBF DVM'ler esnektir ve doğrusal olarak ayrılamayan verilerle başa çıkabilir. Bununla birlikte, γ ve C gibi hiperparametrelerin seçimine duyarlıdır ve hiperparametreler uygun şekilde ayarlanmazsa verilere aşırı veya yetersiz uyum sağlayabilirler.

5.1.2. k-en yakın komşuluk algoritması

Sınıflandırma grubu altında benzerlik fonksiyonlarının kullanıldığı bir algoritma olan k-en yakın komşu (k-nearest neighborhood – k-NN) algoritması olarak en yakın k komşuya bakıyor. k-NN, sınıflandırma grubu altında anlaşılması kolay basit bir algoritmadır. k-NN algoritması, finans, sağlık, öneri sistemleri ve çok daha fazlasında bir dizi gerçek dünya sorunu için kullanılabilen basit bir araçtır. Sınıflandırma problemlerini çözmek için denetimli bir öğrenme yöntemidir [30, 50]. k-NN, sınıflandırma problemlerini, regresyon problemlerini çözmek için kullanılabilen basit, uygulaması kolay, denetimli bir makine öğrenimi algoritmasıdır. k-NN sınıflandırıcısı, parametrik olmayan bir denetimli makine öğrenme algoritmasıdır. Bu yöntem, verilerin sınıflandırılması için kullanılır ve sınıflandırma işlemi, örnek verilerin benzerliklerine dayanarak yapılır. k-NN algoritması, verilerin belirli bir uzayda temsil edildiği varsayımına dayanır ve yeni verilerin sınıflandırılması için, önceden belirlenmiş bir sayıda en yakın komşusu kullanılır. k-NN algoritması, eğitim aşamasında herhangi bir parametrenin belirlenmesine gerek duymaz ve bu nedenle, genellikle basit, verimli ve etkili bir sınıflandırma yöntemi olarak kabul edilir. Mesafeye dayalıdır: nesneleri en yakın komşularının sınıflarına göre sınıflandırır. kNN çoğunlukla sınıflandırma için kullanılır, ancak regresyon problemlerine de uygulanabilir. Endüstride ise sınıflandırma problemlerinde en yaygın kullanılmaktadır. k-NN sınıflandırma algoritması 1967 senesinde Peter. E. Hart ve. Thomas M. Cover tarafından geliştirilmiştir.

k-NN, mesafe hesaplamasına dayalı olarak en yakın k verisini bulmak için eğitim verisi ve önceden tanımlanmış bir k değeri gerektirecek şekilde yarı denetimli bir öğrenme algoritmasıdır [77]. Eğer k verinin farklı sınıfları varsa, algoritma bilinmeyen verinin sınıfının çoğunluk sınıfıyla aynı olacağını tahmin eder. Örneğin, bir Öklid (Euclidean) mesafe metriği ile k-en yakın komşu algoritmasını kullanarak uygun yeni veri sınıfını bulmak için kavram gösterilebilir.

İki boyutlu veya çok boyutlu bir uzayda özellik çıkarımından sonra, kNN algoritması, "X" ve "Y" verilerinden oluşan iki sınıftan oluşur ve ayrıca bilinmeyen bir "?" veri noktası bulunmaktadır. Bu veri noktası hangi sınıfa ait olduğunu çözmek için kNN algoritmasına ihtiyaç duyulmaktadır. kNN yardımıyla veri kümesinin sınıfını kolayca belirlerler. Veri noktası komşularını oy çoğunluğuyla belirlemektedir. Mesafe hesaplamaları için üç (3) farklı uzaklık fonksiyonu kullanılabilir. Bunlar (1) "Manhattan" Uzaklık, (2) "Euclidean" Uzaklık, (3) "Minkowski" Uzaklığı'dır.

k-NN algoritmasının makine öğrenme üzerindeki çalışma yöntemi


- Knn sınıflandırma algoritmasını uygulamak için veri yüklenmesi gerekmektedir. Eğitim ve test verileri.
- En yakın k değeri veri noktaları seçilmeli. K herhangi bir tam sayı olabilir.
- Tüm test verileri için aşağıdaki adımları gerçekleştirin.
- Euclidean mesafesi, Hamming veya Manhattan kullanarak test verileri ile her bir eğitim seti arasındaki mesafeyi hesaplayın. Euclidean yöntemi, mesafeleri hesaplamak için en yaygın kullanılan yöntemdir.
- Kayıtları artan mesafe değerine göre sıralayın.
- Sıralanmış dizide en üstteki k satırı seçilir.
- Test noktalarını bu sıralardan en çok öne çıkan sınıfa göre kategorize edin.
- Sonlandır

k-NN'in üstünlükleri:

- Basit algoritma kullanılır
- Hızlı hesaplanır ve sonuç verir
- Çok yönlü olduğu için, sınıflandırma algoritması için kullanılmaktadır.
- Uygulanabilirliğin kolay olması.
- Karmaşık veya kompleks (gürültülü) eğitim verileri için etkilidir

k-NN'nin kısıtları:

- Büyük verileri tahmin etmek yavaştır
- Veri ölçeklendirmeye ve ilgisiz özelliklere duyarlı
- Tüm eğitim veri setini saklamak için yüksek bellek gerekir.
- Büyük eğitim veri setlerde hesaplama açısından zor ve pahalıdır.



Şekil 5.2. kNN algoritması genel akış diyagramı

Her sınıfın özelliklerinin açıkça belirtilmesi önemlidir. Yöntem performansı, k-NN sayısı, eşit, benzerlik ve eğitim setindeki yeterli sayıda başarılı davranıştan etkilenir. k-NN tabanlı sınıflandırma yöntemi önce k değerleri seçer. k için büyük bir değer seçmek, farklı veri kümelerini toplayabilir. Çalışmalar genellikle 3, 5 veya 7 k değerlerini tercih eder [30, 78].

5.1.3. Naive bayes algoritması

Naive Bayes, sınıflandırma görevleri için kullanılan popüler olasılıksal bir algoritmadır. Bayes teoremine dayanır ve bir sınıfta belirli bir özelliğin varlığının başka herhangi bir özelliğin varlığıyla ilgisiz olduğunu varsayar. Naive Bayes

sınıflandırıcı, bir dizi özellik (x) verildiğinde bir sınıfın (y) olasılığını hesaplar. Matematiksel olarak şu şekilde ifade edilebilir:

$$P(y | x) = \frac{P(x | y) * P(y)}{P(x)} \quad (5.5)$$

Burada $P(y | x)$ özellikler göz önüne alındığında sınıfın sonsal olasılığı, $P(x | y)$ sınıf göz önüne alındığında özelliklerin olasılığı, $P(y)$ sınıfın önsel olasılığı ve $P(x)$ özelliklerin önsel olasılığıdır.

Naive Bayes yöntemindeki "naif" varsayım, özelliklerin birbirinden bağımsız olduğudur. Bu, olasılığın hesaplanmasını basitleştirir ve algoritmayı hesaplama açısından verimli hale getirir.

Yeni bir veri noktasını sınıflandırmak için Naive Bayes algoritması, özellikler göz önüne alındığında her bir sınıfın son olasılığını hesaplar ve en yüksek olasılığa sahip sınıfı seçer [79]. Algoritma hem sürekli hem de kategorik özellikleri işleyebilir. Genel olarak, Naive Bayes yöntemi sınıflandırma görevleri için basit ancak güçlü bir algoritmadır ve doğal dil işleme, spam filtreleme ve görüntü tanıma dahil olmak üzere çeşitli alanlarda yaygın olarak kullanılmaktadır.

5.1.4. Rastgele orman algoritması

Rastgele Orman, bir sınıflandırma veya regresyon problemi çözmek için kullanılan bir makine öğrenmesi algoritmasıdır. Bu algoritma, birden çok karar ağacını birleştirerek çalışır ve böylece daha doğru sonuçlar elde eder. Rastgele Orman algoritması, veri setinin bir parçasını rastgele seçerek birden çok karar ağacı oluşturur. Her ağaç, rastgele seçilen bir özellik kümesine dayanarak verileri bölerek ağaçları oluşturur. Böylece, her bir ağacın birbirinden farklı bir yapıya sahip olması sağlanır [80].

Sonuç olarak, algoritma, tüm ağaçların tahminlerinin ortalamasını alarak bir sonuç üretir. Bu sayede, ayrı ayrı karar ağaçlarının yapabileceği hataların dağılımı azaltılır ve daha güvenilir sonuçlar elde edilir. Rastgele Orman algoritması, sınıflandırma ve regresyon problemleri için etkili bir çözüm sunar ve birçok endüstriyel ve akademik uygulamada yaygın olarak kullanılmaktadır.

5.1.5. Çok katmanlı algılayıcı ağ

Çok katmanlı algılayıcı ağ (Multi Layer Perceptron MLP), sınıflandırma görevleri için yaygın olarak kullanılan ileri beslemeli bir sinir ağıdır. Bir giriş katmanı, bir veya daha

fazla gizli katman ve bir çıkış katmanından oluşur. Her katman, düğüm olarak da bilinen bir veya daha fazla nörondan oluşur. Her katmandaki nöronlar bir önceki ve bir sonraki katmandaki nöronlara tamamen bağlıdır ve her bağlantının ilişkili bir ağırlığı vardır.

Eğitim süreci sırasında MLP, eğitim verilerindeki sınıflandırma hatasını en aza indirmek için nöronlar arasındaki bağlantıların ağırlıklarını ayarlamayı öğrenir. Bu genellikle sinir ağlarını eğitmek için popüler bir algoritma olan geri yayılım kullanılarak yapılır.

Gizli katmanlardaki nöronlar, çıktıları hesaplamak için bir aktivasyon fonksiyonu kullanır. Aktivasyon fonksiyonu modele doğrusal olmayan bir özellik katar ve MLP'nin doğrusal olmayan karar sınırlarını öğrenmesini sağlar. Popüler aktivasyon fonksiyonları arasında sigmoid fonksiyonu, hiperbolik tanjant fonksiyonu ve düzeltilmiş doğrusal birim (ReLU) fonksiyonu bulunur.

MLP'nin çıktı katmanı tipik olarak sınıflandırma problemindeki her sınıf için bir nörondan oluşur. Her nöronun çıkışı, giriş verilerinin o sınıfa ait olma olasılığını temsil eder. MLP, çıktı katmanının çıktıları sınıflar üzerinde bir olasılık dağılımına dönüştürmek için bir softmax işlevi kullanır.

Çıkarım sırasında MLP bir giriş veri noktası alır ve bunu giriş katmanından besler. Gizli katmanlardaki her bir nöronun çıkışı aktivasyon fonksiyonu kullanılarak hesaplanır ve bir sonraki katmana aktarılır. MLP'nin nihai çıkışı, softmax fonksiyonu tarafından hesaplanan sınıflar üzerindeki olasılık dağılımıdır [85].

MLP'ler karmaşık doğrusal olmayan karar sınırlarını öğrenebilir ve çeşitli sınıflandırma görevlerinde yaygın olarak kullanılır. Bununla birlikte, eğitilmeleri hesaplama açısından pahalı olabilir ve model çok karmaşıksa veya eğitim verileri çok küçükse verilere aşırı uyum sağlayabilirler. Aşırı uyumu azaltmak için ağırlık azaltma veya bırakma gibi düzenli hale getirme teknikleri kullanılabilir.

5.1.6. Ensemble tree

Bir ağaç topluluğu, bireysel karar ağaçlarından elde edilen sonuçları harmanlayarak tahminde bulunur [86]. Ensemble Karar Ağaçları regresyon ve sınıflandırma problemlerinde sıklıkla kullanılan makine öğrenmesi algoritmalarından biridir [80, 81]. Ensemble'nın temel çalışma ilkesine dayanarak, herhangi bir sınıflandırma işlemlerini

çok aşamalı bir hale getirilerek basit bir karar verme işleminin gerçekleştirilmesi esasına dayanmaktadır [89]. Bir nesnenin hangi sınıfa gireceğini tahmin etmeye çalışmak için bir sınıflandırma algoritması kullanır. Birçok sınıflandırma yönteminden probleme uygun olanı seçip gerekli optimizasyonları yaparak yüksek doğruluk elde etmeye çalışıyoruz.


Ensemble yöntemi; tek bir modelden daha güçlü ve genelleştirilebilir sonuçlar üretmek için çoklu tabanlı modellerin tahmin sonuçlarını birleştirme. Bu yöntemlerin başarısı iki kritere dayanmaktadır. Temel öğrencilerin öğrenme başarıları ve birbirlerinden farklılıkları. Model performansı düşebilir. Bu durumda, çoklu karar mekanizması, performans pahasına bile sistem kararlılığını sağlar.

Ensemble sınıflandırıcılar, daha güvenilir veya kararlı tahminler üretmek için farklı sınıflandırıcıların birleştirilmesiyle oluşturulan sistemlerdir. Sistem, tek veya çift sayıda N sınıflandırıcı ile oluşturulmuştur. Sınıflandırma sırasında her bir sınıflandırıcının ürettiği çıktı değerleri sayılır. Topluluk sınıflandırıcısının kararı çoğunluk kuralına göre belirlenir.

Bu çalışmada, sınıflandırma algoritması olarak SVMs, kNN ve Ensemble Tree olmak üzere üç sınıflandırıcı kullanılarak MATLAB ortamında hazırlanmıştır.

5.1.7. Karar ağaçları

Veri madenciliğinde yaygın olarak kullanılan tekniklerden biri de sınıflandırıcılar oluşturan sistemlerdir. Karar ağaçları (KA), makine öğrenimi, görüntü işleme ve görüntülerin tanımlanması gibi çeşitli alanlarda yaygın olarak kullanılan güçlü yöntemlerden biridir [90]. Karar ağacı hem sınıflandırma hem de regresyon görevleri için kullanılan, parametrik olmayan denetimli bir öğrenme algoritmasıdır. Kök düğüm, dallar, iç düğümler ve yaprak düğümlerden oluşan hiyerarşik bir ağaç yapısına sahiptir. Adından da anlaşılacağı gibi, ağaç benzeri bir karar modeli kullanır. Belirli bir hedefe ulaşmak için bir strateji türetmek için veri madenciliğinde yaygın olarak kullanılan bir araç olsa da makine öğreniminde de yaygın olarak kullanılmaktadır. Karar ağacı algoritmalarının temel yapısı kökleri, dalları, düğümleri ve yaprakları içerir. Bir karar ağacının temel yapısı Şekil 5.3.'te gösterilmiştir.




