

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

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

YÜKSEK LİSANS TEZİ

Sedat ÖRENÇ

Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK MÜH.
Tez Danışmanı : Doç. Dr. Mehmet Recep BOZKURT

Mayıs 2019

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

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

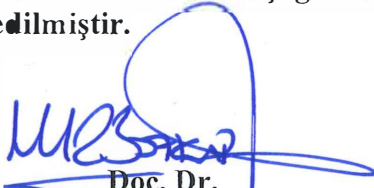
YÜKSEK LİSANS TEZİ

Sedat ÖRENÇ

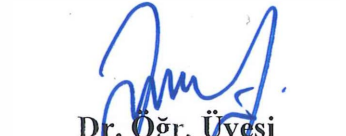
Enstitü Anabilim Dalı

**ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ**

Bu tez tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.


Doç. Dr.
Mehmet R. BOZKURT
Jüri Başkanı


Dr. Öğr. Üyesi
Gökçen ÇETİNEL
Üye


Dr. Öğr. Üyesi
Mustafa Zahid YILDIZ
Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Sedat ÖRENÇ
01.01.2018

TEŐEKKÜR

Yüksek lisans eğitiminin boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Doç. Dr. Mehmet Recep Bozkurt'a teşekkürlerimi sunarım. Tez çalışmasında kullanılan verilerin toplanma konusunda yardımcı olan Dr. Cahit Bilgin'e, tez süresi boyunca bilgi ve tecrübeleri ile destek veren Arş. Gör. Dr. Muhammed Kürşad Uçar'a teşekkürlerimi sunmak isterim.

Ayrıca hayatımın her alanında ve özellikle tez çalışma süresince maddi ve manevi desteklerini esirgemeyen aileme teşekkürü bir borç bilirim.

Bu tez çalışmasının diğer çalışmalara ışık tutmasını ve yardımcı olmasını temenni ederim.

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	vii
TABLOLAR LİSTESİ.....	viii
ÖZET.....	ix
SUMMARY	x
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
KRONİK OBSTRÜKTİF AKCİĞER HASTALIĞI	6
2.1. KOAH Nedenleri	6
2.2. KOAH Belirtileri.....	7
2.3. KOAH Teşhisi.....	8
2.4. Tedavi.....	8
2.4.1. İlaç tedavisi ve davranışsal değişiklikler.....	9
2.4.2. Bronkodilatör cihaz tedavisi	10
2.4.3. Cerrahi müdahale	10
BÖLÜM 3.	
FOTOPLETİSMOGRAFİ SİNYALİNİN İNCELENMESİ.....	11
3.1. Fotopletismografi Sinyalinin Oluşumu ve Ölçülmesi.....	12
3.2. Sayısal Filtreleme.....	13
3.3.Özellik Çıkarma	14

3.4. Fotopletismografi Sinyalinin Karakteristik Özellikleri.....	15
BÖLÜM 4.	
KULLANILAN VERİ KÜMESİ	17
4.1. Verilerin Toplanması	17
BÖLÜM 5.	
SINIFLANDIRMA ALGORİTMALARI.....	19
5.1. Sınıflandırma Algoritmaları	19
5.2.1. k- en yakın komşu algoritması	19
5.2.2. Olasılıksal yapay sinir ağları	20
5.2.3. Destek vektör makineleri	22
5.3. Performans Değerlendirme Kriterleri	22
5.3.1. Karışıklık matrisi, doğruluk, duyarlılık, özgüllük ve f-ölçümü	23
BÖLÜM 6.	
SONUÇLAR	25
BÖLÜM 7.	
TARTIŞMA	31
KAYNAKÇA.....	34
ÖZGEÇMİŞ	39

SİMGELER VE KISALTMALAR LİSTESİ

A	: Hjort parametresi - aktivite
AC	: Alternatif Akım
C	: Hjort parametresi - karmaşıklık
CL	: Ortalama eğri uzunluğu
Cm	: Santimetre
D	: Uzaklık hesaplama formülü
DC	: Doğru akım
DSÖ	: Dünya sağlık örgütü
FEV1	: Zorlu ekspirasyon hacmi
FIR	: Sonlu dürtü yanıtı
FN	: Yanlış negatif
FP	: Yanlış pozitif
FVC	: Zorlu vital kapasite
G	: Geometrik ortalama
GOLD	: Kronik obstrüktif akciğer hastalığı için global girişim
H	: Harmonik ortalama
Hz	: Hertz
IIR	: Sonsuz dürtü yanıtı
IR	: Kızıl ötesi
K	: kNN için en yakın komşu sayısı
Kg	: Kilogram
kNN	: k-en yakın komşuluk sınıflandırma algoritması
KOAH	: Kronik obstrüktif akciğer hastalığı
LOCMIN	: Yerel minimum
M	: Hjort parametresi - hareketlilik
m	: Metre

m^2	: Metre kare
Maks	: Maksimum
Min	: Minimum
N	: Negatif
N	: Toplam birey sayısı
n_1	: Erkek birey sayısı
n_2	: Kadın birey sayısı
Ort	: Ortalama
P	: Pozitif
PNN	: Olasılıksal yapay sinir ağıları
PPG	: Fotopletismografi
PSG	: Polisomnografi
R	: Aralık
S	: Standart Sapma
S_1^2	: 1. türevin varyansı
S_2	: Varyans
S_2^2	: 2. türevin varyansı
SF	: Şekil faktörü
SFT	: Solunum fonksiyon testi
S_n	: Saniye
Std	: Standart sapma
SVD	: Tekil değer ayrışımı (Singular value decomposition)
SVM	: Destek vektör makine
S_x	: Standart hata
T	: Periyot sayısı
T25	: %25 kırılmış ortalama
T50	: %50 kırılmış ortalama
TC	: Türkiye Cumhuriyeti
TE	: Ortalama teager enerjisi
TN	: Gerçek negatif
TP	: Gerçek pozitif
X	: Basıklık (Kurtosis)

\bar{x}	: Medyan
X_{kur}	: Ortalama
X_{max}	: Maksimum
X_{min}	: Minimum
X_{rms}	: Ortalama karekök deęeri (Root mean squared value)
X_{ske}	: arpıklık (Skewness)
Λ	: Dalga boyu

ŞEKİLLER LİSTESİ

Şekil 1.1. Tez genel akış diyagramı	5
Şekil 3.1. Fotopletismografi sinyaline ait periodogram grafiği	11
Şekil 3.2. PPG çalışma mekanizması [30]	12
Şekil 3.3. Filtrelenmemiş PPG Sinyali.....	14
Şekil 3.4. Bant geçiren filtre uygulanmış PPG Sinyali	14
Şekil 3.5. Bant geçiren ve Kayan ortalama filtreleri uygulanmış PPG Sinyali	14
Şekil 3.6. PPG sinyalinden özellik çıkarım akış diyagramı	15
Şekil 5.1. PNN için genel ağ yapısı.....	21
Şekil 5.2. Sınıfların (a) lineer ve (b) lineer olmayan doğrularla ayrılması [30].....	22

TABLolar LİSTESİ

Tablo 2.1. KOAH Şiddet Evreleme [24].....	8
Tablo 3.1. PPG sinyali için istatistiksel zaman domeni özellikleri.....	15
Tablo 4.1. Bireylere ait demografik bilgiler.....	18
Tablo 4.2. Bireylere ait demografik bilgilerin standart sapma ve ortalama cinsinden (ort ± std) gösterilmesi	18
Tablo 5.1. kNN için kullanılacak parametreler	20
Tablo 5.2. Eğitim ve test aşamalarında veri dağılımı	23
Tablo 5.3. Doğruluk, özgüllük ve duyarlılık için karşılaştırma matrisi	24
Tablo 6.1. kNN sonuçlar	27
Tablo 6.2. PNN sonuçlar	29
Tablo 6.3. SVMs sonuçlar.....	30

ÖZET

Anahtar Kelimeler: Biyomedikal Sinyal İşleme, Kronik Obstrüktif Akciğer Hastalığı, Spirometre, Fotopletismografi, k – En Yakın Komşuluk Sınıflandırma Algoritması, Olasılıksal Yapay Sinir Ağları, Destek Vektör Makine

Kronik Obstrüktif Akciğer Hastalığı (KOAH) sigara, toz ve duman gibi etkenlerden dolayı akciğerlere giden hava miktarının azalması ile birlikte meydana gelen solunumsal hastalıktır. Bu hastalığın teşhisi spirometre ve polisomnografi (PSG) cihazı ile yapılabilmektedir fakat sistemin yeterince gelişmemesinden dolayı, bireylere bazı zorluklar yaşatabilmektedir. Bu zorlukları ortadan kaldırmak için PSG cihazı kadar yararlı olabilecek alternatif sistemlere ihtiyaç duyulmaktadır. Bu çalışmada, bireye daha az sıkıntı oluşturan ve PSG cihazı kadar verimli bir şekilde çalışabilen bir sistem geliştirilmiştir. Bu durumdan dolayı fotopletismografi sinyali kullanılarak zaman ekseninde 26 adet özellik çıkartılmıştır. Makine öğrenmesi modelleri olan k – En Yakın Komşu Algoritması, Olasılıksal Yapay Sinir Ağları ve Destek Vektör Makine olmak üzere toplamda 3 adet sınıflandırma algoritması kullanılmıştır. Bu tez çalışmasında ayrıca 8 KOAH'lı hasta ve 6 kişilik sağlıklı bireye ait veriler kullanılmıştır. Sınıflandırma algoritma performanslarının değerlendirebilmek için doğruluk oranı, özgüllük, duyarlılık ve F-ölçümü gibi parametreler kullanılmıştır. Her 3 makine öğrenmesi modelinde de elde edilen sonuçlar en az doğruluk oranı %80 olup bazı algoritmalara göre tüm verilerin doğruluk oranı %100 doğru sınıflandırılmış, duyarlılık 1, özgüllük 1 ve F-ölçümü 1 olarak tespit edilmiştir. Tez çalışmasında elde edilen sonuçlar değerlendirildiğinde makine öğrenmesi temelli KOAH teşhisi verimli bir şekilde yapılabileceği gösterilmiştir.

DEVELOPMENT A NEW METHOD FOR DIAGNOSING CHRONIC OBSTRUCTIVE PULMONARY DISEASE BASED ON MACHINE LEARNING

SUMMARY

Keywords: Biomedical Signal Processing, Chronic Obstructive Pulmonary Disease, Spirometry, Photoplethysmography, k – Nearest Neighbor Classification Algorithm, Probabilistic Neural Network, Support Vector Machines

Chronic Obstructive Pulmonary Disease is a respiratory disease that it is caused by decreased in the amount of air to the lungs due to factors such as smoking, dust and smoke. Diagnosis of this disease can be made by spirometry and polysomnography (PSG) device but it may cause some difficulties to persons because owing to deficiency of system. It needs alternative systems that can be as beneficial as the PSG device to eliminate these challenges. In the study, a system that less distressing and works as efficiently as the PSG device has been developed. Because of this situation, 26 features were extracted from pletismography signal in the time domain. It was used 3 classification algorithms which are k – Nearest Neighbor Classification, Probabilistic Neural Network and Support Vector Machines that are machine learning models. In this thesis, 8 patients with COPD and 6 healthy subjects were used. Accuracy ratio, sensitivity, specificity and f-measurement are used to evaluate the classification algorithms performance. The result is obtained in all 3 machine learning models were at least %80 and according to some algorithms all datas were classified as %100 and all parametres sensitivity, specificity and f-measurement were determined as 1. Evaluating the results obtained in the study, it has been proven that machine learning based COPD diagnosis can be performed efficiently.

BÖLÜM 1. GİRİŞ

Tarih boyunca insanlar çeşitli hastalıklara maruz kalmış ve bu hastalıklardan kurtulmak için çeşitli yöntemler, araçlar ve gereçler kullanmış ve geliştirmiştir. Bu hastalıkların başında solunumsal hastalıklar gelir ve solunumsal hastalıkların en önemlilerinden biri olan Kronik Obstrüktif Akciğer Hastalığı (KOAH)'dır. KOAH ilerleyici ve tam anlamıyla geri dönüşü olmayan, fakat önlenabilir ve tedavi edilebilir bir akciğer hastalığıdır [1]. Bu hastalık ilerleyici olup havayollarında ve akciğerin zararlı parçacıklara, gazlara karşı artmış kronik bir inflamatur yanıt ile ilişkili, kalıcı hava akımı kısıtlılığı karakterize, yaygın görülen, önlenabilir ve tedavi edilebilir ciddi, öldürücü bir solunumsal hastalıktır [2].

Akciğerlerin çalışma mekanizmasına bakıldığında, dışarıdan alınan temiz havanın akciğerlere ulaşmasına inspirasyon ve alınan havanın akciğerlere ulaşp diğer organlardan geçtikten sonra kirli havanın akciğerlerden atılmasına ekspirasyon denir. Alınan oksijen, burun ve ağız yoluyla nefes borusu olarak adlandırılan esnek bir borudan geçerek bronşlara ulaşır. Hem sağ akciğer hem de sol akciğer içerisinde iki büyük bronş bulunur. Ayrıca ağaç dalı gibi çok sayıda küçük bronşçuklar mevcuttur. Oksijen, bu borular vasıtasıyla ile akciğerin en uç noktasında bulunan alveol olarak adlandırılan elastik keseciklere kadar iletilir. İletilen oksijen kan damarları yoluyla tüm vücuda dağıtılır. Vücutta kullanılan oksijen karbondioksite dönüşür ve tekrar akciğere taşınır. Soluk verme sırasında dışarıya atılır. Bu gaz alış-verişinde ciğerlere giren hava kirli olursa; akciğer, bronş ve alveollerin yapısı zaman içerisinde bozulur. Bu bozulmadan dolayı KOAH meydana gelir [3].

KOAH dünya genelinde çok ciddi ve tehlikeli bir hastalık olup ölüme sebebiyet veren hastalıklardan birisidir. KOAH bütün dünya ülkelerinde gittikçe artan mortalite nedeni olarak gösterilen evrensel bir sağlık sorunudur. Dünya Sağlık Örgütü (WHO,

DSÖ)'ne göre, bu hastalık dünya çapında en sık görülen 4. ölüm nedenidir. Her yıl dünyada 2 milyon 900 bin insan bu hastalıktan ölmektedir. Türkiye'de ise KOAH, ölüme neden olan hastalıklar grubunda 3. sırada yer almaktadır. Türkiye'de her 5 bireyden biri KOAH'lıdır. Fakat KOAH'a maruz kalanların ancak 10'da biri hastalığının farkındadır. Hem dünyada hem de ülkemizde KOAH yeteri kadar bilinmemekle beraber yeterince teşhis edilememektedir. Teşhis edilen bireylerde ise; etkileyici ve yararlı bir tedavi sürecine girilememektedir [3], [4].

Günümüzde tıbbi alanda teknolojik gelişmeler ile birlikte KOAH teşhisi gittikçe kolaylık kazanmaktadır. KOAH teşhisi yapabilmek için hastalar en başta belirtileri fark etmeli ve ardından hastalığın teşhisi için bazı testler yapmalıdır. En sık görülen solunum fonksiyon testlerinden biri, akciğer fonksiyonlarının inhale ve ekshalasyon hava miktarını ve hızını ölçmek için kullanılan spirometredir. Bu akciğer fonksiyonlardaki bozukluğu ve bozukluğun derecesini belirlemek amacıyla kullanılan bir yöntemdir. Solunum testi sırasında hasta, bir cihaza bağlı olan boru şeklindeki bir tüpe nefesinin yetebildiği kadarıyla üfler. Bu cihaz, hastanın havayı ne kadar soluduğu ve ne kadar hızla havayı üflediğini ölçer. Spirometre cihazı genellikle 2 parametreyi ölçer: Zorlu vital kapasite (FVC) ve bir saniyede zorlu ekspirasyon hacim (FEV1) [5]. Solunum testinden sonra eğer $FEV1/FVC < \%70$ oranında ise hasta KOAH olarak kabul edilir [6]. Hastalar semptomların ilerlemesine dikkat etmeli ve hastalığı daha erken teşhis edip alevlenmeleri önlemek amacıyla solunumsal spirometri testleri uygulayıp düzenli olarak kontrollerden geçmelidir. Ne yazık ki bu tür testler, hastanelere gitmeyi zorunlu kılmakta ve neticesinde ekonomik zarar ve zaman kaybına sebebiyet vermektedir [5]. Bu tarz sorunların üstesinden gelebilmek için maliyeti uygun ve taşınabilir cihazların geliştirilmesi gerekmektedir. KOAH teşhisini daha çabuk yapabilmek ve hastalık sürecini daha kolay izleyebilmek için bu çalışmada taşınabilir bir teşhis sistemi geliştirilmesi amaçlanmıştır. Bu amaca ulaşabilmek için çalışmada fotopletizmografi (PPG) sinyali kullanılmıştır.

PPG, doku içine belirli dalga boyunda ışık yayarak bir fototransistör yardımıyla yansıyan veya iletilen ışığı tespit ederek kan hacmindeki değişimleri saptayan bir yöntemdir [7]. PPG verilerini elde edebilmek için parmağın bir tarafına dalga boyu λ

olan bir ışık kaynağı, diğer tarafına kaynağın tam karşısına iletilen ışığı yakalayacak fototransistör yerleştirilir. Bir PPG sinyali, kan damarının içinden geçmeyip deri, kas ve kemikten geçen büyük bir DC bileşeni ile doğrudan kan damarlarından geçen küçük bir AC bileşenden oluşur. Ancak bireyin kişisel bilgisini içeren bu AC bileşenin, tüm sinyallerde küçük bir etkisi mevcuttur. Bundan dolayı amaca yönelik kullanılan bir yükselteç devresi AC sinyalden istenilen bilginin çıkartılmasında önemli bir rol oynamaktadır. Bu amaçla, sinyaldeki DC kısmın azaltılıp AC kısmın kuvvetlendirilerek elde edilmesi sağlanmalıdır. PPG'nin tercih edilme sebepleri arasında kolay erişilebilir olması, kullanım kolaylığı ve güvenilirliğin yüksek olması mevcuttur. Ayrıca PPG, kan basıncı, solunum, kalp hızı ve kanın oksijen yoğunluğu gibi birçok parametrelerin belirlenmesinde de kullanılabilir [8].

Bu çalışmada PPG sinyali ile elde edilen veriler, hastanın uyku halinde parmağından alınan verilerdir. Bu nedenle yapılan çalışmalar ile elde edilmek istenen doğruluk yüzdesi artırma hedeflenmiştir. 14 bireyin yaklaşık olarak 8 saatlik PPG sinyal kayıtları kullanılmıştır. Uzman doktor tarafından teşhisi konulan 8 erkek ile KOAH grubunda, 2 kadın 4 erkek birey de Sağlıklı grubunda olmak üzere toplamda 14 adet bireyin kaydı alınmıştır. Ayrıca sinyaldeki gürültülerin giderilmesi amacıyla Kayan ortalama filtresi uygulanmıştır. Akabinde sinyal 15 saniyelik epoklara bölünmüş olup bölünen her epoktan zaman ekseninde 26 adet özellik çıkarımı yapılmıştır. Özellik çıkarımı yapıldıktan sonra makine öğrenmesi yöntemleri kullanılarak sınıflandırma yapılmıştır. Sınıflandırma yöntemlerinde sistemin performansını değerlendiren parametreler kayıt altına alınmıştır.

Bilgi ve medikal teknolojilerdeki son gelişmeler hastalara akıllı, kişiselleştirilmiş bakım sağlayarak yapay zeka ile tıbbi karar destek sistemlerine olan ilgiyi artırdı [9]. Yapay zeka, akıllı davranışları asgari insani müdahale ile modellemek için bir bilgisayar kullanılmasını gerektiren genel bir kavramdır [10]. Yapay zekanın kullanıldığı birçok alan vardır. Bunların başında robotik gelir. Ayrıca yapay zeka ses tanıma, görüntü işleme, sürücüsüz arabalar, yüksek seviyeli oyunlar ve hastalık teşhisinde kullanılır [11], [12]. Bu gelişmeler, KOAH teşhisinde oldukça yeni olan bazı sınıflandırıcı, karar verici yazılımlar ve yöntemlerin uygulanabilirliği üzerine

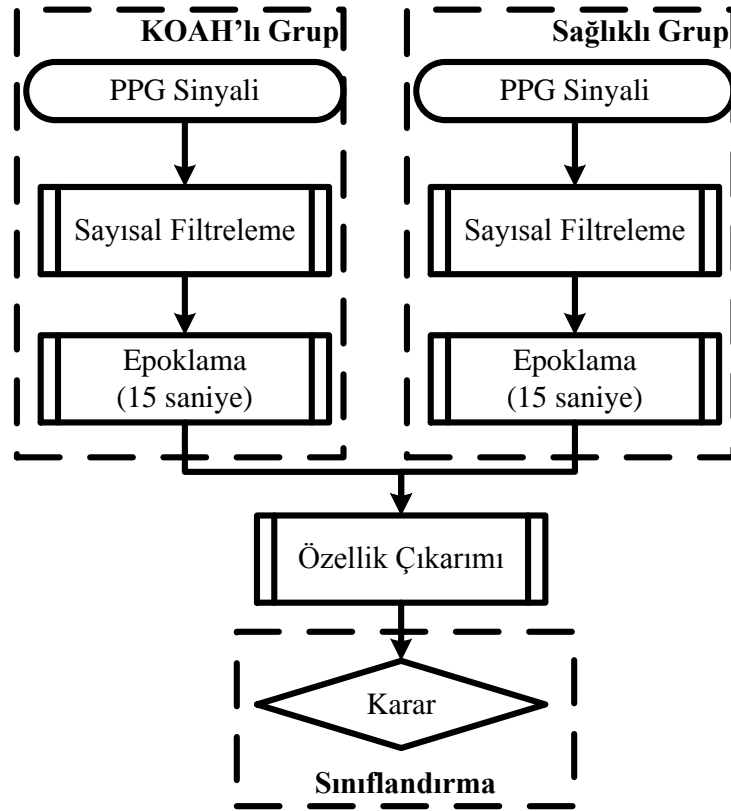
çeşitli çalışmalar yapılmakta olup projeler yürütülmektedir. Bu çalışmalar ile sınıflandırma problemlerinde kullanılacak birçok makine öğrenmesi yöntemi mevcuttur [6], [13]. Bu çalışmada 3 adet makine öğrenmesi yöntemi kullanılmıştır. k-en yakın komşuluk sınıflandırma algoritması (k-Nearest Neighbors Classification Algorithm - kNN), olasılıksal yapay sinir ağları (Probabilistic Neural Network-PNN) ve destek vektör makineleri (Support Vector Machines - SVMs) olmak üzere 3 adet metot kullanılmıştır. Bu çalışmada kullanılan makine öğrenmesi yöntemlerinin faydaları arasında; zaman kazancı, teşhis süresinin kısalması ve verimliliğin artışı mevcuttur [6].