Şekil 5.3. Karar ağaçları genel yapısı.

Ağaç yapısını oluştururken, her öznelilik bir düğüme atanır. Kök ile düğüm arasında bir dal vardır. Her düğümden dallar aracılığıyla diğer düğümlere iletilir. Ağaç kararlarını son yaprağa göre verir. Ağacın son kısmına yaprak, üst kısmına ise kök adı verilir [91]. Karar ağacı yapısının oluşturulmasındaki temel mantık, ulaşılan her düğümden ilgili soruyu sormak ve verilen cevabı takip ederek son yaprağa en kısa yol ve sürede ulaşmak olarak özetlenebilir. Bu nedenle, bir sorudan verilen cevaplar doğrultusunda bir karar kuralı/modeli oluşturmanız gerekmektedir. Bu eğitilmiş ağaç yapısının doğruluğu, çeşitli test verileri kullanılarak kontrol edilir ve sonuçlar tatmin edici ise model kullanılır.

5.1.8. Hibrit yapay zekâ yöntemi

Günümüzde kurumların operasyonel çözümler yerine yapay zekâyı giderek daha fazla konumlandığını ve hızla iş süreçlerine entegre ettiğini gözlemleyebiliyoruz [92]. Hibrit yapay zekâ alınan sınıflandırma işlemlerini birleştirerek çoğunluğun verdiği

cevabı üretir (Şekil 5.4.). Zayıf sınıflandırıcıya bir araya getirip kuvvetli sınıflandırma ortaya çıkarmaktır. Sınıflandırıcı sayısı arttıkça model kararlılıkları artmaktadır.



Şekil 5.4. Hibrit yapay zekâ modeli algoritması genel akış diyagramı.

5.2. k-Kat Çapraz Doğrulama Yöntemi

k-kat çapraz doğrulama, bir makine öğrenmesi modelinin performansını değerlendirmek için kullanılan bir test tekniğidir. Bu yöntem ile veri seti k tane kümeye bölünür. Kümelerin k-1 tanesi eğitim için bir tanesini de test için kullanılır. Böylece her bir küme hem eğitim hem de test aşamasından geçer. Her bir iterasyonda karmaşıklık matrisi elde edilir. Bu matrise göre performans metrikleri hesaplanır. Son aşamada elde edilen k tane performans metriğinin ortalaması alınır ve modelin performansı ortaya çıkar [93].

k-kat çapraz doğrulama yöntemi ile modelin aşırı uyumu (overfitting) veya aşırı basitlik (underfitting) gibi problemleri tespit edilir. k-kat çapraz doğrulama yöntemi, hem küçük hem de büyük veri setleri için uygun bir yöntemdir. Küçük veri setleri için, modelin doğruluğunu daha güvenilir bir şekilde değerlendirmek için kullanılır. Büyük veri setleri için ise, veri setinin sadece bir bölümünü eğitim verisi olarak kullanarak, eğitim süresini azaltabilir.

5.3. Performans Metrikleri

Biz bu çalışma da makine öğrenmesi modelinin performans analizi için Tablo 5.1.'de görülen doğruluk, kesinlik, duyarlılık, özgüllük, Mathew Korelasyon Katsayısı (MCC) ve F-skor performans metriklerini hesapladık.

Tablo 5.1. Karmaşıklık Matrisi

		Tahmin Edilen	
		Pozitif	Negatif
Gerçek Durum	Pozitif	TP	FN
	Negatif	FP	TN

Doğruluk: Bir modelin doğruluğunu ölçmek için kullanılan en basit metriktir. Doğruluk, denklem 5.6'da doğru tahminlerin toplam sayısının toplam örnek sayısına bölünmesiyle hesaplanır. TP, True Positiv (Gerçek Pozitif) anlamına gelir; TN, True Negative (Gerçek Negatif) anlamına gelir; FP, False Positive (Yanlış Pozitif) anlamına gelir; ve FN, False Negative (Yanlış Negatif) anlamına gelir.

$$Doğruluk = \frac{TP+TN}{TP+TN+FN+FP} \quad (5.6)$$

Kesinlik (Precision): Kesinlik, denklem 5.7'de görüldüğü üzere bir modelin pozitif olarak tahmin ettiği örneklerin gerçekten pozitif olma olasılığıdır. Örneğin, bir e-posta spam filtresi için precision, spam olarak sınıflandırılan e-postaların gerçekten spam olma oranını ölçer.

$$Kesinlik = \frac{TP}{TP+FP} \quad (5.7)$$

Duyarlılık (Recall): Duyarlılık, denklem 5.8'de görüldüğü üzere gerçek pozitif örneklerin toplam pozitif örnek sayısına bölünmesiyle hesaplanan bir metriktir. Örneğin, bir kanser tarama testi için recall, gerçek kanserli hastaların test sonucunda tespit edilme oranını ölçer.

$$Duyarlılık = \frac{TP}{TP+FN} \quad (5.8)$$

Özgüllük (Specificity): Özgüllük, denklem 5.9'da görüldüğü üzere gerçek negatif örneklerin toplam negatif örnek sayısına bölünmesiyle hesaplanan bir metriktir..

Örneğin, bir suçluluk belirleme testi için specificity, gerçek suçsuz insanların test sonucunda doğru bir şekilde suçsuz olarak tespit edilme oranını ölçer.

$$\text{Özgüllük} = \frac{TN}{FP+TN} \quad (5.9)$$

MCC (Matthews Korelasyon Katsayısı): Matthew's Korelasyon Katsayısı (MCC), denklem 5.10'da görüldüğü üzere doğru pozitifler (TP), doğru negatifler (TN), yanlış pozitifler (FP) ve yanlış negatifleri (FN) dikkate alarak ikili sınıflandırma tahminlerinin kalitesini ölçen bir metriktir. MCC -1 (tahmin ile temel gerçek arasında mükemmel uyuşmazlık) ile +1 (tahmin ile temel gerçek arasında mükemmel uyum) arasında değişir ve 0 değeri korelasyon olmadığını gösterir.

MCC şu şekilde tanımlanır:

$$MCC = \frac{(TP * TN - FP * FN)}{\sqrt{((TP + FP) * (TP + FN) * (TN + FP) * (TN + FN))}} \quad (5.10)$$

Burada TP, TN, FP ve FN sırasıyla doğru pozitiflerin, doğru negatiflerin, yanlış pozitiflerin ve yanlış negatiflerin sayısını temsil eder.

MCC dört değeri de (TP, TN, FP ve FN) dikkate alır ve sınıflar dengesiz olduğunda veya yanlış pozitiflerin ve yanlış negatiflerin maliyeti farklı olduğunda kullanışlıdır. 1 değeri tahminin mükemmel olduğunu gösterirken -1 değeri tahminin tamamen yanlış olduğunu gösterir.

MCC, makine öğreniminde, özellikle ikili sınıflandırıcıların değerlendirilmesinde yaygın olarak kullanılır. Sınıflar dengesiz olduğunda veya yanlış pozitiflerin ve yanlış negatiflerin maliyeti farklı olduğunda doğruluktan daha güvenilir bir metriktir.

F-skoru veya F1-skoru, sınıflandırma modellerinin performansını değerlendirmek için yaygın olarak kullanılan bir ölçüttür. Denklem 5.11'de görüldüğü üzere hassasiyet ve geri çağırma olarak adlandırılan diğer iki sınıflandırma metriği kullanılan F-skoru, hassasiyet ve geri çağırmanın ağırlıklı harmonik ortalamasıdır.

$$F = 2x \frac{\text{Özgüllük} \times \text{Duyarlılık}}{\text{Özgüllük} + \text{Duyarlılık}} \quad (5.11)$$

F-skoru, 0 ile 1 arasında değişen bir değere sahiptir ve daha yüksek bir skor, daha iyi bir performansı gösterir [94].

Kappa: Kappa istatistiği, gözlenen doğruluk ile beklenen doğruluğu karşılaştıran bir metriktir.

$$Kappa = \frac{(P_o - P_e)}{(1 - P_o)} \quad (5.12)$$

Uyum derecesi ile ilgili olarak literatürde Kappa katsayısı için farklı limitler tanımlanmıştır [95]. Bu çalışmada Tablo 5.2.'deki eşik değerler kullanılmıştır.

Tablo 5.2. Kappa katsayıları sınır aralıkları

Kappa katsayıları	Açıklamalar
0,81 – 1,00	Uyum düzeyi Çok iyi
0,61 – 0,80	Uyum düzeyi iyi
0,41 – 0,60	Uyum düzeyi Orta
0,21 – 0,40	Uyum düzeyi Düşük
0,00 – 0,20	Uyum düzeyi zayıf
<0,00	Uyum düzeyi Çok zayıf

5.4. Leave-One Out Yöntemi

Leave-one-out (LOO), bir makine öğrenimi algoritmasının performansını tahmin etmek için kullanılan bir çapraz doğrulama tekniğidir. LOO'da algoritma biri hariç tüm veri noktaları üzerinde eğitilir ve performans dışarıda bırakılan nokta üzerinde değerlendirilir. Bu işlem veri kümesindeki tüm veri noktaları için tekrarlanır ve ortalama performans raporlanır.

LOO yöntemi, algoritmanın performansının diğer çapraz doğrulama yöntemlerine göre daha güvenilir bir şekilde tahmin edilmesini sağladığından, veri kümesi küçük olduğunda özellikle kullanışlıdır. Ayrıca LOO, eğitim için mevcut tüm verileri kullanma avantajına sahiptir ve bu da daha iyi bir modelle sonuçlanabilir. LOO'yu uygulamak için, bir veri noktasını doğrulama kümesi ve kalan veri noktalarını eğitim kümesi olarak seçerek başlarsınız. Ardından, makine öğrenimi algoritmasını eğitim

kümesi üzerinde eğitir ve performansını doğrulama kümesi üzerinde değerlendirirsiniz. Ardından, doğrulama kümesi olarak farklı bir veri noktası seçer ve her veri noktasını bir kez doğrulama kümesi olarak kullanana kadar işlemi tekrarlırsınız. Her veri noktası için algoritmanın performansını değerlendirdikten sonra, algoritmanın genel performansını tahmin etmek için ortalama performans metriğini (doğruluk veya hata gibi) hesaplayabilirsiniz. Bu ortalama performans, algoritmanın farklı veri alt kümeleri üzerindeki performansının birden fazla değerlendirmesine dayandığından, genellikle tek bir eğitim/test ayrımı kullanmaktan daha güvenilirdir.

Bu çalışmada, %50 eğitim ve %50 test olacak şekilde hesaplama algoritmalarına göre sınıflandırılmıştır. Makine Öğrenmesi için süreye bağlı eğitim (%50) ve test (%50) veri seti dağılımı Tablo 5.3.'te gösterilmiştir. Hasta ve sağlıklı olarak veri dağılımı 2-1024 süreler arasında yapılmıştır. Eğitim ve Test hasta ve sağlıklılardan alınan veriler Hasta ve Sağlıklı bireyler epoklama işlemi gerçekleştirilmiştir.

Tablo 5.3. Makine öğrenmesi için süreye bağlı eğitim (%50) ve test (%50) veri seti dağılımı

Süre	Eğitim (%50)		Test (%50)		Toplam (%100)	
	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı
2	56092	53408	56092	53407	112184	106815
4	28039	26699	28039	26698	56078	53397
8	14014	13343	14014	13343	28028	26686
16	7001	6666	7001	6666	14002	13332
32	3494	3328	3494	3328	6988	6656
64	1741	1659	1741	1659	3482	3318
128	864	825	865	824	1729	1649
256	426	408	427	406	853	814
512	207	198	207	198	414	396
1024	97	95	98	93	195	188

Çalışma sonuçlarının başarısı tüm değerlendirme yöntemlerine ek olarak Leave-one-out yöntemiyle yeniden değerlendirilmiştir. 8 hasta 6 sağlıklı birey için eğitim ve test veri seti Tablo 5.4.'te gibi düzenlenmiştir. Veri seti 6 gruba ayrılarak işlem yapılmıştır.

Tablo 5.4. Leave-one-out yöntemine göre makine öğrenmesi için süreye bağlı eğitim ve test veri seti dağılımı

Eğitim					Test			
Grup	HN	HE	SN	SE	HN	HE	SN	SE
1	2-8	97861	2-6	76355	1	14323	1	17263
2	1,3-8	89971	1,3-6	74225	2	22213	2	19393
3	1-2,4-8	109936	1-2,4-6	78155	3	2248	3	15463
4	1-3,5-8	95956	1-3,5-6	78155	4	16228	4	15463
5	1-4,6-8	98206	1-4,6	82355	5	13978	5	11263
6	1-5,7-8	96511	1-5	78845	6	15673	6	14773

Sayılar birey numaralarını ifade eder.

HN- Hasta No, **HE-**Hasta Epok, **SN-**Sağlıklı No, **SE-** Sağlıklı Epok

Önerilen sistemin doğruluğunu test etmek için farklı performans değerlendirme kriterleri kullanılmaktadır. Bunlar doğruluk, hassasiyet, özgüllük, kappa katsayısı, alıcı işletim karakteristiği (ROC), ROC eğrisi altındaki alan (AUC) ve k-katlı çapraz doğrulama doğruluğudur [56].

Özellik kümeler sınıflandırılırken Eğitim (50%) ve Test (50%) veri setlerine ayrılmıştır (Tablo 5.5). Alınan verilerde Sağlıklı ve Kontrol olmak üzere 14 hastadan alınan veriler 2 saniye epoklama işlemleri gerçekleştirilmiştir. Alınan eğitim ve test sonuçlarından toplam Hasta sayısı 112184, Sağlıklı ise 106815'tir. Yapılan işlemlerde sınıflandırma algoritmaları kullanılarak, hibrit yapay zekâ yöntemiye sınıflandırma algoritmaları birleştirilerek en iyi performans sonuçları elde edilmiştir.

Tablo 5.5. (%50) Eğitim ve (%50) Test

	Yüzde	Hasta	Sağlıklı	Toplam
Eğitim	50%	56092	53408	109500
Test	50%	56092	53407	109499
Toplam	100%	112184	106815	218999

Performans değerlerinin hesabı için karmaşıklık matrisi oluşturulmuş ve performans parametreleri hesaplanmıştır Tablo 5.1.