Bu çalışmanın genel amaçlarından biri, makine öğrenmesi yöntemleri kullanılarak KOAH teşhisini kolaylaştırmak ve KOAH'ı tespit etmeye yardımcı olmaktır. Bunun yanı sıra teşhis süresinin, verimlilik ve zaman gibi parametrelerin de iyileştirilmesi gayeler arasında yer almaktadır [6]. Bu çalışma Kronik Obstrüktif Akciğer Hastalığı için Global Girişim (GOLD) prensiplerine uygun olarak yapılmış olup PPG sinyali kullanılarak gerçekleştirilmiştir.

Tez çalışması genel hatlarıyla Şekil 1.1.'de gösterilmiştir. Bu akış diyagramına göre tez bölümleri hazırlanmıştır. Bu tez kitabı 7 bölümden oluşur. Bölüm 1'de problemin ne olduğundan bahsedilmiş ve literatür taraması yapılmıştır. Bölüm 2'de KOAH'ın tanımı, belirtileri, teşhis ve tedavisinden bahsedilmiştir. Bunun yanı sıra tedavi yöntemlerinden olan, ilaç tedavisi ve davranışsal değişiklikler, bronkodilatör cihaz tedavisi ve son olarak da cerrahi müdahale anlatılmıştır.

Bölüm 3'te PPG sinyalinin oluşumu, özellikleri, ön işlenmesi, ölçülmesi ve PPG sinyalin sayısal filtrelenmesi gibi konulardan bahsedilmiştir. Ayrıca PPG sinyalinden özellik çıkarımından bahsedilmiş olup PPG sinyalinden elde edilen karakteristik özellikler anlatılmıştır.

Bölüm 4'te, çalışmada kullanılan verilerin toplanması ve sinyal işleme adımları anlatılmış olup Şekil 1.1.'deki akış diyagramında "Veri Kümesi" olarak adlandırılan kısmı anlatmak için verilmiştir.



Şekil 1.1. Tez genel akış diyagramı

Bölüm 5’da PPG sinyalinden elde edilen verilerin sınıflandırılması ile alakalı yöntemler ve performans değerlendirme kriterleri anlatılmıştır. Sınıflandırma algoritmaları olarak kNN, PNN ve SVMs olmak üzere 3 adet makine öğrenmesi yöntemlerinden ve son olarak da performans değerlendirme kriterleri olan doğruluk, duyarlılık, özgüllük, F-ölçümü ve karışıklık matrisi gibi parametrelerden bahsedilmiştir.

Bölüm 6’da makine öğrenmesi metotları kullanılarak tez çalışmasına uygun sonuçlar elde edilmiştir ve bulunan bu sonuçlara göre, PPG sinyalinin KOAH teşhisinde kullanılabileceği gösterilmiştir. Bölüm 7’de son olarak tez çalışmasının sonuçları tartışılıp yorumlanmış olup bu adımdan sonra teze son verilerek çalışma tamamlanmıştır.

BÖLÜM 2. KRONİK OBSTRÜKTİF AKCİĞER HASTALIĞI

Hava kirliliği, sigara dumanı, araba egzozu, toz gibi etkenlerden dolayı solunumsal hastalıkların artış oranı gün geçtikçe yükselmektedir. KOAH, yüksek ölüm oranları ile bu hastalıkların en önemlilerinden biridir [14]. KOAH günümüzde en çok görülen ve yaygın olan solunum yolu hastalıklarından biridir [5]. Hastalık, genellikle sigara dumanı ve diğer zararlı gaz maddelerine bağlı olarak ilerleyen ve nefes borularında meydana gelen solunum yolu iltihaplanması sonucu oluşur. Bu nedenle soluk alış-verişi süresince, hava yollarında ve hava keseciklerinde problemler meydana gelir [15]. KOAH, prevalansı yüksek olan mesleki hastalıklarından biridir. KOAH'ın oluşmasında etkili olan sebepler arasında; havadaki zararlı gazlar, sigara dumanı, yetersiz egzersiz ve dengesiz beslenme mevcuttur [16]. KOAH'ın ülkemizde ve dünyada görülme sıklığı oldukça yüksektir.

Dünya genelinde 235 milyon üzeri insan KOAH'lıdır ve bunun 30 milyondan fazlası Avrupa'da görülmektedir [17]. Avrupa ülkelerinden biri olan Danimarka'da yaklaşık olarak 400 bin insan KOAH'a yakalanmıştır ve bunun 40 bini KOAH'tan ciddi anlamda etkilenmiştir [18]. Amerika'da 24 milyon insan bu hastalığa maruz kalmış olup KOAH'a yakalanan bireyler için harcanan para yıllık 38 milyar dolardır [15].

2.1. KOAH Nedenleri

KOAH oluşumuna neden olan başlıca faktörler şöyledir [19].

- Sigara kullanımı
- Toz ve duman
- Zararlı gazlara maruziyet
- İç ortam hava kirliliği
- Genetik

- Cinsiyet
- Yetersiz egzersiz

Toz, duman ve zararlı gazlara maruziyet, maden işçiliği, metal işçiliği, ulaşım sektörü, odun, kağıt üretiminde bulunan fabrikalarda çalışma, çimento, tahıl ve tekstil işçiliği gibi mesleklerde KOAH riski daha fazla görülmektedir. İç ortam hava kirliliği, ısınma veya pişirme amacıyla çalı, çırpı veya tezek yakmak ve bunların dumanına maruz kalmak KOAH oluşumuna neden olmaktadır. Hava kirliliği, son zamanlarda sanayileşmenin arttığı büyük kentlerde KOAH oluşumunu tetikler [19]. Aktif bir şekilde sigara kullanmak, KOAH oluşumu ve gelişimi için bilinen önemli risk faktörlerinden biridir. Sigaranın oluşturduğu etmenler, içilen sigara miktarı ve sigara içiciliğinin sürdürülmesi ile doğru orantılıdır. Solunum fonksiyon testi verileri değerlendirildiğinde, obstrüksiyon şiddeti fazla olan durumlarda, sigara oranı yüksektir [20].

2.2. KOAH Belirtileri

KOAH'ın başlıca belirtileri arasında; nefes darlığı, kronik öksürük ve balgam üretimi görülür [21].

Nefes darlığı, KOAH belirtilerinden biridir ve hareket ederken meydana gelir. Zaman geçtikçe, etkisi daha da artar. Nefes darlığı, başlangıçta koşarken, yürürken ya da merdivenlerden yukarı çıkarken ortaya çıkar fakat zaman içerisinde konuşma, giyinme hatta otururken bile hissedilecek hale gelir [19].

Kronik öksürük, KOAH'ın ilk belirtilerinden birisi olup, hastalar tarafından temel sebebinin sigara olduğu düşünülür ve pek ehemmiyet verilmez. Erken yaşlarda öksürük aralıklı periyotlar ile meydana gelse de ilerleyen zamanlarda gün boyunca sıklıkla oluşur [19]. Balgam başlangıçta sadece günün ilk ışıklarında meydana gelirken diğer dönemlerde günün tüm zamanlarında görülür. Sağlıklı bir bireyde balgam, krem-beyaz renklidir. Balgam miktarının artmasıyla birlikte renginin sarı veya yeşile dönüşmesi solunum yolu enfeksiyonu olduğunu gösterir [22].

2.3. KOAH Teşhisi

KOAH teşhisi, spirometre cihazı uygun bir şekilde kullanılarak solunum fonksiyon testinin yapılması ile gerçekleştirilir. KOAH teşhisine yardımcı diğer testler; kan oksijen derecesinin ölçümü, kan testleri, akciğer filmi ve egzersiz testleridir [3]. KOAH'ta evreleme, spirometrik olarak FEV1 ölçümüne göre yapılır. Şekil 1.2.'de gösterildiği gibi FEV1 değeri, beklenen değerden %80'den yüksek ise hafif KOAH, %50 - %80 değerleri arasında orta KOAH, %30 - %50 değerleri arasında ağır KOAH ve %30'un altında ise çok ağır KOAH olarak değerlendirilir. Hafif derecede KOAH yaşam kalitesini fazla etkilemeyebilir. Orta, ağır ve çok ağır KOAH vakalarında yakın takip ve tedavi gereklidir [22]. Ayrıca, Solunum Fonksiyon Testinden (SFT) sonra $FEV1 / FVC < 0,70$ oranı oluşuyorsa birey KOAH'lıdır [23].

Tablo 2.1. KOAH Şiddet Evreleme [24]

	Post Bronkodilatör FEV1	FEV1/FVC
Evre 1 (Hafif)	>%80	
Evre 2 (Orta)	>%50-80	<%70
Evre 3 (Ağır)	>%30-50	
Evre 4 (Çok ağır)	<%30 veya solunum yetmezliği	

2.4. Tedavi

KOAH gelişimine sebebiyet veren en önemli etkenlerden biri sigara olduğu için, tedavi sürecinde atılması gereken ilk adım, sigarayı bırakmak olacaktır. Çünkü sigaranın bırakılması ile birlikte kaliteli yaşam daha elverişli olacaktır. Ayrıca sigaranın bırakılması neticesinde KOAH ilerleme hızı düşecektir [3]. Sigarayı bırakmanın yanında dengeli beslenme, solunum sistemi enfeksiyonlarından kaçınma, düzenli egzersiz yapma gibi yaşam kalitesini arttıran faaliyetlerin tümü KOAH'ı önlemede yardımcı olduğu gibi KOAH'lı bireylerin yaşam fonksiyonlarını iyileştirmede faydası da olacaktır [25].

KOAH teşhisi konulan hastalara ve hasta yakınlarına, hastalık ile ilgili bilgi verilmeli, hastanın tedavi sürecine aktif olarak katılmasına teşvik edip olabildiğince

hareketli bir yaşam sürdürmesine yardımcı olunmalıdır. KOAH tedavisinde etkili olan yöntemlerden bir tanesi de stabil KOAH tedavisidir. Bu tedavinin amaçları arasında KOAH'ın ilerlemesini engelleme, egzersiz kapasite artırımı ve yaşam kalitesini geliştirme gibi durumlar söz konusudur [19].

2.4.1. İlaç tedavisi ve davranışsal değişiklikler

Doktorlar, KOAH tedavisinde, belirti ve semptomlar için birkaç tür ilaç kullanabilmektedirler. Bundan dolayı bazı ilaçlar düzenli, bazıları da ihtiyaç duyulduğunda kullanılmalıdır. Solunan steroidler, soluma yoluyla kullanılan kortikosteroid ilaçlar, hava yollarındaki iltihaplanmayı azaltabilmekte ve şiddetlenmeyi önleyebilmektedir. Bu gibi ilaçların yaralanma, ağız enfeksiyonları ve ses kısıklığı gibi yan etkileri olabilmektedir. Bu hastalık için kullanılan ilacın yan etkileri olmasına rağmen KOAH tedavisinde etkin olduğundan kullanılmaktadır.

İlaç tedavisinin birçok amacı vardır;

- Hastalığın ilerlemesini önleme
- Ölüm oranını azaltma
- Yaşam kalitesinin artırılması
- Egzersiz kapasitesinin artırılması
- Semptomların giderilmesi

Bu amaçları gerçekleştirebilmek için hasta düzenli olarak egzersiz yapmalı ve dengeli beslenmelidir. KOAH'ın hızını azaltmak için hastalığın şiddeti, komorbiditeler ve bireysel yanıtlar gibi faktörler göz önüne alınmalıdır.