Kappa değeri yorumlanırken Tablo 5.2. 'deki aralıklar göz önüne alınır. Bu değerlere göre 0.81 üzeri olan R değerleri sistem için oldukça iyidir.



6. SONUÇLAR

6.1. Kronik Obstrüktif Akciğer Hastalığı Minimum Süre Tespiti Modeline Dayalı Sonuçlar

Bu çalışmada KOAH teşhisi için PPG sinyali ile makine öğrenmesi tabanlı minimum teşhis süresi tespiti yapılmıştır. KOAH yapılan işlemlerde Şekil 4.1'deki akış diyagrama göre yapılmış ve sonuçlar elde edilmiştir. Öncelikle alınan veriler sayısal filtrelemeler yapılarak ön işlemler gerçekleştirilmiştir. Hastalardan alınan her veri için belli saniyelere dağılarak epoklama işlemleri gerçekleştirdik. Veriler dengeleme işlemleri yapıp nitelik grupları oluşturduk. Daha sonra özellikler seçilmiştir. Ardından veri seti eğitim ve test bölümlerine ayrılarak karar ağaçları ile sınıflandırılmıştır. Sonuçlar bölümünde, makine öğrenmesi algoritmalarının hem eğitim hem de test sonuçları verilmiştir. Ancak başarı değerlendirmeleri test üzerinden yapılması daha uygun olacaktır.

Çalışma ilk uygulaması 2-1024 saniye aralıklarındaki sinyallerin sınıflandırılmasını içermektedir. Bu amaçla yapılan analizlerin sonuçları Tablo 6.1. ve Tablo 6.2.'de performans değerlendirme kriterleri ile gösterilmiştir. Sonuçlar Tablo 6.2.'de incelendiğinde en iyi performans 2 saniyelik kayıtlar ile elde edilmiştir. Ayrıca, burada KOAH teşhisinin her uzunluktaki PPG sinyali ile yüksek doğruluk oranı ile tespit edilebildiği görülmüştür. Doğruluk oranı hariç, diğer performans kriterleri 0-1 aralığında değerler almaktadır ve 1 en iyi değeri temsil etmektedir. Doğruluk oranı ise % üzerinden verilmiş olup en yüksek değer 100'dür.

Özellik seçme algoritması kullanımı ile birlikte analizler tekrarlanmıştır Tablo 6.3. ve Tablo 6.4. Burada en iyi performans %72,06 doğruluk oranı ile 512 saniyelik kayıtlardan elde edilmiştir. Diğer kayıt süreleri için yapılan analiz performans sonuçları da oldukça iyidir. Hastalığın teşhisi için sensitivity değerinin yüksek olması beklenir. Bu yüzden Tablo 6.4'te görüldüğü gibi 0.86 duyarlılık değerine sahip 1024 saniyelik kayıtlarda KOAH teşhisi için faydalı olabilir.

Çalışmanın güvenilirliğinin artırılması için tüm özelliklerle birlikte Leave-one-out yöntemi ile sınıflandırma işlemi tekrarlanmıştır. Leave-one-out yöntemine göre eğitim ve test dağılımında Tablo 5.4.'te verilmiştir. Sınıflandırma sonuçları eğitim ve test olmak üzere Tablo 6.5 ve Tablo 6.6. 'da özetlenmiştir. Eğitim sonuçları oldukça iyidir. Ancak test sonuçlarının ortalama performans değeri %57,54 civarındadır. Bu oran sistemin geliştirilmesine ihtiyaç duyulduğunun göstergesidir.

Yapılan analiz sonucunda, KOAH teşhisi için tüm özelliklerin kullanıldığı 2 saniyelik kayıtlar ile elde edilen sonuçlar, Tablo 6.2'de görüldüğü üzere 0.94 duyarlılık, 0.97 özgüllük ve %99.8 doğruluk oranı gösterdi. Bu performans değerine ait karar ağacı yapısı Şekil 6.1'de gösterilmiştir. Kurallar karmaşık olmakla birlikte bilgisayar tabanlı uygulanabilir niteliktedir.

Tablo 6.1. Tüm özellikler için eğitim performans sonuçları

Saniye	Eğitim Performans Değerlendirem Kriterleri					
	Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa katsayısı	F-Ölçümü	AUC
2	0,99	0,99	98,99	0,98	0,99	0,99
4	0,99	0,99	99,13	0,98	0,99	0,99
8	0,98	0,98	97,96	0,96	0,98	0,98
16	0,99	0,99	98,79	0,98	0,99	0,99
32	0,99	0,99	99,08	0,98	0,99	0,99
64	0,99	0,98	98,35	0,97	0,98	0,98
128	0,99	0,98	98,64	0,97	0,99	0,99
256	0,97	0,99	97,84	0,96	0,98	0,98
512	0,97	0,91	94,07	0,88	0,94	0,94
1024	0,89	0,99	93,75	0,88	0,94	0,94

Tablo 6.2. Tüm özellikler için eğitim performans sonuçları

Saniye	Test Performans Değerlendirme Kriterleri					
	Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa	F-Ölçümü	AUC
2	0,94	0,97	95,31	0,91	0,95	0,95
4	0,94	0,91	92,36	0,85	0,92	0,92
8	0,92	0,95	93,76	0,88	0,94	0,94
16	0,92	0,88	89,97	0,80	0,90	0,90
32	0,92	0,87	89,53	0,79	0,89	0,89
64	0,92	0,88	90,00	0,80	0,90	0,90
128	0,90	0,93	91,53	0,83	0,92	0,92
256	0,84	0,84	84,03	0,68	0,84	0,84
512	0,86	0,85	85,93	0,72	0,86	0,86
1024	0,80	0,90	84,82	0,70	0,85	0,85

Tablo 6.3. Seçilmiş özellikler için eğitim performans sonuçları

Saniye	Eğitim Performans Değerlendirme Kriterleri					
	Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa	F-Ölçümü	AUC
2	0,76	0,72	74,40	0,49	0,74	0,74
4	0,94	0,94	94,32	0,89	0,94	0,94
8	0,81	0,72	76,68	0,53	0,76	0,77
16	0,89	0,87	87,93	0,76	0,88	0,88
32	0,94	0,95	94,83	0,90	0,95	0,95
64	0,93	0,94	93,74	0,87	0,94	0,94
128	0,81	0,75	78,03	0,56	0,78	0,78
256	0,92	0,92	91,73	0,83	0,92	0,92
512	0,92	0,92	92,10	0,84	0,92	0,92
1024	0,92	0,54	72,92	0,46	0,68	0,73

Seçilen özellik sayısı 6'dır.

Tablo 6.4. Seçilmiş özellikler için Test performans sonuçları

Saniye	Test Performans Değerlendirme Kriterleri					
	Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa Katsayısı	F-Ölçümü	AUC
2	0,74	0,70	72,01	0,44	0,72	0,72
4	0,74	0,66	70,07	0,40	0,70	0,70
8	0,78	0,71	74,50	0,49	0,74	0,74
16	0,75	0,69	72,55	0,45	0,72	0,72
32	0,75	0,66	70,76	0,41	0,70	0,71
64	0,74	0,69	71,85	0,44	0,72	0,72
128	0,75	0,72	73,59	0,47	0,74	0,74
256	0,72	0,65	68,55	0,37	0,68	0,68
512	0,69	0,82	75,06	0,50	0,75	0,75
1024	0,86	0,53	69,63	0,39	0,65	0,69

Seçilen özellik sayısı 6'dır.

Tablo 6.5. Leave-one-out için Eğitim Performans Sonuçları

Grup	Eğitim Performans Değerlendirme Kriterleri					
	Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa Katsayısı	F-Ölçümü	AUC
1	0,99	0,99	99,28	0,99	0,99	0,99
2	0,99	0,99	99,29	0,99	0,99	0,99
3	0,98	0,97	97,89	0,96	0,98	0,98
4	0,99	0,99	98,98	0,98	0,99	0,99
5	0,99	0,99	99,33	0,99	0,99	0,99
6	1,00	1,00	99,51	0,99	1,00	1,00
Ortalama	0,99	0,99	99,05	0,98	0,99	0,99

Tablo 6.6. Leave-one-out için Test Performans Sonuçları

Grup	Test Performans Değerlendirme Kriterleri					
	Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa Katsayısı	F-Ölçümü	AUC
1	0,48	0,66	58,15	0,15	0,56	0,57
2	0,78	0,38	59,30	0,16	0,51	0,58
3	0,23	0,93	84,09	0,18	0,37	0,58
4	0,30	0,97	63,03	0,27	0,46	0,64
5	0,77	0,01	43,19	-0,23	0,03	0,39
6	0,48	0,26	37,48	-0,26	0,34	0,37
Ortalama	0,51	0,54	57,54	0,05	0,38	0,52

6.2. Fotopletismografi Alt Frekans Bantları Ayrımına Dayalı Kronik Obstrüktif Akciğer Hastalığının Tahmin Sonuçları

Çalışma kapsamında, Tablo 6.7’de görüldüğü üzere PPG ve üç alt frekans bantlarına ait tüm özellikler hem ayrı ayrı hem de birlikte kullanılarak KOAH tahmini yapılmıştır. Tezde sunulan modellerde, PPG ve üç alt frekans bantlarına ait tüm özellikler kullanılarak hazırlanan tahminler, Tablo 6.7’de belirtilen performans değerlendirme kriterleri kullanılarak yapılmıştır. Hesaplanan performans değerlendirme kriterlerinin 1’e oldukça yakın olduğu tespit edilmiştir. PPG sinyali ile oluşturulan modelde doğruluk oranı yaklaşık %95’tir. PPG alt frekanslarına ait modellerin başarı oranları da %80 üzerinde olduğu görülmektedir. Modellerin duyarlılık ve özgüllük değerleri dengeli ve 0.85 üzerindedir.

Tablo 6.7. Tüm kayıtlar için tüm özelliklere göre elde edilen sonuçlar

Sinyal	Model	Tüm Özellikler için Performans Değerlendirme Kriterleri					
		Duyarlılık	Özgüllük	Doğruluk	Kappa	F-Ölçüm	AUC
PPG	k-NN	0,858	0,887	87,24	0,745	0,872	0,872
	SVMs	0,922	0,950	93,59	0,872	0,936	0,936
	ET	0,939	0,967	95,31	0,906	0,953	0,954
	Hibrit	0,940	0,961	95,10	0,902	0,951	0,952
PPG_LF	k-NN	0,746	0,823	78,37	0,568	0,782	0,784
	SVMs	0,790	0,835	81,24	0,625	0,812	0,813
	ET	0,877	0,929	90,30	0,806	0,903	0,904
	Hibrit	0,837	0,892	86,46	0,729	0,864	0,865
PPG_MF	k-NN	0,768	0,846	80,64	0,613	0,805	0,807
	SVMs	0,648	0,596	62,26	0,244	0,620	0,622
	ET	0,853	0,916	88,46	0,769	0,885	0,886
	Hibrit	0,813	0,877	84,44	0,689	0,844	0,854

Tablo 6.7. (Devamı) Tüm kayıtlar için tüm özelliklere göre sonuçlar

Sinyal	Model	Tüm Özellikler için Performans Değerlendirme Kriterleri					
		Duyarlılık	Özgüllük	Doğruluk	Kappa	F-Ölçüm	AUC
PPG_HF	k-NN	0,826	0,918	87,17	0,743	0,870	0,872
	SVMs	0,619	0,731	67,41	0,350	0,670	0,675
	ET	0,894	0,915	90,43	0,808	0,904	0,905
	Hibrit	0,836	0,925	87,95	0,759	0,878	0,880
All	k-NN	0,773	0,922	84,60	0,693	0,841	0,847
	SVMs	0,641	0,839	73,79	0,478	0,727	0,740
	ET	0,928	0,951	93,96	0,879	0,939	0,940
	Hibrit	0,828	0,955	89,03	0,781	0,887	0,891

Tüm özellik grupları Fisher özellik seçme algoritması yardımıyla azaltılarak KOAH tahmin modeli yeniden oluşturulmuştur.

PPG sinyallerinde Özellik seçme algoritması için kullanılan Performans değerlendirme kriterlerine göre alınan sonuçlar Tablo 6.8’da gösterilmiştir. PPG Özellik seçme işlemi için 10 seviyede gerçekleştirilmiştir. Her seviyede en iyi özelliklerin %5 ‘i alınarak model oluşturulmuştur. Seviye 1 için %5, seviye 2 için %10 ve seviyeler 5 artırılarak 10 seviye için seçilen özellik miktarı %50’dir. PPG Özellik seçme işlemi için kNN, SVMs, Ensemble Tree sınıflandırma algoritmaları kullanılarak Hibrid yapay zekâ yöntemiyle sınıflandırma algoritmaları birleştirilerek en iyi sonuçları elde etmeye çalıştık. Alınan sonuçlarda 8. seviye %40 seviyesinde alınan performans değerlendirme kriterlerine göre en iyi sonuçlar elde edilmiştir. Doğruluk oranı 0,98 olarak 1 en yakın değer gösterilmiştir. Tablolarda her seviyede en iyi başarı oranına sahip modelin performans değeri koyu olarak gösterilmiştir.

Tablo 6.8. PPG sinyalleri özellik seçme performans sonuçları

		PPG için Performans Değerlendirme Kriterleri					
	Model	Duyarlılık	Özgüllük	Doğruluk	Kappa	F-Ölçüm	AUC
Seviye %5	k-NN	0,663	0,533	60,04	0,198	0,591	0,598
	SVMs	0,639	0,575	60,80	0,214	0,605	0,607
	ET	0,611	0,608	60,99	0,219	0,609	0,609
	Hibrit	0,626	0,589	60,81	0,215	0,607	0,607
Seviye %10	k-NN	0,853	0,955	90,29	0,806	0,901	0,904
	SVMs	0,854	0,907	88,03	0,760	0,880	0,881
	ET	0,841	0,901	87,01	0,741	0,869	0,870
	Hibrit	0,853	0,928	89,02	0,781	0,889	0,891
Seviye %15	k-NN	0,816	0,964	88,83	0,777	0,884	0,890
	SVMs	0,882	0,938	90,97	0,819	0,909	0,910
	ET	0,880	0,902	89,14	0,782	0,891	0,892
	Hibrit	0,871	0,953	91,11	0,822	0,910	0,912
Seviye %20	k-NN	0,850	0,963	90,57	0,811	0,903	0,907
	SVMs	0,879	0,940	90,95	0,819	0,909	0,910
	ET	0,880	0,917	89,84	0,797	0,898	0,899
	Hibrit	0,879	0,959	91,82	0,837	0,917	0,919
Seviye %25	k-NN	0,927	0,987	95,68	0,913	0,956	0,957
	SVMs	0,950	0,966	95,82	0,916	0,958	0,958
	ET	0,917	0,960	93,80	0,876	0,938	0,939
	Hibrit	0,945	0,986	96,55	0,931	0,965	0,966
Seviye %30	k-NN	0,927	0,986	95,60	0,912	0,956	0,957
	SVMs	0,941	0,968	95,43	0,908	0,954	0,955
	ET	0,932	0,969	95,06	0,901	0,950	0,951
	Hibrit	0,951	0,987	96,90	0,938	0,969	0,969
Seviye %35	k-NN	0,919	0,986	95,13	0,902	0,951	0,952
	SVMs	0,620	0,882	74,81	0,499	0,728	0,751
	ET	0,918	0,963	94,05	0,881	0,940	0,941
	Hibrit	0,901	0,981	94,01	0,880	0,939	0,941

Tablo 6.8. (Devamı) PPG sinyalleri özellik seçme performans sonuçları

Model		PPG için Performans Değerlendirme Kriterleri					
		Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa	F-Ölçümü	AUC
Seviye %40	k-NN	0,911	0,983	94,66	0,893	0,946	0,947
	SVMs	0,974	0,981	97,77	0,955	0,977	0,977
	ET	0,903	0,953	92,81	0,856	0,928	0,929
	Hibrit	0,947	0,987	96,71	0,934	0,967	0,968
Seviye %45	k-NN	0,919	0,983	95,03	0,901	0,950	0,951
	SVMs	0,893	0,944	91,81	0,836	0,918	0,919
	ET	0,907	0,956	93,07	0,861	0,931	0,931
	Hibrit	0,927	0,979	95,25	0,905	0,952	0,953
Seviye %50	k-NN	0,881	0,966	92,28	0,846	0,922	0,923
	SVMs	0,922	0,935	92,87	0,857	0,929	0,929
	ET	0,890	0,942	91,55	0,831	0,915	0,916
	Hibrit	0,922	0,970	94,60	0,892	0,946	0,947

Tezde kullanılan PPG LF özellik seçme algoritmasının performansı, Tablo 6.9'da sunulan performans değerlendirme kriterlerine göre elde edilen sonuçlar ile gösterilmiştir. PPG LF özellik seçme işlemi için 10 seviyede gerçekleştirilmiştir. Her seviye için, kNN, SVMs ve Ensemble Tree sınıflandırma algoritmaları kullanılmıştır. Bu çalışmada, sınıflandırma algoritmalarının en iyi sonuçlarını elde etmek için optimizasyon yöntemleri kullanılmıştır. Algoritmaların performansları performans değerlendirme kriterlerine göre değerlendirilerek, Hibrid yöntemiyle birleştirilmiştir. Bu yöntem, 10 seviyede gerçekleştirilmiş olup, en iyi sonuçlar 7. seviyede %35 oranıyla elde edilmiştir. Doğruluk oranı 0.96 olarak hesaplanmıştır ve 1'e en yakın değer olarak gösterilmiştir.

Tablo 6.9. PPG LF sinyalleri özellik seçme performans sonuçları

	Model	Performans Değerlendirme Kriterleri					
		Duyarlılık	Özgüllük	Doğruluk	Kappa	F-Ölçümü	AUC
Seviye %5	k-NN	0,829	0,291	56,65	0,121	0,431	0,559
	SVMs	0,936	0,184	56,98	0,123	0,308	0,561
	ET	0,948	0,170	56,89	0,121	0,288	0,559
	Hibrit	0,943	0,176	56,94	0,122	0,297	0,560
Seviye %10	k-NN	0,823	0,878	85,03	0,700	0,850	0,851
	SVMs	0,790	0,802	79,61	0,592	0,796	0,796
	ET	0,792	0,793	79,27	0,585	0,793	0,793
	Hibrit	0,815	0,832	82,36	0,647	0,824	0,824
Seviye %15	k-NN	0,925	0,965	94,50	0,890	0,945	0,945
	SVMs	0,822	0,852	83,69	0,674	0,837	0,837
	ET	0,898	0,937	91,76	0,835	0,917	0,918
	Hibrit	0,914	0,959	93,65	0,873	0,936	0,937
Seviye %20	k-NN	0,899	0,951	92,47	0,849	0,924	0,925
	SVMs	0,946	0,959	95,26	0,905	0,953	0,953
	ET	0,892	0,934	91,31	0,826	0,913	0,913
	Hibrit	0,935	0,969	95,19	0,904	0,952	0,952
Seviye %25	k-NN	0,915	0,960	93,73	0,874	0,937	0,938
	SVMs	0,608	0,680	64,34	0,288	0,642	0,644
	ET	0,898	0,941	91,96	0,839	0,919	0,920
	Hibrit	0,890	0,958	92,36	0,847	0,923	0,924
Seviye %30	k-NN	0,895	0,947	92,07	0,841	0,920	0,921
	SVMs	0,953	0,961	95,74	0,914	0,957	0,957
	ET	0,896	0,940	91,80	0,836	0,918	0,918
	Hibrit	0,937	0,967	95,19	0,903	0,952	0,952
Seviye %35	k-NN	0,884	0,947	91,52	0,830	0,915	0,916
	SVMs	0,949	0,959	95,42	0,908	0,954	0,954
	ET	0,895	0,941	91,75	0,835	0,917	0,918
	Hibrit	0,935	0,968	95,17	0,903	0,951	0,952

Tablo 6.9. (Devamı) PPG LF sinyalleri özellik seçme performans sonuçları

		Performans Değerlendirme Kriterleri					
	Model	Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa	F-Ölçümü	AUC
Seviye %40	k-NN	0,864	0,938	90,06	0,801	0,900	0,901
	SVMs	0,412	0,846	62,40	0,255	0,554	0,629
	ET	0,894	0,937	91,51	0,830	0,915	0,915
	Hibrit	0,843	0,954	89,75	0,795	0,895	0,899
Seviye %45	k-NN	0,879	0,942	91,04	0,821	0,910	0,911
	SVMs	0,933	0,950	94,14	0,883	0,941	0,941
	ET	0,893	0,937	91,48	0,829	0,914	0,915
	Hibrit	0,928	0,965	94,61	0,892	0,946	0,946
Seviye %50	k-NN	0,885	0,952	91,80	0,836	0,917	0,918
	SVMs	0,392	0,895	63,77	0,284	0,545	0,643
	ET	0,884	0,932	90,81	0,816	0,908	0,908
	Hibrit	0,848	0,966	90,60	0,812	0,903	0,907

Tezde kullanılan PPG MF özellik seçme algoritmasının performansı, Tablo 6.10'da sunulan performans değerlendirme kriterlerine göre elde edilen sonuçlar ile gösterilmiştir. PPG MF özellik seçme işlemi için 10 seviyede gerçekleştirilmiştir. Her seviye için kNN, SVMs, Ensemble Tree sınıflandırma algoritmaları kullanılmıştır. Bu algoritmalar optimizasyon yöntemi kullanılarak en iyi sonuçlar çıkarılması hedeflenmiştir. Sınıflandırma algoritmaları birleştirilerek, performans değerlendirme kriterlerine göre en iyi sonuçlar Hibrid yöntemiyle elde edilmiştir. Bu 10 seviyeden en iyi sonuçlar 7. seviye %35 seviyesinde en iyi sonuçlar elde edilmiştir. Doğruluk oranı 0,97 olarak 1 en yakın değer gösterilmiştir.

Tablo 6.10. PPG MF sinyalleri özellik seçme performans sonuçları

	Model	Performans Değerlendirme Kriterleri					
		Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa	F-Ölçümü	AUC
Seviye %5	k-NN	0,822	0,304	56,93	0,127	0,444	0,563
	SVMs	0,860	0,264	56,97	0,126	0,404	0,562
	ET	0,938	0,182	56,97	0,123	0,306	0,560
	Hibrit	0,887	0,237	57,05	0,127	0,374	0,562
Seviye %10	k-NN	0,916	0,965	94,04	0,881	0,940	0,941
	SVMs	0,917	0,961	93,92	0,878	0,939	0,939
	ET	0,887	0,931	90,89	0,818	0,909	0,909
	Hibrit	0,921	0,969	94,47	0,889	0,944	0,945
Seviye %15	k-NN	0,916	0,965	94,07	0,881	0,941	0,941
	SVMs	0,918	0,962	94,01	0,880	0,940	0,941
	ET	0,888	0,929	90,85	0,817	0,908	0,909
	Hibrit	0,921	0,969	94,46	0,889	0,944	0,945
Seviye %20	k-NN	0,889	0,944	91,65	0,833	0,916	0,917
	SVMs	0,957	0,975	96,58	0,931	0,966	0,966
	ET	0,901	0,937	91,92	0,838	0,919	0,919
	Hibrit	0,935	0,969	95,17	0,903	0,951	0,952
Seviye %25	k-NN	0,910	0,962	93,56	0,871	0,935	0,936
	SVMs	0,952	0,975	96,38	0,927	0,964	0,964
	ET	0,890	0,932	91,06	0,821	0,910	0,911
	Hibrit	0,934	0,973	95,34	0,906	0,953	0,953
Seviye %30	k-NN	0,911	0,964	93,67	0,873	0,936	0,937
	SVMs	0,957	0,961	95,91	0,918	0,959	0,959
	ET	0,896	0,936	91,60	0,832	0,916	0,916
	Hibrit	0,942	0,974	95,82	0,916	0,958	0,959
Seviye %35	k-NN	0,889	0,946	91,72	0,834	0,917	0,918
	SVMs	0,956	0,963	95,98	0,919	0,960	0,960
	ET	0,912	0,947	92,97	0,859	0,929	0,930
	Hibrit	0,949	0,973	96,12	0,922	0,961	0,962

Tablo 6.10. (Devamı) PPG MF sinyalleri özellik seçme performans sonuçları

		Performans Değerlendirme Kriterleri					
	Model	Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa	F-Ölçümü	AUC
Seviye %40	k-NN	0,863	0,926	89,37	0,787	0,893	0,894
	SVMs	0,942	0,952	94,73	0,894	0,947	0,947
	ET	0,911	0,946	92,85	0,857	0,928	0,929
	Hibrit	0,937	0,962	94,96	0,899	0,949	0,949
Seviye %45	k-NN	0,880	0,939	90,94	0,819	0,909	0,910
	SVMs	0,937	0,950	94,38	0,887	0,943	0,944
	ET	0,912	0,946	92,86	0,857	0,928	0,929
	Hibrit	0,943	0,970	95,68	0,913	0,957	0,957
Seviye %50	k-NN	0,881	0,939	90,96	0,819	0,909	0,910
	SVMs	0,939	0,950	94,48	0,889	0,945	0,945
	ET	0,868	0,925	89,62	0,792	0,896	0,896
	Hibrit	0,922	0,963	94,24	0,884	0,942	0,943

Tezde kullanılan PPG HF özellik seçme algoritmasının performansı, Tablo 6.11'de sunulan performans değerlendirme kriterlerine göre elde edilen sonuçlar ile gösterilmiştir. PPG HF özellik seçme işlemi için 10 seviyede gerçekleştirilmiştir. Her seviye için kNN, SVMs, Ensemble Tree sınıflandırma algoritmaları kullanılmıştır. Bu algoritmalar optimizasyon yöntemi kullanılarak en iyi sonuçlar çıkarılması hedeflenmiştir. Sınıflandırma algoritmaları birleştirilerek Hibrid yöntemiyle en iyi sonuçları performans değerlendirme kriterlerine göre sonuçlanmıştır. Bu 10 seviyeden en iyi sonuçlar 8. seviye %40 seviyesinde en iyi sonuçlar elde edilmiştir. Doğruluk oranı 0,98 olarak 1 en yakın değer gösterilmiştir.