KOAH'lı hastalarda kullanılan ilaçlar ya hava yolları ya da hava keseciklerinde (alveoller) etki gösterirler. Genel olarak iki tip ilaç kullanılmaktadır: Nefes açıcı olanlar (bronkodilatörler) ve havayollarında hastalığa neden olan iltihaplanmayı baskı altına alan ilaçlar (iltihap gidericiler). Bronkodilatörler, hava yolları etrafındaki kas tabakasını gevşeterek hava yollarının genişlemesini sağlarlar. Böylece nefes darlığı, hırıltı ve öksürük azalır. KOAH hava yollarında ve hava keseciklerinde

tahribata neden olup akciğer dokusunu bozan bir yangı ortaya çıkmasına sebebiyet vermiştir. Bu yangı, zamanla havayollarının yapısını bozar ve daralmasına neden olur. Bu gruptaki ilaçlar inhaler veya oral kortikosteroidler ve antibiyotiklerdir. Bu ilaçlar her hastada ve her zaman kullanılmamaktadır. Doktora danışılmadan kullanılmamalıdır [3].

2.4.2. Bronkodilatör cihaz tedavisi

Bronkodilatörler, bronşların düz kaslarını gevşetmek suretiyle hava yollarının direncini düşüren ilaçlardır. Kronik bronşit ve amfizem gibi akciğer hastalıkları, hava yollarının artmış olan direncini etkiler bu yüzden bronş ve alveollerin yapısında tıkanma meydana gelir.

KOAH için kullanılan bronkodilatör tedavisinin genel özellikleri şöyle gösterilebilir: Semptomatik tedavinin temelini bronkodilatörler oluşturur.

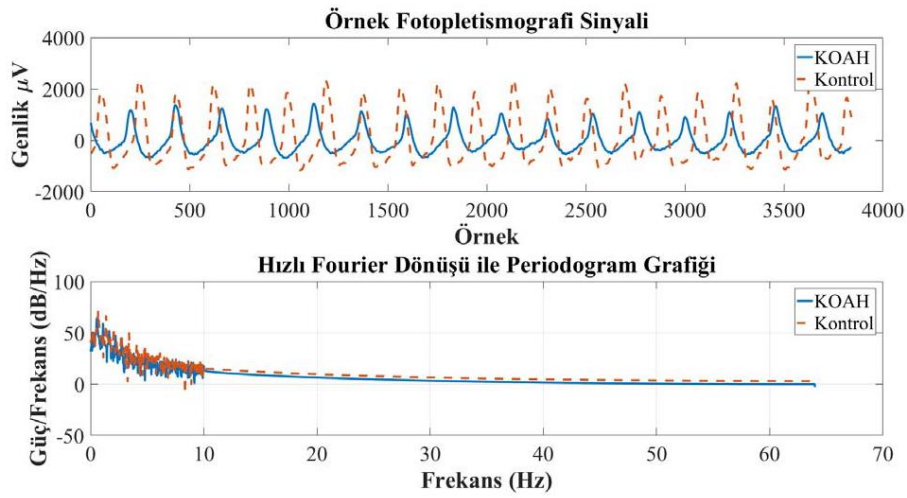
- Günümüzde kullanılan bronkodilatörler; antikolinergikler, β_2 agonistler ve teofilindir.
- İnhalasyon yolu tercih edilmelidir.
- Bronkodilatör seçiminde ve kombinasyonlarda bireysel yanıtlar, yan etkiler ve ilaçların bulunabilirliği önemlidir [26].

2.4.3. Cerrahi müdahale

Cerrahi müdahale, eğer kullanılan ilaçlar tek başına yeterli olmamış ve hastalık ciddi anlamda ilerlemiş ise, ameliyat başvurulması gereken önemli ve ciddi bir tedavi opsiyonu olmalıdır. Ameliyat tedavisi iki şekilde yapılır. Birincisi, zarar görmüş akciğer dokusunu ortadan kaldırarak akciğer hacim küçültme ameliyatı yapılır. İkincisi ise, organ nakli yapılarak bireyin eski sağlığına kavuşması sağlanır [3].

BÖLÜM 3. FOTOPLETİSMOGRAFİ SINYALİNİN İNCELENMESİ

PPG sinyali, vücudun deriye yakın herhangi bir bölgesinde akan kanın hacimsel değişimine bağlı olarak kan basıncı ile alakalı bilgi veren non-invaziv ve elektro-optik bir metottur. Bununla birlikte PPG sinyali, kalp atış hızını ölçmeye yarayan en önemli ve yaygın sinyallerden biridir. PPG, insan psikolojisi ve patolojik durumlar üzerinde kayda değer veriler sağlamada yardımcı olabilmektedir. Ayrıca PPG sinyali, analiz etme ve hastalıkları teşhis etmede kullanılır. PPG sinyali hem elde edilme kolaylığı hem de hastaya uygulanma kolaylığı sebebiyle ihtiyaç halinde medikal cihazlarda kolaylıkla ve ekonomik olarak görüntülenir [27], [28]. Genel olarak, insan vücudu periyodik aralıklarla gerçekleşen kalp atışları, dokulardaki kan akış hacmini değiştirir. Bu kan akışı, kırmızı ışığı yansıtan bir özelliğe sahiptir. PPG sensör tasarımının bir parçası olan LED, canlı dokuya ışık yaydığı anda kan akışından yansıyan veya iletilen ışığın yoğunluğu, kan hacmi değişimi hakkında bilgi verir. Ayrıca PPG sensör sistemi, kızılötesi sensörü aracılığıyla yansıtılan veya iletilen ışık yoğunluğunun değişimini belirleyerek atış hızını ölçer.



Şekil 3.1. Fotopletismografi sinyaline ait periodogram grafiği


Hasta ve Sağlıklı gruplar için PPG sinyalinin Hızlı Fourier Dönüşümü ile periodogram grafiği Şekil 3.1.'de verilmiştir. Grafik incelendiğinde PPG sinyalinin 0-10 Hz frekans bileşenleri için farklılıklar olduğu görülmektedir.

3.1. Fotopletismografi Sinyalinin Oluşumu ve Ölçülmesi

PPG, optik temelli, genellikle parmaktan ve kulak memesinden alınan bir sinyal olmak ile beraber, cilt yüzeyinin her noktasından ölçüm yapılabilen non-invaziv bir yöntemdir [29].

PPG, kalp aktivitesi sırasında kan akışındaki değişiklikler sebebiyle yansıyan ışıktan türetilen elektrik sinyalleridir. Bu sinyalleri tespit edebilmek için düşük yoğunluklu kızıl ötesi (IR) ışık kullanılır. Işık, biyolojik dokulara ulaştığında, kemik, cilt pigmentleri ve kan tarafından emilir. Işık çevredeki dokulara kıyasla kan tarafından daha fazla emildiklerinden, kan akışındaki değişiklikler, ışık yoğunluğundaki değişiklikler olarak PPG sensörleri tarafından tespit edilir [28].

PPG sinyali, damarlardan akan kan miktarıyla doğru orantılıdır. Aslında kan miktarını ölçmek için kullanılmayan bu yöntem, kan hacminde meydana gelen değişiklikleri belirlemede kullanılır [29].



Şekil 3.2. PPG çalışma mekanizması [30]

PPG, bir çubuk veya bir grafik yardımı ile dalga formu olarak gösterir. Dalga formu, Alternatif Akım (AC) bileşeni ve bir doğru akım (DC) bileşenine sahiptir. AC bileşeni, kalp atışıyla senkronize edilen kan hacmindeki değişiklikleri temsil eder. DC bileşen, dokular tarafından yansıtılan ve iletilen optik sinyallerden oluşur [29].


PPG ölçüm sisteminin tasarımı iki kısımdan oluşur. Işık göndermeye yarayan LED ve dokuların ışığı soğurmasından sonra kalan ışığı toplamak için tasarlanan fototransistörden oluşur. LED, ışığın parmağa doğru yayılmasını sağlar. Cilt pigmentleri, kan ve kemik ışığı soğurur. Damardaki kanın hacim ve yoğunluğu kalp atımlarına göre değiştiği, fototransistör üzerinde oluşan işaretin değişken bileşeni doğrudan damardaki kanın hacimsel değişimi ile orantılıdır. PPG ölçümü için tasarlanan sistem, Şekil 3.2.'de gösterilmiştir. Bu çalışmada PPG sinyalleri SOMNO Screen Plus marka cihazla kaydedilmiştir. Sinyalin örnekleme frekansı 256 Hz'dir.

3.2. Sayısal Filtreleme


Bu tez çalışmasında filtreleme işlemleri için MATLAB programının 'fdatool' aracı kullanılmıştır. PPG sinyali üzerinde oluşan gürültüyü temizlemek amacıyla tasarlanmış olup başarı ile uygulanmıştır. PPG sinyaline 0,1-20 Hz arası Chebyshev 2. Tipte bant geçiren filtre uygulanmış ve akabinde Kayan ortalama filtresinden istifade edilmiştir.

Filtreleme işleminde 0,1 Hz ile başlama sebebi, sinyal üzerinde bulunan DC bileşenleri temizlemektir. Matlab 'fdatool' aracı ile 7 adet IIR (sonsuz dürtü yanıtı) ve 11 adet FIR (sonlu dürtü yanıtı) olmak üzere toplamda 18 adet filtreleme yöntemi kullanılmaktadır. Bu yöntemler içerisinde Chebyshev 2. Tipte bant geçiren filtre tercih edilmiştir. Bu yöntemin tercih edilme sebepleri arasında geçiş bandının düz olması ile istenmeyen frekansları daha iyi bastırabilme özelliğine sahip olmasıdır.


Kayan ortalama filtresi, sinyal içerisinde bulunan küçük değişimlerin temizlenmesi ve bu sayede işaretin yumuşatılması için kullanılan filtredir. Tepe noktaları bulunurken, işaret üzerindeki küçük genlik / yüksek frekanslı bileşenler, yerel maksimum ve minimumlar oluşturur. Bu durum tepe bulma algoritmalarının başarımını düşürür. Bunu önlemek için Kayan ortalama filtresi kullanılmıştır [31].



Şekil 3.3. Filtrelenmemiş PPG Sinyali



Şekil 3.4. Bant geçiren filtre uygulanmış PPG Sinyali



Şekil 3.5. Bant geçiren ve Kayan ortalama filtreleri uygulanmış PPG Sinyali

3.3.Özellik Çıkarma

Özellik çıkarımı bir boyut azalımı olarak düşünülebilir. Yani kompleks olan bir verinin boyutları azaltılarak daha basit bir problem haline getirme durumudur. PPG sinyalinden elde edilecek olan özellikler KOAH teşhisi için kullanılacaktır. PPG sinyal kayıtları, 8 KOAH'lı ve 6'sı Sağlıklı grubu olmak üzere toplamda 14 bireyden elde edilmiştir. Kayıt süresi 15 saniye olarak belirlenmiştir. PPG sinyalinden zaman domeninde toplamda 26 adet özellik çıkarımı yapılmıştır.

PPG sinyalinden özellik çıkarım akış diyagramı Şekil 3.6.'da ayrıntılı bir şekilde gösterilmiştir. Bu akış diyagramına bakıldığında, ilk yapılması gereken şey PPG sinyalinin yerel maksimum ve yerel minimum noktalarını bulmak olacaktır. Bu noktalara göre sinyal periyotlara ayrılır. Sinyalin yerel minimum noktaları

periyotların başlangıç ve bitiş noktaları olarak kabul edilecektir. Sinyalin periyot sayısı T, yerel minimum noktası LOCMIN olarak adlandırılır.