Tablo 6.11. PPG HF sinyalleri özellik seçme performans sonuçları

	Model	Performans Değerlendirme Kriterleri					
		Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa	F-Ölçümü	AUC
Seviye %5	k-NN	0,643	0,584	61,47	0,228	0,612	0,614
	SVMs	0,647	0,577	61,36	0,225	0,610	0,612
	ET	0,665	0,561	61,46	0,227	0,608	0,613
	Hibrit	0,658	0,568	61,48	0,229	0,610	0,614
Seviye %10	k-NN	0,819	0,952	88,41	0,768	0,880	0,885
	SVMs	0,447	0,923	67,94	0,366	0,602	0,685
	ET	0,823	0,868	84,51	0,690	0,845	0,845
	Hibrit	0,785	0,954	86,75	0,736	0,861	0,869
Seviye %15	k-NN	0,893	0,968	93,02	0,860	0,929	0,931
	SVMs	0,848	0,930	88,84	0,777	0,887	0,889
	ET	0,856	0,888	87,24	0,744	0,872	0,872
	Hibrit	0,874	0,948	91,03	0,821	0,909	0,911
Seviye %20	k-NN	0,840	0,957	89,76	0,795	0,895	0,899
	SVMs	0,847	0,930	88,82	0,776	0,887	0,889
	ET	0,857	0,892	87,43	0,748	0,874	0,875
	Hibrit	0,854	0,945	89,85	0,797	0,897	0,899
Seviye %25	k-NN	0,842	0,846	84,47	0,689	0,844	0,844
	SVMs	0,881	0,937	90,89	0,818	0,908	0,909
	ET	0,868	0,898	88,30	0,766	0,883	0,883
	Hibrit	0,887	0,918	90,24	0,805	0,903	0,903
Seviye %30	k-NN	0,880	0,966	92,25	0,845	0,921	0,923
	SVMs	0,940	0,965	95,24	0,904	0,952	0,952
	ET	0,887	0,941	91,36	0,827	0,913	0,914
	Hibrit	0,921	0,973	94,65	0,893	0,946	0,947
Seviye %35	k-NN	0,911	0,978	94,42	0,888	0,943	0,945
	SVMs	0,564	0,886	72,17	0,447	0,690	0,725
	ET	0,902	0,945	92,34	0,846	0,923	0,924
	Hibrit	0,874	0,977	92,49	0,850	0,923	0,926

Tablo 6.11. (Devamı) PPG HF sinyalleri özellik seçme performans sonuçları

		Performans Değerlendirme Kriterleri					
	Model	Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa	F-Ölçümü	AUC
Seviye 8 %40	k-NN	0,906	0,975	94,00	0,880	0,939	0,940
	SVMs	0,959	0,975	96,69	0,933	0,967	0,967
	ET	0,898	0,940	91,85	0,837	0,918	0,919
	Hibrit	0,942	0,980	96,08	0,922	0,961	0,961
Seviye 9 %45	k-NN	0,891	0,893	89,25	0,785	0,892	0,892
	SVMs	0,867	0,922	89,40	0,788	0,893	0,894
	ET	0,889	0,941	91,48	0,829	0,914	0,915
	Hibrit	0,913	0,955	93,35	0,867	0,933	0,934
Seviye 10 %50	k-NN	0,883	0,963	92,25	0,845	0,921	0,923
	SVMs	0,863	0,915	88,84	0,777	0,888	0,889
	ET	0,884	0,940	91,17	0,823	0,911	0,912
	Hibrit	0,901	0,962	93,08	0,862	0,931	0,932


Tezde kullanılan PPG All özellik seçme algoritmasının performansı, Tablo 6.12'de sunulan performans değerlendirme kriterlerine göre elde edilen sonuçlar ile gösterilmiştir. PPG All özellik seçme işlemi için 10 seviyede gerçekleştirilmiştir. Her seviye için kNN, SVMs, Ensemble Tree sınıflandırma algoritmaları kullanılmıştır. Bu algoritmalar optimizasyon yöntemi kullanılarak en iyi sonuçlar çıkarılması hedeflenmiştir. Sınıflandırma algoritmaları birleştirilerek Hibrid yöntemiyle en iyi sonuçları performans değerlendirme kriterlerine göre sonuçlanmıştır. Bu 10 seviyeden en iyi sonuçlar 3.ci seviye %15 seviyesinde en iyi sonuçlar elde edilmiştir. Doğruluk oranı 0,98 olarak 1 en yakın değer gösterilmiştir.

Tablo 6.12. PPG ALL sinyalleri özellik seçme performans sonuçları


Model		Performans Değerlendirme Kriterleri					
		Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa	F-Ölçümü	AUC
Seviye %5	1	k-NN	0,865	0,965	91,39	0,828	0,915
		SVMs	0,868	0,922	89,45	0,789	0,895
		ET	0,860	0,888	87,40	0,748	0,874
		Hibrit	0,874	0,941	90,66	0,813	0,907
Seviye %10	2	k-NN	0,902	0,977	93,93	0,879	0,940
		SVMs	0,932	0,963	97,72	0,894	0,947
		ET	0,887	0,915	90,12	0,802	0,901
		Hibrit	0,925	0,973	94,87	0,897	0,949
Seviye %15	3	k-NN	0,912	0,978	94,42	0,888	0,945
		SVMs	0,963	0,977	96,99	0,939	0,970
		ET	0,893	0,940	91,61	0,832	0,916
		Hibrit	0,944	0,982	96,24	0,924	0,962
Seviye %20	4	k-NN	0,916	0,964	93,98	0,879	0,940
		SVMs	0,958	0,968	96,31	0,926	0,963
		ET	0,893	0,943	91,77	0,835	0,918
		Hibrit	0,945	0,977	96,15	0,923	0,961
Seviye %25	5	kNN	0,862	0,958	90,96	0,819	0,911
		SVMs	0,912	0,953	93,24	0,864	0,933
		ET	0,889	0,943	91,58	0,832	0,915
		Hibrit	0,910	0,971	94,04	0,881	0,941
Seviye %30	6	k-NN	0,850	0,952	90,03	0,801	0,902
		SVMs	0,922	0,942	93,18	0,864	0,932
		ET	0,889	0,943	91,56	0,831	0,916
		Hibrit	0,908	0,963	93,55	0,871	0,935
Seviye %35	7	k-NN	0,832	0,945	88,72	0,775	0,888
		SVMs	0,903	0,943	92,32	0,846	0,924
		ET	0,890	0,944	91,66	0,833	0,917
		Hibrit	0,900	0,965	93,18	0,863	0,931

Tablo 6.12. (Devamı) PPG ALL sinyalleri özellik seçme performans sonuçları


Model		Performans Değerlendirme Kriterleri					
		Duyarlılık	Özgüllük	Doğruluk Oranı	Kappa	F-Ölçümü	AUC
Seviye %40	k-NN	0,817	0,933	87,38	0,748	0,871	0,875
	SVMs	0,905	0,945	92,50	0,850	0,925	0,925
	ET	0,895	0,944	91,90	0,838	0,919	0,919
	Hibrit	0,901	0,963	93,16	0,863	0,931	0,932
Seviye %45	k-NN	0,818	0,939	87,78	0,756	0,875	0,879
	SVMs	0,917	0,948	93,25	0,865	0,932	0,932
	ET	0,885	0,916	90,04	0,801	0,901	901
	Hibrit	0,907	0,959	93,27	0,865	0,932	0,933
Seviye %50	k-NN	0,826	0,937	88,07	0,762	0,878	0,882
	SVMs	0,914	0,948	93,12	0,862	0,931	0,931
	ET	0,882	0,915	89,84	0,797	0,898	0,898
	Hibrit	0,907	0,958	93,20	0,864	0,932	0,932




Şekil 6.1. PPG sinyalleri özellik seçme sonuçları




Şekil 6.2. PPG LF sinyalleri özellik seçme sonuçları



Şekil 6.3. PPG MF sinyalleri özellik seçme sonuçları



Şekil 6.4. PPG HF sinyalleri özellik seçme sonuçları



Şekil 6.5. PPG ALL sinyalleri özellik seçme sonuçları

7. TARTIŞMA VE SONUÇ

7.1. Kronik Obstrüktif Akciğer Hastalığı Minimum Süre Tespiti Modeline Dayalı Tartışmalar

Çalışmanın sonuçlarına göre, PPG sinyali ve biyomedikal sinyal işleme tekniklerinin kullanımıyla makine öğrenmesi tabanlı KOAH teşhisi yapmanın mümkün olduğu ispatlanmıştır. Bununla birlikte, ne kadar sürelik bir PPG kaydına ihtiyaç duyulduğu tespit edilmiştir. Sadece 2 saniyelik bir kayıt ile %95,31 doğruluk oranı elde edilmiştir. Bu sonuçlar KOAH teşhisinin pratik teşhis yöntemlerinin olduğunun bir göstergesidir. KOAH teşhisi genellikle spirometre cihazları yardımıyla konur. Ancak bu cihazların kullanım zorluğu sebebiyle farklı alternatiflere ihtiyaç duyulmaktadır. Cihazların piyasa değeri ortalama 2.000 dolar civarındadır. Önerilen model teknolojik altyapı, hızlı teşhis, güvenilirlik, yüksek doğruluk oranı ve maliyetinin az olması sebebiyle birçok avantaja sahiptir. Önerilen model basit oksijen saturasyon cihazlarına basit bir yazılımla eklenebilir. Sadece bu ekonomik boyutu ile bile büyük bir yenilik sağlamaktadır.

Sonuç olarak, çalışmanın önemli yerlerini vurgulayarak özetlemek gerekirse, (1) kullanımı kolay, (2) yapay zekâ tabanlı, (3) ekonomik maliyeti yok denecek kadar az (4) güvenilir biyomedikal sinyal ölçüm verilerine göre karar veren bir sistem geliştirilmiştir. Bu çalışmanın KOAH teşhisi için yeni ufuklar açacağını ümit ediyoruz.

7.2. Fotopletismografi Alt Frekans Bantları Ayrımına Dayalı KOAH Tahmin Tartışmaları

Her geçen gün hızla kirlenen atmosfer, artan çevre kirliliği, zorlu şehir hayatı ve tütün ürünlerinin kullanımı nedenleriyle; göğüs hastalıkları günümüzün en büyük sağlık problemlerinden biridir [3, 12, 19]. Göğüs hastalıklarından En hızlı artan, ancak en az bilineni KOAH olduğu görülmüştür. KOAH, sigara dumanı, zehirli gazlar ve partikül maddelerin neden olduğu hava yollarının mikrobiyal olmayan enflamasyonundan kaynaklanan ilerleyici bir hastalıktır. Bu enflamasyon, hava yolları kademeli olarak daralırken, akciğer dokusunun hava keselerinin (alveoller) geri dönüşü olmayan bir

şekilde genişlemesine ve tahrip olmasına neden olur. Kronik obstrüktif akciğer hastalığındaki değişiklikler tanı geciktiği takdirde geri dönüşümsüz ve ilerleyicidir, bu nedenle bu hastalığın saptanması ve erken saptanması büyük önem taşımaktadır [96]. KOAH dünyada üçüncü ölüm nedeni olmakla birlikte yılda üç milyon kişinin hayatını kaybetmesine sebep olmaktadır. Toplumda sigara kullanımının yaygınlaşmasıyla birlikte KOAH görülme sıklığı ve bu hastalıktan kaynaklanan kayıplar her geçen gün artmaktadır. Bu nedenle bu hastalığın erken teşhisi ve tedavisi çok önemlidir [96].

Erken teşhisin bu kadar önemli olduğu bir hastalıkta, erken tanıya yönelik çalışmaların yapılması kaçınılmaz olmuştur. Literatüre bakıldığında KOAH teşhisi üzerine yapılan çalışmaların genellikle steteskop, hastalara ait demografik bilgiler ve spirometre ile birlikte yapıldığı görülmektedir [87–89]. Literatürde KOAH teşhisi için kullanılan biyolojik sinyaller spirometre, steteskop, kayıtları ile sınırlı kalmıştır [87-89]. Örneğin spirometre aracı ile KOAH hastalığının teşhisinin konulması için gereken zaman süreci uzun ve maliyetli olduğu görülmektedir. Bunun yanı sıra hastalar uzun bir tanı koyma sürecine dahil olurken birçok psikolojik ve fizyolojik sıkıntılara maruz kalmışlardır. Hastalarda anksiyete seviyesinin arttığı ve hastalarda depresyona yol açtığı belirtilmiştir [24, 25]. Spirometre ile KOAH hastalığının teşhisini koyma süreci zahmetli ve çok fazla zaman aldığı için, bir gün içinde sürece dahil edilebilecek hasta sayısı çok azdır. Bu da hastaların tanı konma sürecinin uzamasına ve hastanın yaşam kalitesinin azalmasına sebep olmaktadır. Ayrıca geri dönüşümü olmayan bir hastalık olması sebebiyle tedavinin gecikmesi hastalarda kalıcı etkilere sebep olmaktadır.

Yapılan literatür taramalarında genellikle sınıflandırma işlemleri sırasında Yapay Sinir Ağları, MLFFNN, DT, kNN, PNN, SVMs gibi çeşitli çoklu veya tekil sınıflandırıcıların tercih edildiği gözlemlenmiştir [8, 23, 90]. Ensemble Tree sınıflandırma algoritması kullanımı çok azdır. Bu çalışmada ise diğer çalışmalardan farklı olarak tekil sınıflandırıcıların güçlerini artırabilmesi için Ensemble tree sınıflandırma algoritması kullanılmış ve performansın büyük oranda arttığı tespit edilmiştir.

Yapılan literatür taraması sonucunda, KOAH hastalarının teşhis sürecinde hızlı ve güvenilir bir yöntem olarak ECG sinyallerinin kullanılabileceği düşünülmektedir [9].

Yapılan diğerk bir alıřmada KOAH teřhisi iin Ampirik Dalgacık Dnüşümü (ADD) yöntemi ile AdaBoost, Bayes, ok Katmanlı Algılayıcılar, Destek Vektör Makineleri, En Yakın k Komřu, Random Subspace, Naïve BayesNet, Rastgele Orman ve J48 algoritması olmak üzere toplamda 9 farklı sınıflandırma algoritması kullanılarak KOAH teřhisinin yapılması iin alıřmalar yapılmıřtır. Sonular, 5 saniye gibi kısa bir sürede en iyi performans deęerlerinin bu algoritmaların kullanımıyla elde edildięini göstermektedir [100]. Bu alıřmada, KOAH teřhisi iin Destek Vektör Makinesi, AdaBoost, Rastgele Orman ve J48 Karar Ağacı gibi sınıflandırma algoritmalarının performansları deęerlendirilmiřtir. Bu algoritmaların sırasıyla %90,41, %95,28, %90,56 ve %85,78 oranlarında doęruluk oranları elde edilmiřtir. Bu alıřmanın önemi, daha yüksek doęruluk oranlarına sahip olması ve teřhis süresini 5 saniyeye indirmesi olarak belirtilmektedir [101]. Bu alıřmada ise süre 2 saniyeye kadar indirilmiřtir. Bu bakımdan alıřmamız süre bakımından öndedir. Ayrıca önerilen modellerin performansı %96,96 gibi literatürden daha iyi bir performansa sahiptir. Bunun nedeni önerilen modellerde güvenilir bir sinyal biyomedikal sinyallerin kullanımının tercih edilmesi olabilir. Ayrıca sinyal işleme süreçlerinde alt frekans bantlarının tespit edilmesi model performanslarını doğrudan etkileyen diğerk bir faktördür.

Bir alıřmada PPG sinyalinin KOAH teřhisi iin kullanılabileceęi sonucuna varılmıřtır. PPG sinyali kullanılarak KOAH teřhisi gerek zamanlı ve 15 saniyelik bir sürede yapılabilir. Bu yöntemin hızlı ve etkili olduęu düşünölmektedir [102]. Yapılan diğerk bir bir alıřmada ise PPG sinyalini kullanarak KOAH hastalıęının teřhisinin 2 saniye gibi kısa bir süre ierisinde hastalıęının teřhisinin mümkün olabileceęi düşünölmektedir [3].

Bugüne kadar yapılan tüm bu alıřmalar, farklı özellikler aısından birbirinden üstünlük ve zayıflıklar iermektedir. Bu alıřmada, KOAH hastalıęının erken teřhisini hedeflemektedir. Böylece hastanın tedavi süreci hızlıca başlatılarak psikolojik ve fizyolojik zorluklar en aza indirilecektir.

7.3. Kararlar

alıřma sonularına göre, PPG sinyali ve biyomedikal sinyal işleme teknikleri kullanılarak makine öęrenmesi tabanlı KOAH teřhisi yapılabileceęi sonucuna

varılmıştır. Bununla birlikte, ne kadar sürelik bir PPG kaydına ihtiyaç duyulduğu tespit edilmiştir. Sadece 2 saniyelik bir kayıt ile PPG ve 3 alt frekans sinyalleri kullanılarak, üç farklı sınıflandırma algoritması kullanılarak bu modellerin birleşimiyle hibrit yapay zeka yöntemi kullanılarak %95,31 doğruluk oranı elde edilmiştir. Bu sonuçlar KOAH teşhisinin pratik teşhis yöntemlerinin olduğunun bir göstergesidir. KOAH teşhisi genellikle spirometre cihazları yardımıyla konur. Ancak bu cihazların kullanım zorluğu sebebiyle farklı alternative ihtiyaç duyulmaktadır. Cihazların piyasa değeri ortalama 2.000 dolar civarındadır. Önerilen model teknolojik altyapı, hızlı teşhis, güvenilirlik, yüksek doğruluk oranı ve maliyetinin az olması sebebiyle birçok avantaja sahiptir. Önerilen model basit oksijen satürasyon cihazlarına basit bir yazılımla eklenebilir. Sadece bu ekonomik boyutu ile bile büyük bir yenilik sağlamaktadır. Sonuç olarak, çalışmanın önemli yerlerini vurgulayarak özetlemek gerekirse, (1) kullanımı kolay, (2) yapay zekâ tabanlı, (3) ekonomik maliyeti yok denecek kadar az (4) güvenilir biyomedikal sinyal ölçüm verilerine göre karar veren bir sistemdir. Bu çalışmanın KOAH teşhisi için yeni ufuklar açacağını ümit ediyoruz.

7.4. Bilgilendirme

Yaptığımız bu çalışmada kullanılan veriler Sakarya Hendek Devlet Hastanesi Uyku Laboratuvarından alınmıştır. Bu çalışmanın yapılması için T.C. Sağlık Bakanlığı Türkiye Kamu Hastaneleri Kurumu Sakarya İli Kamu Hastaneleri Birliği Genel Sekreterliğinden 94556916/904/151.5815 numaralı veri kullanım ve Sakarya Üniversitesi Tıp Fakültesi'nin 1614662/050.01.04/70 numaralı Etik Kurul raporuna göre izinler alınmıştır.

KAYNAKLAR

- [1] Batur, M., Batur, H., Can, H., Kısabay, A., Göktalay, T. ve Yılmaz, H. (2015). Evaluation of the Severity of Sleep Complaints According to the Stages of Chronic Obstructive Pulmonary Disease. *Journal of Turkish Sleep Medicine*, vol. 3, doi: 10.4274/jtsm.75.
- [2] Zubaydi, F., Sagahyroon, A., Aloul, F. ve Mir, H. (2017). MobSpiro: Mobile based spirometry for detecting COPD. *IEEE 7th Annual Computing and Communication Workshop and Conference, CCWC 2017*, 2017. doi: 10.1109/CCWC.2017.7868345.
- [3] Melekoğlu, E., Kocabıçak, Ü., Uçar, M. K., Bozkurt, M. R. ve Bilgin, C. (2021). Machine Learning for the Diagnosis of Chronic Obstructive Pulmonary Disease and Photoplethysmography Signal – Based Minimum Diagnosis Time Detection. in *Lecture Notes on Data Engineering and Communications Technologies*, vol. 76, doi: 10.1007/978-3-030-79357-9_6
- [4] American Thoracic Society Patient Education | Information Series, (2019). Chronic Obstructive Pulmonary Disease (COPD). Accessed: Dec. 15, 2022. Erişim adresi <https://perf2ndwind.org>
- [5] Lopez, A.D. et al. (2006). Chronic obstructive pulmonary disease: Current burden and future projections. *European Respiratory Journal*, vol. 27, no. 2, pp. 397–412, doi: 10.1183/09031936.06.00025805.
- [6] Arslan, C. ve Ünsar, S. (2021). Kronik Obstrüktif Akciğer Hastalarında Dispne Algısı ve Yaşam Kalitesinin Değerlendirilmesi. *Journal of Anatolia Nursing and Health Sciences*, doi: 10.17049/ataunihem.732692.
- [7] Pauwels, P. R. A. ve Rabe, K. F. (Aug. 2004). Burden and clinical features of chronic obstructive pulmonary disease (COPD). *The Lancet*, 364, no. 9434, pp. 613–620, doi: 10.1016/S0140-6736(04)16855-4.
- [8] Işık, Ü., Güven, A. ve Büyükoğlu, H. (2015). Yapay Sinir Ağları ile Kronik Obstrüktif Akciğer Hastalığının Sınıflandırılması. *IEEE*.
- [9] Uçar, M. K., Moran, İ., Altılar, D. T., Bilgin, C. ve Bozkurt, M. R. (2018). Statistical Analysis of The Relationship Between Chronic Obstructive Pulmonary Disease and Electrocardiogram Signal. *Journal of Human Rhythm*, vol. 4, no. 3, pp. 142–149, Erişim adresi <http://dergipark.gov.tr/johr/issue/39449/465504>

- [10] Bhatt, S. P. Et al., (Jun. 2019). Discriminative Accuracy of FEV1:FVC Thresholds for COPD-Related Hospitalization and Mortality. *JAMA*, vol. 321, no. 24, p. 2438, doi: 10.1001/JAMA.2019.7233.
- [11] Er, O. ve Temurtas, F. (Oct. 2008). A study on chronic obstructive pulmonary disease diagnosis using multilayer neural networks. *J Med Syst*, vol. 32, no. 5, pp. 429–32, doi: 10.1007/s10916-008-9148-6.
- [12] Er, O., Sertkaya, C., Temurtas, F. ve Tanrikulu, A. C. (Dec. 2009). A comparative study on chronic obstructive pulmonary and pneumonia diseases diagnosis using neural networks and artificial immune system. *J Med Syst*, vol. 33, no. 6, pp. 485–92, doi: 10.1007/s10916-008-9209-x.
- [13] Uçar, M. K., Moran, I., Altılar, D. T., Bilgin, C. ve Bozkurt M.R. (2018). Rule-based diagnosis of chronic obstructive pulmonary disease with electrocardiogram signal. *Electric Electronics, Computer Science, Biomedical Engineerings Meeting, EBBT 2018*, doi: 10.1109/EBBT.2018.8391462.
- [14] Er, O., Yumusak, N. ve Temurtas, F. (Feb. 2012). Diagnosis of chest diseases using artificial immune system. *Expert Syst Appl*, vol. 39, no. 2, pp. 1862–1868, doi: 10.1016/J.ESWA.2011.08.064.
- [15] Er, O., Yumusak, N. ve Temurtas, Tanrikulu, A. C. ve Abakay, A. (Aug. 2009). Chronic Obstructive Pulmonary Disease Diagnosis Using Radial Based Function Neural Network. *Electronic Letters on Science and Engineering*, vol. 5, no. 2, pp. 1–8, Accessed: Jan. 25, 2023. Erişim adresi <https://dergipark.org.tr/en/pub/else/issue/29318/313751>
- [16] Kocabaş, A. et al., (2014). Official Journal Of The Turkish Thoracic Society Kronik Obstrüktif Akciğer Hastalığı (Koah) Koruma, Tanı Ve Tedavi Raporu 2014 Türk Toraks Derneği Koah Çalışma Grubu. Accessed: Jan. 25, 2023. Erişim adresi <https://www.toraks.dergisi.org>
- [17] Goryński, K. et al., (Jul. 2014). Artificial neural networks approach to early lung cancer detection. *Cent Eur J Med*, vol. 9, no. 5, pp. 632–641, doi: 10.2478/S11536-013-0327-6/METRICS.
- [18] Er, O., Yumusak, N. ve Temurtas, F. (Dec. 2010). Chest diseases diagnosis using artificial neural networks, *Expert Syst Appl*, vol. 37, no. 12, pp. 7648–7655, doi: 10.1016/J.ESWA.2010.04.078.
- [19] Er, O., Yumusak, N. ve Temurtas, F. (2012). Diagnosis of chest diseases using artificial immune system. in *Expert Systems with Applications*, vol. 39, no. 2. doi: 10.1016/j.eswa.2011.08.064.
- [20] Bhuvaneswari, C., Aruna, P. ve Loganathan, D. (Jul. 2014). A new fusion model for classification of the lung diseases using genetic algorithm. *Egyptian Informatics Journal*, vol. 15, no. 2, pp. 69–77, doi: 10.1016/J.EIJ.2014.05.001.
- [21] Gökmen, B. D. ve Fırat, M. (2022). KOAH hastalarında hastalık algısı, ölüm kaygısı ve öz bakım gücü ilişkisinin incelenmesi. *Adıyaman Üniversitesi Sağlık Bilimleri Dergisi*, pp. 57–66, 2022.

- [22] Akbolat, A. (2022). Kronik Hastalarda İyi Oluş ve Maneviyat: Nitel Bir Araştırma. Accessed: Nov. 13, 2022. Erişim adresi <https://acikerisim.erbakan.edu.tr/xmlui/bitstream/handle/20.500.12452/8223/ABDURRAHMAN%20AKBOLAT.pdf>
- [23] Örenç, S. (2019). Kronik Obstrüktif Akciğer Hastalığı teşhisi için Makine Öğrenmesi Temelli Yeni Bir Yöntem Geliştirilmesi.
- [24] Anar, C., Tatar, D., Gediktaş, E., Yildirim, Y. ve Hallçolar, H. (2012). Uzun Süreli Oksijen Tedavisi Uygulanan KOAH'lı Olgularda Anksiyete Depresyon Sıklığı.
- [25] Akkuş, Y., Yılmaz Karabulutlu, E. ve Yağcı, S. (2016). Kronik Obstrüktif Akciğer Hastalarda Anksiyete ve Depresyonun Bilişsel Duruma Etkisi.
- [26] Satman, İ., Erkan, F., Doğan Merih, Y., Ertürk, N. ve Yemenici, M. (2021). Türkiye’de Kronik Obstrüktif Akciğer Hastalığının Yönetimi: Korunma, Tanı ve Tedavi Standartları Kılavuzu. Accessed: Nov. 17, 2022. Erişim adresi www.tuseb.gov.tr
- [27] Solé Morillo, Á., Lambert Cause, J., Baciú, V. E., da Silva, B. Garcia-Naranjo, J. C. ve Stiens, J. (Feb. 2022). PPG EduKit: An Adjustable Photoplethysmography Evaluation System for Educational Activities. *Sensors*, vol. 22, no. 4, doi: 10.3390/s22041389.
- [28] Park, J., Seok, H. S., Kim, S. S. ve Shin, H. (Mar. 01, 2022). Photoplethysmogram Analysis and Applications: An Integrative Review. *Frontiers in Physiology*, vol. 12. Frontiers Media S.A., doi: 10.3389/fphys.2021.808451.
- [29] Alnaeb, M., Alobaid, N., Seifalian, A., Mikhailidis, D. ve Hamilton, G. (Dec. 2007). Optical techniques in the assessment of peripheral arterial disease. *Curr Vasc Pharmacol*, vol. 5, no. 1, pp. 53–59, doi: 10.2174/157016107779317242.
- [30] Uçar, M. K. (2017). Developing a new Method For Obstructive Sleep Apnea Diagnosis Based On Machinelearning.
- [31] Spachos, P., Gao, J. ve Hatzinakos, D. (2011). Feasibility study of photoplethysmographic signals for biometric identification. *17th DSP 2011 International Conference on Digital Signal Processing*, doi: 10.1109/ICDSP.2011.6004938.
- [32] Yıldırım, Ö. (2017). Kalp Aritmisinin Çift Dalgaboylu PPG Sinyalleri Kullanılarak Belirlenmesi.
- [33] Aydemir, B. (Jun. 2019). Egzersiz esnasında toplanan fotoplethysmografi sinyallerinden kalp atım hızı ve ventilasyon hızı değişkenlerinin ayrıştırılması. Accessed: Nov. 17, 2022. Erişim adresi <https://acikbilim.yok.gov.tr/handle/20.500.12812/282457>
- [34] Kavsaoglu, A. R., Polat, K. ve Bozkurt, M. R. (2014). Temassız elde edilen fotoplethysmografi sinyalleri ile gerçek zamanlı kalp hızı tespiti. *2014 22nd Signal Processing and Communications Applications Conference, SIU 2014 - Proceedings*, pp. 196–199, doi: 10.1109/SIU.2014.6830199.