Şekil 3.6. PPG sinyalinden özellik çıkarım akış diyagramı

3.4. Fotopletismografi Sinyalinin Karakteristik Özellikleri

Literatür taraması yapıldığında PPG sinyalinden çıkartılan pek çok farklı özellik mevcuttur. Bunlara karakteristik özellik denir. Tez çalışmasında PPG sinyalinden zaman domeninde toplamda 26 adet özellik çıkartılmıştır. Bu özellikler Tablo 3.1.'de gösterilmiştir. Bu tabloda formül, özellik adı ve özellik numarası olmak üzere toplamda 3 adet parametre sütunda gösterilmiştir. gösterilmiştir. Formülde yer alan x, biyomedikal sinyali göstermektedir.

Tablo 3.1. PPG sinyali için istatistiksel zaman domeni özellikleri

Sıra	Özellik Adı	Formül
1	Ortalama	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} (x_1 + \dots + x_n)$
2	Standart Sapma	$S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$
3	Varyans	$V = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$
4	Hjort Parametresi-Aktivite	$A = S^2$
5	* Maksimum	$x_{max} = \max(x_i)$
6	* Minimum	$x_{min} = \min(x_i)$

Tablo 3.1. (Devamı)

7	Medyan	$\tilde{x} = \begin{cases} \frac{x_{n+1}}{2} & : x \text{ tek} \\ \frac{1}{2}(x_{\frac{n}{2}} + x_{\frac{n}{2}+1}) & : x \text{ çift} \end{cases}$
8	Geometrik Ortalama	$G = \sqrt[n]{x_1 \times \dots \times x_n}$
9	Harmonik Ortalama	$H = n / \left(\frac{1}{x_1} + \dots + \frac{1}{x_n} \right)$
10	Ortalama Karekök Değeri	$X_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i ^2}$
11	Çarpıklık	$x_{ske} = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)S^3}$
12	Basıklık(Kurtosis)	$x_{kur} = \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{(n-1)S^4}$
13	* Tekil Değer Ayrışımı	$SVD = svd(x)$
14	* %25 Kırpılmış Ortalama	$T25 = trimmean(x, 25)$
15	* %50 Kırpılmış Ortalama	$T50 = trimmean(x, 50)$
16	Şekil Faktörü	$SF = X_{rms} / \left(\frac{1}{n} \sum_{i=1}^n \sqrt{ x_i } \right)$
17	Ortalama Enerji	$E = \frac{1}{n} \sum_{i=1}^n x_i^2$
18	Hjort Parametresi-Hareketlilik	$M = S_1^2 / S^2$
19	Hjort Parametresi –Karmaşıklık	$C = \sqrt{(S_2^2 / S_1^2)^2 - (S_1^2 / S^2)^2}$
21	* Ortalama ya da Medyan Mutlak Sapma	$MAD = mad(x)$
22	* Moment, Merkezi Moment	$CM = moment(x, 10)$
23	Ortalama Eğri Uzunluğu	$CL = \frac{1}{n} \sum_{i=2}^n x_i - x_{i-1} $
24	Ortalama Teager Enerji	$TE = \frac{1}{n} \sum_{i=3}^n (x_{i-1}^2 - x_i x_{i-2})$
25	Değişim Katsayısı	$DK = (S / \bar{x})100$
26	Standart Hata	$S_{\bar{x}} = S / \sqrt{n}$

* işaretli özellikler hazır MATLAB kodları ile oluşturulmuştur.

BÖLÜM 4. KULLANILAN VERİ KÜMESİ

Bu kısımda tezde kullanılan veri seti, hastalara ait olan demografik bilgiler anlatılacaktır.

4.1. Verilerin Toplanması

Çalışmada kullanılan veriler, Sakarya Hendek Devlet hastanesi Göğüs Hastalıkları Uyku Laboratuvarında oluşturulmuştur. Bu veriler SOMNOscreen Plus PSG cihazından elde edilmiştir. Ayrıca bu veriler için Sakarya Üniversitesi Tıp Fakültesi Dekanlığından 1614662/0.50.01.04/70 sayılı etik kurulu raporu ve T.C. Sağlık Bakanlığı ve Türkiye Kamu Hastaneleri Kurumu Sakarya İli Kamu Hastaneleri Birliği Genel Sekreterliğinden 94556916/904/151.5825 sayılı veri kullanım izni alınmıştır.

Elde edilen veriler, bütün gece süresince SOMNOscreen Plus PSG cihazı ile kayıt altına alınmıştır. Çalışma, PPG sinyali kullanılarak yapılmıştır. Veriler elde edilirken, hastanın rahat bir şekilde uyuyabileceği bir ortam sağlanmıştır. Hastalardan veri elde edimi sırasında; hastalar yaklaşık olarak 8 saat boyunca uyumuşlardır. Uygun ortamda elde edilen verilerin 8'i KOAH'lı ve diğer 6'sı Sağlıklı bireyler olmak üzere toplamda 14 bireyden veri alınmıştır.

Bireylere ait demografik bilgiler Tablo 4.1.'de gösterildiği gibi Tablo 4.2.'de ort \pm std (ort Ortalama, std Standart Sapma) şeklinde verilmiştir. Tabloya göre 'Fotopletismografi Kayıt Dağılımları' kısmında hasta ve sağlıklı gruplarına ait bilgiler yer almaktadır. Çalışmada 8 erkek hastaya karşılık olarak 6 Sağlıklı grubunda 2 kadın ve 4 erkek birey kaydı alınmıştır. Her bireyin kaydı 15 saniyelik parçalara (epoklara) ayrılmıştır. Her epokta hasta ya da sağlıklı etiketi vardır. Bu

işlem neticesinde KOAH grubuna ait 14960, Sağlıklı gruba ait 12484 epok oluşturulmuştur.

Tablo 4.1. Bireylere ait demografik bilgiler

	Cinsiyet	Yaş (Yıl)	Ağırlık (kg)	Boy (cm)	Vücut Kitle İndeksi (kg/m ²)	KOAH Grubu	Sağlıklı Grubu
1	Erkek	60	105	172	35,5	1910	0
2	Erkek	53	110	170	38,1	2962	0
3	Erkek	65	106	175	34,6	300	0
4	Erkek	35	117	189	32,8	2164	0
5	Erkek	57	100	170	34,6	2090	0
6	Erkek	48	107	170	37	1924	0
7	Erkek	70	99	173	33,1	1746	0
8	Erkek	44	97	180	29,9	0	2302
9	Erkek	52	85	162	30,4	0	2062
10	Erkek	51	100	172	33,8	0	2062
11	Erkek	47	102	172	34,5	0	1502
12	Erkek	56	95	176	30,7	1864	0
13	Kadın	52	110	165	40,4	0	2586
14	Kadın	59	101	175	33	0	1970

Tablo 4.2.'de bireylere ait demografik bilgilerin standart sapma ve ortalama cinsinden (ort \pm std) gösterimi yer almaktadır. Bu tabloya göre 2 kadın ve 12 erkek olmak üzere toplamda 14 adet birey mevcuttur.

Tablo 4.1.'de verilenlere göre; 40 yaş altı sadece bir birey mevcuttur. Ağırlık değerlerine bakıldığında en fazla 117 kg ve en az 85 kg vardır. Boy parametresi değerlendirildiğinde ise, minimum 162 cm ve maksimum 189 cm olarak kayıt altına alınmıştır.

Bu tabloda yer alan vücut kitle indeksi KOAH teşhisinde ekili olan parametrelerden biridir. Tabloda verilen değerler göz önüne alındığında en düşük değer 29,9 ve yüksek değer ise 40,4 olarak yer kaydedilmiştir.

Tablo 4.2. Bireylere ait demografik bilgilerin standart sapma ve ortalama cinsinden (ort \pm std) gösterilmesi

Bilgiler	Erkek		Kadın		Tüm Bireyler	
	n ₁ =12		n ₂ =2		n=n ₁ +n ₂ =14	
	std	ort	std	ort	std	ort
Yaş (Yıl)	9,42	53,16	4,94	55,5	8,82	53,5
Ağırlık (kg)	8,08	101,91	6,36	105,5	7,75	102,42
Boy(cm)	6,51	173,41	7,07	170	6,42	172,92
Vücut Kitle İndeksi (kg/m ²)	2,54	33,75	5,23	36,7	2,95	34,17

std: standart sapma, ort: ortalama

BÖLÜM 5. SINIFLANDIRMA ALGORİTMALARI

Tez çalışması kapsamında, verileri işleyebilmek için çeşitli yöntemler kullanılmıştır. Sınıflandırma için kNN, PNN ve SVMs olmak üzere toplamda 3 farklı sınıflandırıcı kullanılmıştır.

5.1. Sınıflandırma Algoritmaları

Sınıflandırma, farklı grupları veya verileri belirli özelliklere göre birbirinden ayırmak için kullanılır [32]. Mevcut halde sınıflandırma, regresyon, optimizasyon ve kümeleme gibi makine öğrenmesi metotlarında kullanılır. Bu tez çalışmasında sınıflandırma modellerinden detaylı bir şekilde bahsedilecektir.

Temelde bu çalışmanın amacı sisteme aktarılan verilere göre dışardan herhangi bir bireyin KOAH'lı olup olmadığını belirleyebilmektir.

5.2.1. k- en yakın komşu algoritması

Bu tez çalışmasının hedefleri arasında; KNN yöntemini kullanarak erken teşhis ve doğruluk yüzdesini artırma gibi etkenler mevcuttur. k en yakın komşuluk algoritması birçok sınıflandırma durumlarında sade fakat elverişli bir sonuç sunmaktadır [33]. Bu çalışmada, KOAH'lı ve Sağlıklı gruplarına ait PPG sinyallerinden zaman ekseninde 26 adet özellik çıkartılmıştır. Çıkartılan özellikler kNN ile sınıflandırılmış olup doğruluk oranı, duyarlılık, özgüllük ve F-ölçümü gibi performans değerlendirme kriterleri ile test edilmiştir.

kNN birçok sınıflandırma sorunlarını çözen denetimli öğrenme metotlarından birisidir. Sınıflandırma yapılacak eğitim verileri ile test edilecek olan verilerin

sonuçları karşılaştırma yapılarak, en yakın olduğu görülen k verinin ortalamasıyla, saptanan eşik değere göre sınıflara atamaları yapılır. k en yakın komşu sayısı, eşik değeri ve benzerlik ölçümü gibi parametreler yöntemin performansını önemli derecede etkiler [34].

Tablo 5.2.'de kNN yöntemi için kullanılabilir parametreler gösterilmiştir.

Tablo 5.1. kNN için kullanılabilir parametreler

Uzaklık Hesaplama Metodu	k
Chebychev	1
Cityblock	2
Correlation	3
Cosine	4
Euclidean	5
Hamming	6
Jaccard	7
Mahalanobis	8
Minkowski	9
Seuclidean	10

5.2.2. Olasılıksal yapay sinir ağları

En temel biyolojik sinir ağlarından hareketle verileri işlemek için belli sayıda yapay sinir hücresinin bir araya getirilmesiyle oluşturulan mimariye yapay sinir ağı denir.

Başka bir tanımlamaya göre, yapay sinir ağları insan beyninden ilham alınarak geliştirilmiş, her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapıları; başka bir deyişle, biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır.

PNN, ilk defa 1988 yılında Donald F. Specht tarafından geliştirildi. 1990'lı yıllarda yapay sinir ağları teknolojisi gün geçtikçe gelişmiş ve çok büyük derecede ilerleme kaydetmiştir [35].