- [35] Kavsaoglu, A.R. (2014). PPG (fotopletismografi) sinyalleri ile biyometrik tanımlama sistemi. Sakarya Üniversitesi, Sakarya, Ref T06214 2014 k.1.
- [36] Merkepçi, M. (2017). University Of Gaziantep Graduate School Of Natural And Applied Sciences Remote Monitored Non-Invasive Photoplethysmography.
- [37] Merkepçi, M., Sadettin Ozyazici, M. ve Dogru, N. (2022). Photoplethysmography based instant remote monitoring of non-invasive blood pressure and oxygen saturation by using zigbee network. Accessed: Dec. 03, 2022, Erişim adresi www.biomedres.info
- [38] Savaskan, D. A., Mahanoglu, A., Soner, B. ve Kholmatov, A. (2020). Heart Rate Measurement from Motion Compensated Photoplethysmographic Signals. *2020 28th Signal Processing and Communications Applications Conference, SIU 2020 - Proceedings*, doi: 10.1109/SIU49456.2020.9302041.
- [39] Bal, U. ve Bal, A. (2015). Temassız Fotopletismografi ile Nabız Kestiriminde Hemoglobin Seviyesinin Etkisi. Cilt 17, Sayı 50, 47-53. Erişim adresi <https://dergipark.org.tr/tr/pub/deumffmd/issue/40786/492035>
- [40] Senturk, U., Polat, K. ve Yucedag, I. (Dec. 2020). A non-invasive continuous cuffless blood pressure estimation using dynamic Recurrent Neural Networks. *Applied Acoustics*, vol. 170, p. 107534, doi: 10.1016/J.APACOUST.2020.107534.
- [41] Uçar. M. K. (2021). Fotopletismografi Sinyali Kullanan Akıllı Bileklikler İçin Kural Tabanlı Kan Basıncının Kestirimi İçin Yeni Bir Yöntem. *1. Uluslararası Yapay Zeka ve Veri Bilimi Kongresi* pp. 25–31, Nov. 2021.
- [42] Pilt, K., Ferenets, R., Meigas, K., Lindberg, L. G., Temitski, K. ve Viigimaa, M. (2013). New photoplethysmographic signal analysis algorithm for arterial stiffness estimation. *The Scientific World Journal*, vol. 2013, doi: 10.1155/2013/169035.
- [43] Elfatimi, E. (2018). Yapay Sinir Ağları ve Bulanık Mantık Denklik İlişkilerini Kullanarak Kalp Hızı değişkenliği Analizi. Erişim adresi <http://acikerisim.pau.edu.tr/handle/11499/3158>
- [44] Van Gastel, M., Stuijk, S. ve De Haan, G. (2016). New principle for measuring arterial blood oxygenation, enabling motion-robust remote monitoring. *Scientific Reports* 2016 6:1, vol. 6, no. 1, pp. 1–16, doi: 10.1038/srep38609.
- [45] Castaneda, D., Esparza, A., Ghamari, M., Soltanpur C. ve Nazeran, H. (2018). A review on wearable photoplethysmography sensors and their potential future applications in health care. *Int J Biosens Bioelectron*, vol. 4, no. 4, doi: 10.15406/IJBSBE.2018.04.00125.
- [46] Allen, J. (Mar. 2007). Photoplethysmography and its application in clinical physiological measurement. *Physiol Meas*, vol. 28, no. 3, doi: 10.1088/0967-3334/28/3/R01.

- [47] Macwan, R., Benezeth, Y. ve Mansouri, A. (Feb. 2018). Remote photoplethysmography with constrained ICA using periodicity and chrominance constraints. *Biomed Eng Online*, vol. 17, no. 1, pp. 1–22, doi: 10.1186/S12938-018-0450-3/FIGURES/8.
- [48] Verkruysse, W., Svaasand, L. O. ve Nelson, J. S. (Dec. 2008). Remote plethysmographic imaging using ambient light. *Opt Express*, vol. 16, no. 26, p. 21434, doi: 10.1364/OE.16.021434.
- [49] Kumar, M., Veeraraghavan, A. ve Sabharwal, A. (May 2015). DistancePPG: Robust non-contact vital signs monitoring using a camera. *Biomed Opt Express*, vol. 6, no. 5, p. 1565, doi: 10.1364/BOE.6.001565.
- [50] Şahan, S., Polat, K., Kodaz, H. ve Güneş, S. (Mar. 2007). A new hybrid method based on fuzzy-artificial immune system and k-nn algorithm for breast cancer diagnosis. *Comput Biol Med*, vol. 37, no. 3, pp. 415–423, doi: 10.1016/J.COMPBIOMED.2006.05.003.
- [51] Uçar, M. K., Bozkurt, M. R., Bilgin, C. ve Polat, K. (Apr. 2018). Automatic sleep staging in obstructive sleep apnea patients using photoplethysmography, heart rate variability signal and machine learning techniques. *Neural Comput Appl*, vol. 29, no. 8, pp. 1–16, doi: 10.1007/s00521-016-2365-x.
- [52] UCI.(2022). UCI Health tests novel stem cell therapy for advanced Parkinson’s disease | UCI Health | Orange County. Erişim adresi <https://www.ucihealth.org/news/2022/03/uci-clinical-trial-tests-stem-cell-therapy-for-advanced-parkinsons>
- [53] Uçar, M. K., Uçar, Z., Uçar, K., Akman, M. ve Bozkurt, M. R. (2021). Determination of body fat percentage by electrocardiography signal with gender based artificial intelligence. *Biomed Signal Process Control*, vol. 68, doi: 10.1016/j.bspc.2021.102650.
- [54] Wallisch, P., Lusignan, M., Benayoun, M., Baker, T., Dickey, A. ve Hatsopoulos, N. (2009). MATLAB for Neuroscientists. doi: 10.1016/B978-0-12-374551-4.X0001-2.
- [55] Akar, E., Kara, S., Akdemir, H. ve Kırış A. (2015). Görüntü Filtreleme Metotlarının Kolay Uygulanması ve Karşılaştırılmasına Yönelik MATLAB Ara Yüz Programı. IEEE, pp. 15–18.
- [56] Uçar, M. K., Nour, M., Sindi, H. ve Polat, K. (2020). The Effect of Training and Testing Process on Machine Learning in Biomedical Datasets. *Math Probl Eng*, vol. 2020, doi: 10.1155/2020/2836236.
- [57] Kohavi, R. ve John, G. H. (1997). Wrappers for feature subset selection. *Artif Intell*, vol. 97, no. 1–2, doi: 10.1016/s0004-3702(97)00043-x.
- [58] Isabelle G. ve Elisseeff, A. (2003). An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research* 3, 1157-1182
- [59] Eskidere, Ö. (2012). A Comparison of Feature Selection Methods for Diagnosis of Parkinson’s Disease from Vocal Measurements. *Journal Engineering and Natural Science*, vol. 30, no. 224.

- [60] Uçar, M. K. ve Düzayak, S. (2020). Papüloskuamöz Hastalıkların Belirlenmesi için Yapay ZekaYöntemleriyle Kural Tabanlı Teşhis Algoritmalarının Geliştirilmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, pp. 1903–1922, doi : 10.29130/dubited.706225.
- [61] McCarthy, J. ve Hayes, P. J. (1981). Some Philosophical Problems from the Standpoint of Artificial Intelligence. *Readings in Artificial Intelligence*, pp. 431–450, doi: 10.1016/B978-0-934613-03-3.50033-7.
- [62] Mahesh, B. (2018). Machine Learning Algorithms-A Review Self Flowing Generator View project Machine Learning Algorithms-A Review View project Batta Mahesh Independent Researcher Machine Learning Algorithms-A Review. *International Journal of Science and Research*, doi: 10.21275/ART20203995.
- [63] Arslankaya, S. ve Toprak, Ş. (2021). Using Machine Learning and Deep Learning Algorithms for Stock Price Prediction. *Uluslararası Muhendislik Arastirma ve Gelistirme Dergisi*, vol. 13, no.1, doi: 10.29137/umagd.771671.
- [64] Rasool, R. U., Ashraf, U., Ahmed, K., Wang, H., Rafique, W. ve Anwar, Z. (2019). Cyberpulse: A Machine Learning Based Link Flooding Attack Mitigation System for Software Defined Networks. *IEEE Access*, vol. 7, 2019, doi: 10.1109/ACCESS.2019.2904236.
- [65] Uçar, M. K., Bozkurt, M. R., Bilgin, C. ve Polat, K. (2017). Automatic detection of respiratory arrests in OSA patients using PPG and machine learning techniques. *Neural Comput Appl*, vol. 28, no. 10, 2017, doi: 10.1007/s00521-016-2617-9.
- [66] Aydılek, I. B. ve Arslan, A. (2013). A hybrid method for imputation of missing values using optimized fuzzy c-means with support vector regression and a genetic algorithm. *Inf Sci (N Y)*, vol. 233, 2013, doi: 10.1016/j.ins.2013.01.021.
- [67] Aydılek, I. B. ve Arslan, A. (2012). A novel hybrid approach to estimating missing values in databases using K-nearest neighbors and neural networks. *International Journal of Innovative Computing, Information and Control*, vol. 8, no. 7 A, 2012.
- [68] Tosunoğlu, E., R. Yılmaz, E., Özeren, E. ve Sağlam, Z. (2021). Machine Learning in Education: A Study on Current Trends in Researchs. *Journal of Ahmet Keleşoğlu Education Faculty*.
- [69] Roscher, R., Bohn, B., Duarte, M. F. ve Garcke, J. (2020). Explainable Machine Learning for Scientific Insights and Discoveries. *IEEE Access*, vol. 8, 2020, doi: 10.1109/ACCESS.2020.2976199.
- [70] Santos, R., Moreno, E. D. ve Estombelo-Montesco, C. (2019). A comparison of two embedded systems to detect electrical disturbances using decision tree algorithm. in *Proceedings - 32nd Symposium on Integrated Circuits and Systems Design, SBCCI 2019*, doi: 10.1145/3338852.3339878.
- [71] Saguil, D. ve Azim, A. (2019). Time-efficient offloading for machine learning tasks between embedded systems and fog nodes. in *Proceedings - 2019 IEEE 22nd International Symposium on Real-Time Distributed Computing, ISORC 2019*, doi: 10.1109/ISORC.2019.00022.

- [72] Cortes, C. ve Vapnik, V. (1995). Support-Vector Networks. *Mach Learn*, vol. 20, no. 3, 1995, doi: 10.1023/A:1022627411411.
- [73] Akben, S. B., Subaşı, A. ve Kıymık, M. K. (2010). Comparison of Artificial Neural Network and Support Vector Machine Classification Methods in Diagnosis of Migraine by using EEG. Erişim adresi <https://www.researchgate.net/publication/274696033>
- [74] Fernandes de Mello, R. ve Antonelli Ponti, M. (2018). Introduction to Support Vector Machines. in *Machine Learning*, doi: 10.1007/978-3-319-94989-5_4.
- [75] Ayhan, S. ve Erdoğan, Ş. (2014). Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü için Çekirdek Fonksiyonu Seçimi. Erişim adresi <https://dergipark.org.tr/tr/download/article-file/65371>
- [76] Kecman, V. (2002). Learning and Soft Computing: Support Vector Machines, Neural Networks and Fuzzy Logic Models by V Kecman.vol. 47. 2002.
- [77] Chomboon, K., Chujai, P., Teerarassamee, P., Kerdprasop, K. ve Kerdprasop, N. (2015). An Empirical Study of Distance Metrics for k-Nearest Neighbor Algorithm. doi: 10.12792/iciae2015.051.
- [78] Khan, M., Ding, Q. ve Perrizo, W. (2002). K-nearest neighbor classification on spatial data streams using P-trees. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 2336, 2002, doi: 10.1007/3-540-47887-6_51.
- [79] Rish, I. (2001, August). An empirical study of the naive Bayes classifier. In *IJCAI 2001 workshop on empirical methods in artificial intelligence* (Vol. 3, No. 22, pp. 41-46).
- [80] Kulkarni, V. Y., & Sinha, P. K. (2012, July). Pruning of random forest classifiers: A survey and future directions. In *2012 International Conference on Data Science & Engineering (ICDSE)* (pp. 64-68). IEEE.
- [81] Stitson, M. O., Weston, J. A. E., Gammerman, A., Vovk, V., & Vapnik, V. (1996). Theory of support vector machines. *University of London*, 117(827), 188-191.
- [82] Burges, C. J. (1998). A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 2(2), 121-167.
- [83] Scholkopf, B., Sung, K. K., Burges, C. J., Girosi, F., Niyogi, P., Poggio, T., & Vapnik, V. (1997). Comparing support vector machines with Gaussian kernels to radial basis function classifiers. *IEEE transactions on Signal Processing*, 45(11), 2758-2765.
- [84] Amari, S. I., & Wu, S. (1999). Improving support vector machine classifiers by modifying kernel functions. *Neural Networks*, 12(6), 783-789.
- [85] Ruck, D. W., Rogers, S. K., & Kabrisky, M. (1990). Feature selection using a multilayer perceptron. *Journal of Neural Network Computing*, 2(2), 40-48.

- [86] Huang, W., Zhao, X. ve Huang, X. (2021). Embedding and extraction of knowledge in tree ensemble classifiers. *Springer*, 2021, doi: 10.1007/s10994-021-06068-6.
- [87] Breiman, L. (2001). Machine Learning. *SpringerLink*, vol. 45, no. 1, 2001.
- [88] Breiman, L. (1996). Bagging predictors. *Mach Learn*, vol. 24, no. 2, 1996, doi: 10.1007/bf00058655.
- [89] Çölkesen, İ. ve Kavzoğlu, T. (2017). Classification of Remotely Sensed Imagery with Canonical Correlation Forest Algorithm. ,” *Afyon Kocatepe University Journal of Science and Engineering*, vol. 17, pp. 102–111, 2017
- [90] Jijo, B.T. ve Abdulazeez, A. M. (2021). Classification based on decision tree algorithm for machine learning. *Journal Of Applied Science And Technology Trends*, vol. 02, no. 01, pp. 20–28, 2021, doi: 10.38094/jastt20165.
- [91] Kavzoğlu, T. ve Çölkesen, İ. (2010). Karar Ağaçları İle Uydu Görüntülerinin Sınıflandırılması: Kocaeli Örneği. *Harita Teknolojileri Elektronik Dergisi*, vol. 2, no. 1, pp. 36–45, Erişim adresi <https://dergipark.org.tr/en/pub/hartek/issue/7601/99675>
- [92] Deliloğlu, R. A. S. ve Çakmak Pehlivanlı, A. (2021). Hybrid Explainable Artificial Intelligence Design and LIME Application. *European Journal of Science and Technology*, 2021, doi: 10.31590/ejosat.959030.
- [93] Yadav, S., & Shukla, S. (2016, February). Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification. In 2016 IEEE 6th International conference on advanced computing (IACC) (pp. 78-83). IEEE.
- [94] Gök, M. (2019). A novel machine learning model to predict autism spectrum disorders risk gene. *Neural Computing and Applications*, 31(10), 6711-6717.
- [95] Uçar, M.K., Bozkurt, M.R. ve Bozkurt, F. (2016). Determination of New Bio Signal and Tests Alternative to Verbal Pain Scale for Diagnosing Fibromyalgia Syndrome. *Image, Graphics and Signal Processing*, vol. 3, pp. 1–8, 2016, doi: 10.5815/ijigsp.2016.03.01.
- [96] Şen, E. et al. (2019). Chronic obstructive pulmonary disease (COPD). Erişim adresi <https://www.toraks.org.tr>
- [97] Pinto, M. ve Marques, P. (2017). OneCare Spiro: Mobile application for monitoring and pre-diagnosis of Chronic Obstructive Pulmonary Disease. in *ENBENG 2017 - 5th Portuguese Meeting on Bioengineering, Proceedings*, doi: 10.1109/ENBENG.2017.7889481.
- [98] Johari, N. H., Balaiyah, J. ve Ahmad, Z. (2014). Effect of chronic obstructive pulmonary disease on airflow motion using computational fluid dynamics analysis. in *I4CT 2014 - 1st International Conference on Computer, Communications, and Control Technology, Proceedings*, doi: 10.1109/I4CT.2014.6914184.