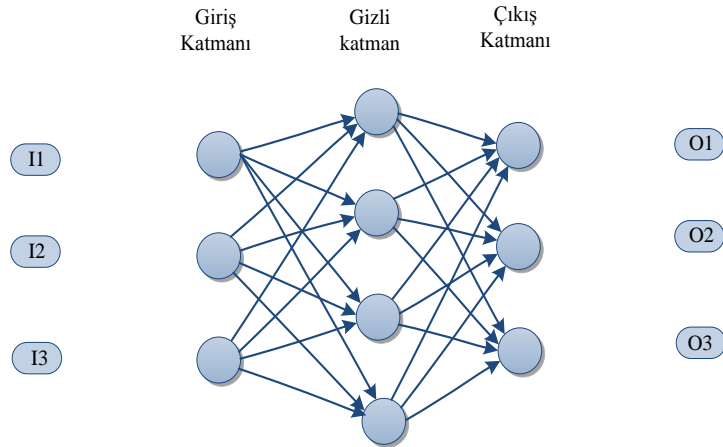
Olasılıksal yapay sinir ağları, radyal temeline dayanan bir çeşit sinir ağıdır. Ayrıca bu yöntemin hızlı çalışması, yüksek kararlılık ve iyi teşhis etme gibi özelliklere sahiptir. Bu makine öğrenmesi modeli danışmanlı öğrenme grubuna girer [36]. PNN, bayesian veya kernel analizine dayanan çok katmanlı ileri beslemeli ağlara göre

tasarlanmış olup sınıflandırma problemleri için genel çözüm üreten bir sınıflandırma algoritmasıdır. Yapay sinir ağları yüksek hız yakınsama, kısa sürede eğitim ve sınıflandırma doğruluk oranı gibi avantajlı özelliklere sahiptir [37].

Yapay sinir ağlarını birbirine bağlayan bağlantıların değerlerine ağırlık değerleri denir. İşlem elemanları birbirine paralel olarak 3 katman halinde bir araya gelerek bir ağ oluştururlar. Bu elemanlar şunlardır;

- Giriş katmanı
- Gizli(Ara) katmanlar
- Çıkış katmanı

Bilgiler ağa giriş katmanından iletilir. Ara katmanlarda işlenerek oradan çıkış katmanına gönderilir. Ağın girişler için doğru çıkışları üretebilmesi için ağırlıkların doğru değerlerinin olması gerekmektedir. Doğru ağırlıkların bulunması işlemine ağın eğitilmesi denilir. Bu değerler başlangıçta rastgele atanırlar. Daha sonra eğitim sırasında her örnek ağa gösterildiğinde, ağın öğrenme kuralına göre ağırlıklar değiştirilir. Daha sonra başka bir örnek ağa sunularak ağırlıklar yine değiştirilir ve en doğru değerler bulunmaya çalışılır. Bu işlemler, ağ eğitim setindeki örneklerin tamamı için doğru çıkışlar üretinceye kadar tekrarlanır. Bu sağlandıktan sonra test setindeki örnekler ağa gösterilir. Eğer ağ test setindeki örneklere doğru cevaplar verirse ağ eğitilmiş kabul edilir [35].




Şekil 5.1. PNN için genel ağ yapısı

5.2.3. Destek vektör makineleri

SVMs gözetimli öğrenme algoritmaları arasında en iyilerinden biridir [14], [38]. 1995 yılında Cortes ve Vapnik tarafından önerilmiştir ve bu metot binary sınıflandırma algoritmasıdır [39]. SVMs sınıflandırma problemlerinin yanı sıra regresyon analizlerinde de etkin bir şekilde kullanılır.

SVMs, iki sınıfı yani lineer ve non-lineer hatlarla özellikleri birbirinden ayırmaya çalışır. Şekilde gösterildiği gibi (a) lineer ve (b) lineer olmayan olarak gruplara ayrılmıştır.



Şekil 5.2. Sınıfların (a) lineer ve (b) lineer olmayan doğrularla ayrılması [30]

SVMs sınıflandırma işlemleri için bir eğitim algoritmasıdır. Algoritmanın amacı, hiperdüzlem üzerinde veri kümelerini en uygun şekilde birbirinden ayırabilmek ve yeni verileri minimum hata oranıyla sınıflandırabilmektir [40]. Hiperdüzleme en yakın öğrenme verileri destek vektörleri olarak adlandırılır. Destek vektörleri arasındaki uzaklığın maksimum olduğu yer tespit edilir ve araya bir eğri uydurulur. Bu eğri, veri kümesini ikiye ayıran genelleştirilmiş çözüm olarak kabul edilir [41].

5.3. Performans Değerlendirme Kriterleri

Tezde kullanılan sistemlerin doğruluk oranlarının test edilmesi için farklı performans değerlendirme ölçütleri kullanılmıştır. Bunlar;

- Doğruluk oranı (accuracy rates)
- Duyarlılık (sensitivity)
- Özgüllük (specificity)
- F-ölçümü (F-measurement)

Yukarıda listelenen performans değerlendirme kriterleri aşağıda detaylı bir şekilde izah edilmiştir.

Tablo 5.2. Eğitim ve test aşamalarında veri dağılımı

Sınıf (%)	KOAH Grubu (%)	Sağlıklı Grubu (%)
Eğitim (50)	7480 (50)	6242 (50)
Test (50)	7480 (50)	6242 (50)
Toplam (100)	14960 (100)	12484 (100)

Tablo 5.2.'de verilen değerler sistemin eğitim ve test aşamalarındaki veri dağılımıdır. Tabloya göre, KOAH grubu için eğitim 7480 epok ve test için 7480 epok elde edilmiştir. Toplamda 14960 epok kaydedilmiştir. Sağlıklı grubu için ise; 6242 epok eğitim kısmında 6242 epok test kısmında kullanılmıştır. Toplamda her iki bölümden 12484 epok kayıt altına alınmıştır.

5.3.1. Karışıklık matrisi, doğruluk, duyarlılık, özgüllük ve f-ölçümü

Bu tez çalışmasında sistemin performansını değerlendirmek amacı ile test setinde sınıfların doğruluk oranları, her yöntem için duyarlılık, özgüllük değerleri hesaplanmış olup bunlara ek olarak F-ölçümü parametresi de hesaplanmıştır.

Duyarlılık, hastalar içinde testin, hastaları ayırma yeteneğidir. 0 ile 1 arasında değer alır. Teşhis amaçlı bir testin duyarlılık değerinin 1 olması istenir. Herhangi bir testin duyarlılık değerinin 1 olması demek, testin bütün hastaları doğru olarak teşhis edebildiğini gösterir. Özgüllük ise, testin sağlıklı bireyleri ayırt edebilme özelliğidir. Duyarlılık gibi, 0 ile 1 arasında değişir. Bir testin özgüllük değerinin 1 olması, o testin tüm sağlıklı bireyleri doğru olarak saptandığını gösterir.

Duyarlılık ve özgüllük parametreleri Denklem 5.2 ve 5.3'teki gibi hesaplanmıştır. Çalışmada doğruluk oranları ise Denklem 5.1'teki gibi gösterilmiştir. Denklem 5.1, 5.2 ve 5.3'de yer alan TP, TN, FP ve FN sırasıyla Gerçek Pozitif (True Positive, TP), Gerçek Negatif (True Negative, TN), Yanlış Pozitif (False Positive, FP) ve Yanlış Negatif (False Negative, FN) olmak üzere 4 adettir. Ayrıca Tablo 5.3.'de doğruluk ve duyarlılık için karşılaştırma matrisi verilmiştir.

Tablo 5.3. Doğruluk, özgüllük ve duyarlılık için karşılaştırma matrisi

		Tahmin Edilen	
		P	N
Gerçek Durum	P	TP	FN
	N	FP	TN

$$Doğruluk = \frac{TP + TN}{TP + TN + FN + FP} \times 100 \quad (5.1)$$

$$Duyarlılık = \frac{TP}{TP + FN} \times 100 \quad (5.2)$$

$$Özgüllük = \frac{TN}{FP + TN} \times 100 \quad (5.3)$$

F-ölçümü, oluşturulan modelin etkinliğini belirlemek amacıyla kullanılır. Elde edilen değer, duyarlılık ve özgüllük değerlerinin ağırlıklı ortalamasıdır. F-ölçümü Denklem 5.4'deki gibi hesaplanabilir. 0 ile 1 arasında değişen değerler alır. 1 tasarlanan modelin mükemmel olduğunu, 0 ise kötü olduğunu belirtir.

$$F = 2 \times \frac{\text{Özgüllük} \times \text{Duyarlılık}}{\text{Özgüllük} + \text{Duyarlılık}} \quad (5.4)$$

BÖLÜM 6. SONUÇLAR

Bu bölümde tezde kullanılan metotlardan elde edilen sonuçlar sunulmuştur. Tez çalışmasında KOAH teşhisi için kullanılabilecek, mevcut bir sisteme alternatif yeni bir yaklaşım geliştirilmiştir.

KOAH teşhisi için yapılan işlemler Şekil 1.1.'deki akış diyagramına göre yapılmış ve sonuçlar elde edilmiştir. Ham olarak elde edilen veriler, sayısal filtrelerden geçirilmiştir. Akabinde PPG sinyalinde elde edilen özellikler kaydedilmiş olup sınıflandırma yöntemleri kullanılarak KOAH teşhisinde yardımcı olmuştur. Sırası ile kNN, PNN ve SVMs algoritmik yöntemlerden elde edilen sonuçlar aşağıdaki gibi gösterilmiştir.

Bu tez kapsamında KOAH teşhisi için kullanılan makine öğrenme metotlarından biri kNN 'dir. kNN yöntemi ile sınıflandırma sonuçları Tablo 6.1.'deki gibi verilmiştir. Tabloda gösterildiği gibi çeşitli uzaklık hesaplama metotları kullanılmıştır. 10 adet k sayısı ve 10 adet uzaklık hesaplama yöntemi kullanıldığından toplam 100 adet varyasyon bulunmaktadır. k en yakın komşu sayısı arttıkça verim dolayısıyla performans ölçme parametre değerleri düşmektedir. k = 3 ve 5 olduğunda uzaklık mesafesi olarak cityblock kullanıldığında doğruluk oranı 93,20 ve 90,96 olarak elde edilmiştir. Ya da k = 4 ve 9 olduğunda uzaklık mesafesi olarak da correlation kullanıldığında doğruluk oranı 89,64 ve 85,99 olarak bulunur.

Tablo sonucuna bakıldığında k = 3 ve 7 olduğunda uzaklık mesafesi olarak da cityblock kullanıldığında duyarlılığın 0,91 ve 0,90 olduğunu görmüş oluruz. Ya da k = 4 ve 10 olarak alınırsa uzaklık mesafesi de minkowski kullanılırsa duyarlılık oranı 0,95 ve 0,91 gibi yüksek değerlere sahip olduğu görülür. Bu uzaklık

parametrelerinde olduđu gibi diđer bütun uzaklık hesaplama metotlarında da aynı deđerlendirmeler söz konusudur.

F-ölçümü ve özgülük performans deđerlendirme parametreleri için elde edilen sonuçlar Tablo 6.1.'de gösterilmiştir. Her iki parametreden de yüksek oranda verim elde edilmiş olup, k en yakın komşu sayısının artmasıyla verimin düştüğü gözlenmiştir.

Bu tez çalışmasına göre PPG sinyalinin KOAH teşhisinde kullanılabilir bir sinyal olduđu görüşüne varılmıştır. Elde edilen verimin oldukça yüksek olması kNN sınıflandırma yönteminin KOAH teşhisinde kullanılabilirliğini göstermektedir. Tüm bu sonuçlar ışığında, elde edilmesi kolay bir işaret olan PPG işaretinin makine öğrenmesi algoritmaları ile deđerlendirilmesiyle, hastalığın daha erken teşhisinin mümkün olduđu ispatlamıştır.

Tablo 6.1. kNN sonuçlar

k	Uzaklık No	Doğruluk	Duyarlılık	Özgüllük	F-Ölçümü	k	Uzaklık No	Doğruluk	Duyarlılık	Özgüllük	F-Ölçümü
1	1	100,00	1,00	1,00	1,00	1	6	100,00	1,00	1,00	1,00
2	1	95,37	1,00	0,90	0,95	2	6	95,15	1,00	0,89	0,94
3	1	93,2	0,91	0,95	0,93	3	6	92,45	0,91	0,95	0,93
4	1	91,05	0,96	0,86	0,90	4	6	90,11	0,95	0,84	0,89
5	1	90,95	0,91	0,90	0,91	5	6	89,92	0,90	0,90	0,90
6	1	90,46	0,93	0,87	0,90	6	6	89,25	0,93	0,85	0,89
7	1	89,84	0,90	0,90	0,90	7	6	88,69	0,88	0,89	0,89
8	1	89,51	0,92	0,86	0,89	8	6	88,17	0,92	0,84	0,88
9	1	89,33	0,89	0,89	0,89	9	6	87,83	0,88	0,87	0,88
10	1	89,19	0,91	0,87	0,89	10	6	87,62	0,91	0,84	0,87
1	2	100,00	1,00	1,00	1,00	1	7	100,00	1,00	1,00	1,00
2	2	95,15	1,00	0,89	0,94	2	7	70,21	1,00	0,34	0,51
3	2	92,45	0,91	0,95	0,93	3	7	70,20	0,99	0,35	0,52
4	2	90,11	0,95	0,84	0,89	4	7	55,85	1,00	0,03	0,06
5	2	89,92	0,90	0,89	0,90	5	7	56,34	0,99	0,05	0,10
6	2	89,25	0,93	0,85	0,89	6	7	55,72	0,99	0,03	0,07
7	2	88,69	0,88	0,89	0,89	7	7	56,13	0,99	0,05	0,10
8	2	88,17	0,92	0,84	0,88	8	7	55,75	0,99	0,03	0,07
9	2	87,83	0,88	0,87	0,88	9	7	55,96	0,98	0,05	0,10
10	2	87,62	0,91	0,84	0,87	10	7	55,61	0,99	0,03	0,07
1	3	100,00	1,00	1,00	1,00	1	8	100,00	1,00	1,00	1,00
2	3	94,19	1,00	0,87	0,93	2	8	70,21	1,00	0,34	0,51
3	3	91,42	0,89	0,94	0,92	3	8	70,2	0,99	0,35	0,52
4	3	88,31	0,95	0,81	0,87	4	8	55,85	1,00	0,03	0,06
5	3	88,45	0,89	0,88	0,88	5	8	56,34	0,99	0,05	0,10
6	3	87,58	0,91	0,83	0,87	6	8	55,72	0,99	0,03	0,06
7	3	86,76	0,86	0,87	0,87	7	8	56,13	0,99	0,05	0,10
8	3	85,98	0,90	0,81	0,85	8	8	55,75	0,99	0,03	0,07
9	3	85,22	0,86	0,84	0,85	9	8	55,96	0,98	0,05	0,10
10	3	85,12	0,88	0,81	0,85	10	8	55,61	0,99	0,03	0,07
1	4	100,00	1,00	1,00	1,00	1	9	100,00	1,00	1,00	1,00

Tablo 6.1. (Devamı)

k	Uzaklık No	Doğruluk	Duyarlılık	Özgüllük	F-Ölçümü	k	Uzaklık No	Doğruluk	Duyarlılık	Özgüllük	F-Ölçümü
2	4	94,83	1,00	0,89	0,94	2	9	95,15	1,00	0,89	0,94
3	4	91,43	0,89	0,95	0,92	3	9	92,45	0,91	0,95	0,93
4	4	89,63	0,94	0,85	0,89	4	9	90,11	0,95	0,84	0,89
5	4	88,64	0,88	0,90	0,89	5	9	89,92	0,90	0,89	0,90
6	4	88,33	0,90	0,86	0,88	6	9	89,25	0,93	0,85	0,89
7	4	87,5	0,85	0,90	0,88	7	9	88,69	0,88	0,89	0,89
8	4	86,67	0,89	0,84	0,86	8	9	88,17	0,92	0,84	0,88
9	4	85,98	0,85	0,87	0,86	9	9	87,83	0,88	0,87	0,88
10	4	85,97	0,87	0,85	0,86	10	9	87,62	0,91	0,84	0,87
1	5	100,00	1,00	1,00	1,00	1	10	99,3	1,00	0,98	0,99
2	5	94,92	1,00	0,89	0,94	2	10	93,35	1,00	0,85	0,92
3	5	91,61	0,89	0,95	0,92	3	10	90,67	0,89	0,93	0,91
4	5	89,62	0,94	0,85	0,89	4	10	87,70	0,93	0,81	0,87
5	5	88,50	0,88	0,90	0,89	5	10	87,18	0,87	0,88	0,87
6	5	88,00	0,90	0,86	0,88	6	10	86,58	0,89	0,83	0,86
7	5	87,09	0,85	0,90	0,87	7	10	85,94	0,84	0,88	0,86
8	5	86,50	0,88	0,84	0,86	8	10	85,32	0,88	0,83	0,85
9	5	86,03	0,85	0,88	0,86	9	10	84,78	0,83	0,86	0,85
10	5	85,84	0,87	0,85	0,86	10	10	84,71	0,86	0,83	0,85

Tezde kullanılan diğ er bir sınıflandırıcı PNN'dir. Bu metodun sonuçları Tablo 6.2.'de gösterilmiştir. PNN, KOAH teşhisinde kullanılan en etkili ve yararlı modellerden biri olduğu elde edilen sonuçlardan belli olmuştur. Metotta kullanılan performans değerlendirme parametreleri sırası ile doğruluk oranı, duyarlılık, özgüllük ve F-ölçümü olarak gösterilmiştir.

Çalışmada spread başlangıç parametresi kullanılmıştır. Spread parametresi sıfıra yaklaştıkça ağ en yakın komşu sınıflandırıcı olarak işlev görür. Spread parametresi sıfırdan uzaklaştıkça tasarlanan ağ, verileri birbirinden ayıran birkaç tasarım vektörünü dikkate alır.

Sonuçlara bakıldığında, her parametreden elde edilen netice %100 olarak kaydedilmiştir. Bu durum da şunu gösteriyor ki, mevcut veriler ve kullanılan yöntem KOAH teşhisinde çok etkili olduğu sonucuna varılmıştır. Ancak bu yöntemin etkinliğinin farklı hastalardan alınacak veriler için de geçerli olacağı doğrulanmalıdır.

Tablo 6.2. PNN sonuçlar

Spread	SE				ST			
	DO	DU	OZ	FO	DO	DU	OZ	FO
0,1	100	1	1	1	100	1	1	1
0,2	100	1	1	1	100	1	1	1
0,3	100	1	1	1	100	1	1	1
0,5	100	1	1	1	100	1	1	1
1	100	1	1	1	100	1	1	1
2	100	1	1	1	100	1	1	1
3	100	1	1	1	100	1	1	1
4	100	1	1	1	100	1	1	1
5	100	1	1	1	100	1	1	1

DO: Doğruluk DU: Duyarlılık OZ: Özgüllük FO: F-Ölçümü

Tezde kullanılan üçüncü sınıflandırıcı SVMs'dir. Bu modelin sonuçları Tablo 6.3.'de gösterilmiştir. Tabloda da görüldüğü gibi test sonuçları oldukça yüksek değer ile sonuçlanmıştır. Her dört parametre için eğitim sonuçları %94,59 olup test sonuçları %79'un altında değildir. Ayrıca eğitim ve test başarı oranları %85 oranının altına inmemiştir.

Tezde kullanılan fraksiyon dış çizgi parametresi hat derecesini belirler. Yani destek vektör oranının margine olan uzaklığının oranıdır. Bu parametrenin değeri arttıkça elde edilen doğruluk oranı azalır.

Her dört parametreden elde edilen sonuçlar gösteriyor ki, SVMs, KOAH teşhisinde oldukça etkili ve verimli bir makine öğrenmesi modelidir.

Tablo 6.3. SVMs sonuçlar

Outliner Fraction	DO	DU	OZ	FO		DO	DU	OZ	FO		EBO	TBO
0,01	95,06	0,95	0,95	0,95		85,90	0,91	0,78	0,84		95,06	85,90
0,04	94,62	0,94	0,94	0,94		86,09	0,91	0,79	0,85		94,62	86,96
0,05	94,59	0,94	0,94	0,94		85,96	0,91	0,79	0,84		94,59	85,96
0,1	93,93	0,93	0,93	0,93		85,86	0,91	0,79	0,84		93,93	85,86
0,2	92,60	0,92	0,92	0,92		85,56	0,90	0,79	0,84		92,60	85,56
0,9	73,72	0,68	0,79	0,73		70,39	0,68	0,72	0,70		73,72	70,39

SE: Eğitim sonuçları ST: Test Sonuçları EBO: Eğitim başarı oranı TBO: Test başarı oranı

BÖLÜM 7. TARTIŞMA

Bu çalışmada, PPG sinyallerinden elde edilen veriler bant geçiren ve Kayan ortalama filtrelerinden geçirilerek daha gürültüsüz veriler elde edilmiştir. Ondan sonra verilerden özellik çıkarımı yapıp makine öğrenmesi metotları kullanılarak sınıflandırma başarı ile gerçekleştirilmiştir. Bu sınıflandırmadan yüksek oranda sonuçlar elde edilmiştir.

Normalde KOAH teşhisi için spirometre cihazı kullanılmakta ve değerlendirme bundan gelen sonuca göre yapılmaktadır. Bu çalışmada spirometre cihazına göre daha ucuz, hastaya uygulanması daha kolay ve daha yaygın olarak bulunan PPG sinyali kullanımı ile KOAH teşhisi yapılabileceği gösterilmiştir.

PPG sinyalinden çıkarılan özelliklerin sınıflandırılmasının amacı, KOAH teşhisini en güvenilir ve en verimli yöntemle tespit etmeye çalışmaktır. Bundan dolayı Tablo 6.1.'de kNN sonuçları gösterildiği gibi Tablo 6.2.'de ve Tablo 6.3.'te PNN ve SVMs sonuçları gösterilmiştir. Bu tablolardaki sınıflandırma parametrelerine bakılarak hangi yöntemin daha güvenilir ve kullanılabilir olduğuna karar verilir.

Literatür taraması yapıldığında, sistemin performansını değerlendirmek ve ölçme yapmak amacıyla birçok yöntem kullanıldığını görmek zor olmayacaktır. Doğruluk, duyarlılık, özgüllük ve F-ölçümü oldukça yaygın olan değerlendirme kriterleridir[42]–[48]. Bu tez çalışmasında da sınıflandırıcılar bu kriterler ile değerlendirilmiştir. Çalışmada kullanılan ilk sınıflandırma yöntemi olan kNN sınıflandırma algoritması oldukça yüksek sonuçlara sahiptir. Yöntemde kullanılan k parametresinin değeri arttıkça verim düşmektedir. Tablodan da anlaşılacağı gibi 10 uzaklık hesaplama parametrelerinde k=1 olduğunda sonuç %100 olarak elde

edilmiştir ve ondan sonra k değeri arttıkça performans değerlendirme parametrelerindeki sonuçlar düşmüştür.