- [99] Örenc, S., Ucar, M. K., Bozkurt, M. R. ve Bilgin, C. (2017). A new approach for treatment of chronic obstructive pulmonary disease. in *2017 Medical Technologies National Conference, TIPTEKNO 2017*, doi: 10.1109/TIPTEKNO.2017.8238034.
- [100] Demir, E. (2022). Diagnosis Of Chronic Obstructive Pulmonary Disease Using Empirical Wavelet Transform Analysis From Auscultation Sounds. accessed Apr. 02, 2022. Erişim adresi: <http://openaccess.iste.edu.tr/xmlui/handle/20.500.12508/1442>
- [101] Gökçen, A. (2021). Computer-Aided Diagnosis System for Chronic Obstructive Pulmonary Disease Using Empirical Wavelet Transform on Auscultation Sounds. *Computer Journal*, vol. 64, no. 11, 2021, doi: 10.1093/comjnl/bxaa191.
- [102] Uçar, M. K., Örenç, S., Bozkurt, M. R. ve Bilgin, C. (2017). Evaluation of the relationship between Chronic Obstructive Pulmonary Disease and photoplethysmography signal. in *2017 Medical Technologies National Conference, TIPTEKNO 2017*, vol. 2017-January, pp. 1–5. doi: 10.1109/TIPTEKNO.2017.8238032.



EKLER

EK A. 10-kat çapraz doğrulama test tıknığıne göre sınıflandırma sonuçları

Yapılan çalışmada PPG ve alt frekans bantları ile sınıflandırma algoritması kullanılarak en iyi sonucu veren algoritmayı bulmaktır. Tablo A.1’de bir fizyolojik sinyal olan PPG'nin (fotopletizmografi) sınıflandırılması için çeşitli algoritmaların performansını ölçen farklı metriklerin sonuçlarını göstermektedir.

PPG ile yapılan çalışmada Tablo A.1’ye göre, Rastgele Orman modeli yüksek doğruluk, kesinlik, geri çağırma, özgüllük, MCC ve F-skoru ile en iyi performansa sahiptir. k-NN modeli Rastgele Orman’ten daha düşük bir doğruluğa sahiptir ancak nispeten yüksek kesinlik ve özgüllüğe sahiptir. Naive Bayes modeli yüksek geri çağırma oranına ancak düşük kesinlik ve özgüllüğe sahiptir. Doğrusal DVM ve Çok Katmanlı Algılayıcı modelleri tüm ölçütler açısından çok düşük performansa sahiptir. Son olarak, RBF SVM modeli yüksek bir geri çağırma oranına ancak düşük hassasiyet, özgüllük ve MCC değerlerine sahiptir.

Tablo A.1. PPG ile Sınıflandırma algoritmaları Performans Metrikleri listesi

Sınıflandırma Algoritmaları	Test Performans Değerlendirme Kriterleri					
	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	MCC	F-Ölçümü
k-NN	65.03	71.48	45.86	82.92	31.11	55.83
Naive Bayes	50.39	49.3	99.53	4.57	12.89	65.93
Random Forest	92.42	93.31	90.83	93.92	84.85	92.04
Linear SVM	51.91	0.1	25.52	76.37	0.1	0.1
RBF SVM	48.86	0.1	90.01	10.01	0.01	0.1
Multilayer Perceptron	49.98	0.1	61.47	39.14	0.01	0.1

Doğruluk: Tüm örnekler arasında doğru sınıflandırılmış örneklerin oranını ölçer.

Kesinlik: Tahmin edilen tüm pozitif örnekler arasında doğru tanımlanan pozitif örneklerin oranını ölçer.

Geri Çağırma: Tüm gerçek pozitif örnekler arasında doğru tanımlanmış pozitif örneklerin oranını ölçer.

Özgüllük: Tüm gerçek negatif örnekler arasında doğru tanımlanan negatif örneklerin oranını ölçer.

MCC (Matthews Korelasyon Katsayısı): İkili sınıflandırmanın kalitesinin bir ölçüsüdür ve -1 (tam uyuşmazlık) ile 1 (mükemmel uyum) arasında değişir.

F-skoru: Bir modelin doğruluğunun hem kesinlik hem de geri çağırma dikkate alan bir ölçüsüdür.

Tablo A.2. PPG LF ile Sınıflandırma algoritmaları Performans Metrikleri listesi

Sınıflandırma Algoritmaları	Test Performans Değerlendirme Kriterleri					
	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	MCC	F-Ölçümü
k-NN	56.3	57.01	38.93	72.41	12.12	46.16
Naïve Bayes	52.94	50.64	97.55	11.33	17.33	66.66
Random Forest	92.56	93.58	90.84	94.19	85.13	92.18
Linear SVM	51.28	6.03	10.01	89.42	-4.65	0
RBF SVM	49.03	0	80.01	20.02	0	0
Multilayer Perceptron	49.79	0	72.74	27.09	0	0

PPG sinyallerinin sınıflandırılması için kullanılan farklı makine öğrenmesi algoritmalarının performans metrikleri Tablo A.2’de göstermektedir. Performans metrikleri, her bir algoritmanın sınıflandırma doğruluğunu, hassasiyetini, geri çağırmasını, özgüllüğünü, Matthews korelasyon katsayısını (MCC) ve F-Skorunu ölçer.

K-NN algoritması, %56.3 doğruluk oranı ile diğer algoritmalara göre daha düşük bir performans sergilemektedir. Diğer performans metrikleri de göreceli olarak düşüktür.

Naive Bayes algoritması, geri çağırma oranı %97.55 ile diğer algoritmalara göre yüksek bir performans sergilemektedir. Ancak, düşük hassasiyeti ve düşük özgüllüğü nedeniyle %52.94 doğruluk oranı ile diğer algoritmalara göre düşük bir performans göstermektedir.

Random Forest algoritması, %92.56 doğruluk oranı ile en yüksek doğruluk oranına sahiptir. Diğer performans metriklerinde de yüksek değerlere sahip olması nedeniyle en iyi performansı gösterir.

Linear SVM, %51.28 doğruluk oranı ve diğer performans metrikleri ile diğer algoritmalara göre düşük bir performans sergiler.

RBF SVM ve Multilayer Perceptron algoritmaları, %49.03 ve %49.79 doğruluk oranları ve diğer performans metrikleri ile diğer algoritmalara göre en düşük performansı gösterirler.

Genel olarak, Random Forest algoritması bu veri seti için en iyi performansı gösterirken, diğer algoritmaların daha fazla geliştirilmeye ihtiyacı vardır.

Tablo A.3. PPG MF ile Sınıflandırma algoritmaları Performans Metrikleri listesi

Sınıflandırma Algoritmaları	Test Performans Değerlendirme Kriterleri					
	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	MCC	F-Ölçümü
k-NN	56.94	57.25	42.69	70.21	13.46	48.87
Naïve Bayes	51.75	50.01	98.53	8.14	15.4	66.33
Random Forest	77.54	78.82	73.06	81.71	55.04	75.82
Linear SVM	49.93	0	15.24	82.2	0	0
RBF SVM	51.75	0	0	100	0	0
Multilayer Perceptron	50.28	0.1	42.24	58.01	0.1	0.1

PPG MF farklı makine öğrenimi algoritmalarının performansını değerlendirmek için kullanılan çeşitli ölçümleri içermektedir. Performans metrikleri, Tablo A.3'te PPG MF veri kümesindeki sınıflandırma görevi için hesaplanmıştır.

Tabloya göre, en yüksek accuracy, precision, recall, specificity, MCC ve F-score değerleri, Random Forest algoritması tarafından elde edilmiştir. Naive Bayes algoritması, en yüksek recall ve F-score değerlerine sahip olmasına rağmen, en düşük accuracy ve specificity değerlerine sahiptir. Linear SVM ve RBF SVM algoritmaları, çok düşük accuracy ve MCC değerlerine sahiptir. Multilayer Perceptron algoritması, tüm performans metriklerinde düşük değerler göstermektedir.

Tablo A.4. PPG HF ile Sınıflandırma algoritmaları Performans Metrikleri listesi

Sınıflandırma Algoritmaları	Test Performans Değerlendirme Kriterleri					
	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	MCC	F-Ölçümü
k-NN	63.41	70.45	41.67	83.68	28.06	52.35
Naïve Bayes	56.83	52.81	99.01	17.51	28.08	68.87
Random Forest	89.65	90.63	87.63	91.55	79.31	89.10
Linear SVM	50.67	0	30	69.95	0	0
RBF SVM	51.36	0	10	90.00	0	0
Multilayer Perceptron	48.18	48.89	88.88	10.41	0	59.14

PPG HF Performans Metriklerini, beş farklı makine öğrenimi algoritmasının kullanımıyla karşılaştıran sonuçları gösterir. PPG HF Tablo A.4.'te algoritmaların performansı, bu metriklerin her birinin değerleri açısından karşılaştırılmıştır. Örneğin, Naive Bayes algoritması yüksek bir geri çağrı oranına sahip olmasına rağmen, düşük bir hassasiyet oranı ve düşük bir doğruluk oranına sahiptir. Diğer yandan, Random Forest algoritması yüksek bir doğruluk oranına sahiptir ve diğer tüm metriklerde iyi performans gösterir. Linear SVM algoritması ise çok düşük bir doğruluk oranı ve diğer tüm metriklerde sıfır performans gösterir.

Tablo A.5. PPG ALL ile Sınıflandırma algoritmaları Performans Metrikleri listesi

Sınıflandırma Algoritmaları	Test Performans Değerlendirme Kriterleri					
	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	MCC	F-Ölçümü
k-NN	66.95	66.75	62.84	70.81	33.76	64.72
Naïve Bayes	51.96	50.11	98.98	8.12	16.77	66.52
Random Forest	92.44	94.77	89.26	95.42	84.97	91.92
Linear SVM	50.79	0	30.01	70.37	0	0
RBF SVM	50.96	0	20.01	80.03	0	0
Multilayer Perceptron	50.12	0	66.15	34.86	0	0

PPG ALL Performans Metriklerini, beş farklı makine öğrenimi algoritmasının kullanımıyla karşılaştıran sonuçları gösterir.

PPG ALL Tablo A.5'te ki algoritmaların performansı, bu metriklerin her birinin değerleri açısından karşılaştırılmıştır. Örneğin, Random Forest algoritması yüksek bir doğruluk oranına sahip olmasına rağmen, Naive Bayes algoritması yüksek bir geri çağrı oranına sahiptir ancak diğer metriklerde zayıf performans gösterir. Linear SVM ve RBF SVM algoritmaları düşük bir doğruluk oranına sahiptir ve diğer tüm metriklerde sıfır performans gösterir. Multilayer Perceptron algoritması yüksek bir geri çağrı oranına sahip olmasına rağmen, diğer metriklerde zayıf performans gösterir.





ÖZGEÇMİŞ

Ad-Soyad : Engin MELEKOĞLU

ÖĞRENİM DURUMU:

- **Lisans** : 2007, Trakya Üniversitesi, Mühendislik – Mimarlık Fakültesi, Bilgisayar Mühendisliği
- **Yükseklisans** : 2010, Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- **2015-Halen** Kolegji AAB Üniversitesinde Öğretim Görevlisi olarak çalışmakta.
- **2011-Halen** Ukshin Hoti Prizren Üniversitesinde Öğretim Görevlisi olarak çalışmakta.
- **2013- Halen** ESengineerin Yazılım Şirketi Genel Müdür olarak çalışmakta.
- **2011-2015** Kamu Yönetim Bakanlığında Bakan Danışmanı olarak görev yaptı
- **2011-2013** University Of European Polytechnical üniversitesinde Öğretim Görevlisi olarak çalıştı
- **2011-2012** Prishtina Üniversitesinde Öğretim Görevlisi olarak çalıştı
- **2009-2011** Grafikirler Yazılım ve Reklamcılık Ltd.Şti Yazılım uzmanı olarak çalıştı
- **2007-2009** ASD Yazılım ve Reklamcılık Ltd.Şti Yazılım Uzmanı olarak çalıştı
- **2006-2007** Markadeste Yazılım ve Reklamcılık Ltd.Şti Web geliştirici olarak çalıştı
- **2006- 3 Ay** Netsis Yazılım Llc Stajer olarak çalıştı

TEZDEN TÜRETİLEN ESERLER:

- E. Melekoğlu, Ü. Kocabiçak, M. K. Uçar, M. R. Bozkurt, C. Bilgin, M Cunkas (2022, 19 Aralık). A new diagnostic method for chronic obstructive pulmonary disease using the photoplethysmography signal and hybrid artificial intelligence, PeerJ Computer Science 8, e1188
- E. Melekoğlu, Ü. Kocabiçak, M. K. Uçar, M. R. Bozkurt, and C. Bilgin, “Machine Learning for the Diagnosis of Chronic Obstructive Pulmonary Disease and Photoplethysmography Signal – Based Minimum Diagnosis Time Detection,” in Lecture Notes on Data Engineering and Communications Technologies, vol. 76, 2021. doi: 10.1007/978-3-030-79357-9_6.
- Sensing platform development for air quality measurements and analysis A Maraj, S Berzati, I Efendiu, A Shala, J Dermaku, E Melekoglu 2017 South Eastern European Design Automation, Computer Engineering
- “Ülke Tanitimina Yönelik Portal Tasarımı ve Kosova Cumhuriyeti için Bir Uygulama” E Melekoğlu PQDT-Global

- ReSPA regional comparative eGovernment study E-Government Kosova Engin Melekoglu, <http://www.cothomasen.dk/document.asp?key=ReSPA-regional-comparative-eGovernment-study&locale=en>

YABANCI DİL

- Türkçe Anadili
- Arnavutça
- Sırpça
- İngilizce