Tablo 6.1.'de elde edilen sonuçlara göre; 10 adet uzaklık hesaplama yöntemleri içinde en yüksek performans değerlendirme kriterlerine sahip olan uzaklık hesaplama yöntemi cityblok'tur ve $k=10$ olduğunda doğruluk oranı 89,19 olup duyarlılık 0,91, özgüllük 0,87 ve F-ölçümü 0,89'dur. En düşük performans değerlendirme kriterlerine sahip uzaklık hesaplama yöntemleri ise; jaccard ve hamming'tir. Çünkü iki yöntemin özellikleri eşdeğerdir ve değerleri düşüktür. Bu değerler; doğruluk 55,62, duyarlılık 0,99, özgüllük 0,03 ve F-ölçümü 0,06 olarak bulunmuştur. Burada duyarlılık diğer parametrelere göre yüksek bulunmasına rağmen performansı diğer yöntemlere nispeten daha düşüktür diyebiliriz.

Tablo 6.2.'de PNN sonuçları gösterilmiştir. Bu sonuçlara bakıldığında tüm parametrelerden elde edilen sonuç %100'dür ve bu da yöntemin KOAH teşhisinde kullanılabilmesini gösterir.

Tablo 6.3.'te SVMs sonuçları gösterilmek üzere, eğitim başarı oranı ve test başarı oranı oldukça yüksek değere sahiptir. Duyarlılık 0,92 değeri ile en yüksek ve özgüllük 0,80 ile en küçük değere sahiptir.

Her grup verinin sınıflandırılmasında PNN oldukça yüksek verilere sahip olduğundan üstün bir performans sağlamıştır. Diğer iki sınıflandırma yöntemlerinde de yüksek sınıflandırma doğruluğuna ulaşılmıştır.

Bu çalışma neticesinde, PPG sinyalinin makine öğrenmesi ve sinyal işleme teknikleriyle beraber işlenmesi sonucu, KOAH teşhisinde kullanılabilmesi kanısına varılmıştır. Literatürde KOAH teşhisi için oldukça farklı sinyaller ve kombinasyonlar kullanılmıştır. Ancak kullanılacak sinyalin kolay ve non-invaziv yöntemlerle ölçülebilmesi hastaya verilen rahatsızlığı azaltacaktır.

Çalışma, çeşitli perspektiflerden de geliştirilebilir. Herhangi bir KOAH teşhis sistemi oluşturulurken bu çalışmada çıkarılan PPG özellikleri kullanılabilir. Bu sayede, gerçek zamanlı analiz yapabilen bir sistem tasarımı ile KOAH teşhisi için gerekli iş yükü azaltılabilir. Ayrıca teknik personel gereksinimi duyulmadan sistem hasta tarafından rahatlıkla kullanılabilir. Sistemin evde kullanılabilirliği farklı bir avantajdır. Çok uzun zaman beklemeksizin teşhisin hızlı bir şekilde yapılabilmesi, tedavinin erken başlamasına yardımcı olacaktır. Bu sayede zamanla KOAH'ın insan vücuduna vermiş olduğu rahatsızlıkların önüne geçilmiş olup, insanın yaşam kalitesini artırıp, daha kaliteli ve elverişli bir yaşama devam edilebileceği çalışmada gösterilmiştir.

KAYNAKÇA

- [1] Merone, M., Onofri, L., Soda, P., Pedone, C., Incalzi, R. A., and Iannello, G., "Early experiences in COPD exacerbation detection," in *2014 IEEE 27th International Symposium on Computer-Based Medical Systems*, 2014.
- [2] Carvalho, P. *et al.*, "Biodata analytics for COPD," in *3rd IEEE EMBS International Conference on Biomedical and Health Informatics, BHI 2016*, 2016, pp. 469–472.
- [3] Türk Toraks Derneği KOAH Çalışma Grubu, *Kronik Obstrüktif Akciğer Hastalığı (KOAH)*, 1st ed. Ankara: Türk Toraks Derneği, 2013.
- [4] Daşkapan, A., Atalay, K. D., Tüzün, H., and Arslan, S.A., "Kırıkkale İli Kronik Obstrüktif Akciğer Hastalıkları Bilinç Düzeyi Araştırması," *Sağlık ve Toplum*, vol. 25, no. 1, pp. 54–60, 2015.
- [5] Zubaydi, F., Sagahyroon, A., Aloul, F., and Mir, H., "MobSpiro: Mobile based spirometry for detecting COPD," in *2017 IEEE 7th Annual Computing and Communication Workshop and Conference (CCWC)*, 2017, pp. 1–4.
- [6] Işık, H., Güven, Ü., Büyükoğlan, A., "Yapay Sinir Ağları İle Kronik Obstrüktif Akciğer Hastalığının Sınıflandırılması Chronik Obstructive Pulmonary Disease Classification with Artificial Neural Networks," in *TıpTekno 2015 Tıp Teknolojileri Ulusal Kongresi*, 2015, pp. 189–192.
- [7] Chreiteh, S.S., Saadi, D.B., Belhage, B., Nabipour, N., Hoppe, K., and Thomsen, E.V., "A clinical study of short-term sternal photoplethysmography: Recordings from patients with obstructive airways diseases," in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2016, vol. 2016–Octob, pp. 2712–2716.
- [8] Johansson, A., "Neural network for photoplethysmographic respiratory rate monitoring," *Med. Biol. Eng. Comput.*, vol. 41, no. 3, pp. 242–248, 2003.
- [9] Van Der Heijden, M., and Lucas, P.J.F., "Probabilistic Models For Smart Monitoring," in *Proceedings - IEEE Symposium on Computer-Based Medical Systems*, 2012, pp. 1–6.

- [10] Hamet, P., and Tremblay, J., “Artificial Intelligence in Medicine,” vol. 2101, pp. 4–8, 2001.
- [11] Kartal, E., “Sınıflandırmaya Dayalı Makine Öğrenmesi Teknikleri ve Kardiyolojik Risk Değerlendirme,” İstanbul Üniversitesi, 2015.
- [12] Srivastava, S., Bisht, A., and Narayan, N., “Safety and Security in Smart Cities Using Artificial Intelligence-A Review,” in *22nd IEEE International Conference on Emerging Technologies And Factory Automation*, 2017, vol. 6, pp. 130–133.
- [13] Özger, M.F., Amasyalı, Z.B., “Meta Öğrenme ile KNN Parametre Seçimi KNN Parameter Selection Via Meta Learning,” 2013.
- [14] Kanwade, A., and Bairagi, V.K., “Classification of COPD and normal lung airways using feature extraction of electromyographic signals,” *J. King Saud Univ. - Comput. Inf. Sci.*, 2016.
- [15] Baechle, C., Agarwal, A., Behara, R., and Zhu, X., “A cost sensitive approach to predicting 30-day hospital readmission in COPD patients,” in *2017 IEEE EMBS International Conference on Biomedical and Health Informatics, BHI 2017*, 2017, vol. 11, pp. 317–320.
- [16] Poreva, A., Karplyuk, Y., Makarenkova, A., and Makarenkov, A., “Detection of COPD’s diagnostic signs based on polyspectral lung sounds analysis of respiratory phases,” in *2015 IEEE 35th International Conference on Electronics and Nanotechnology, ELNANO 2015 - Conference Proceedings*, 2015, pp. 351–355.
- [17] Nousias, S., *et al.*, “An mHealth system for monitoring medication adherence in obstructive respiratory diseases using content based audio classification,” *IEEE Access*, vol. 2, no. c, pp. 1–11, 2018.
- [18] Nissen, L., and Lindhardt, T., “A qualitative study of COPD-patients’ experience of a telemedicine intervention,” *Int. J. Med. Inform.*, vol. 107, no. March, pp. 11–17, 2017.
- [19] T.T.D.K.Ç. Grubu, “Kronik Obstrüktif Akciğer Hastalığı Tanı ve Tedavi Uzlaşısı Raporu,” Ankara, 2010.
- [20] İnce, D.İ., Savcı, S., Sağlam, M., Güçlü, M.B., Arıkan, H., and Çöplü, L., “Kronik Obstrüktif Akciğer Hastalarında Sigara Öyküsü ve Fonksiyonel Kapasite Arasındaki İlişki,” vol. 22, no. 1, pp. 39–43, 2011.

- [21] Baechle, C., Agarwal, A., Behara, R., and Zhu, X., “Co-Occurring Evidence Discovery For COPD Patients Using Natural Language Processing,” in *2017 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, 2017, pp. 321–324.
- [22] Ergan, B., and Çöplü, L., “Kronik Obstrüktif Akciğer Hastalığı,” *Hacettepe Tıp Derg.*, vol. 8, no. 4, pp. 12–14, 2001.
- [23] Grishin, O.V., Gulyaeva, V.V., Uryumtsev, D.Y., Zinchenko, M.I., and Grishin, V.G., “Diagnostic use of the resistive device in COPD patients,” in *2015 International Conference on Biomedical Engineering and Computational Technologies (SIBIRCON)*, 2015, pp. 146–149.
- [24] Silva, B.S.A., *et al.*, “Severity of COPD and its relationship with IL-10,” *Cytokine J.*, no. October, 2017.
- [25] Şahin, E.M., “Kronik Obstrüktif Akciğer Hastalığında Önleyici Yaklaşım,” *Aile Hekim.*, vol. 2, no. 4, pp. 12–15, 2008.
- [26] Celli, B.R., *et al.*, “Standards for the diagnosis and treatment of patients with COPD: A summary of the ATS/ERS position paper,” *Eur. Respir. J.*, vol. 23, no. 6, pp. 932–946, 2004.
- [27] Li, D., Zhao, H., and Dou, S., “A new signal decomposition to estimate breathing rate and heart rate from photoplethysmography signal,” *Biomed. Signal Process. Control*, vol. 19, pp. 89–95, 2015.
- [28] Dhar, S., Mukhopadhyay S.K., , Pal, S., and Mitra, M., “An efficient data compression and encryption technique for PPG signal,” *Meas. J. Int. Meas. Confed.*, vol. 116, no. September 2017, pp. 533–542, 2018.
- [29] Kavsaoglu, A.R., Polat, K., and Bozkurt, M.R., “A novel feature ranking algorithm for biometric recognition with PPG signals,” *Comput. Biol. Med.*, vol. 49, pp. 1–14, 2014.
- [30] Uçar, M.K., “Obstrüktif Uyku Apne Teşhisi için Makine Öğrenmesi Tabanlı Yeni Bir Yöntem Geliştirilmesi,” Sakarya University, 2017.
- [31] Uçar, M.K., Bozkurt, M.R., Polat, K., and Bilgin, C., “EEG Sinyalleri Kullanılarak Uyku Evrelerinin Sınıflandırılmasında Sayısal Filtrelemenin Etkisi Effect of Digital Filtering to Sleep Stage Classification Using EEG Signals,” in *Eleco 2014 Elektrik – Elektronik – Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu*, 2014.

- [32] Ulfat, I., Waqar, A., Asif, M., and Ishtiaq, A., "Classification of Students Results Using KNN and ANN," in *Emerging Technologies (ICET), 2017 13th International Conference*, 2017.
- [33] Kundu, S., and Roy, S., "K-Nearest Neighbour (KNN) Approach using SAT Based Technique for Rectilinear Steiner Tree Construction," in *Embedded Computing and System Design (ISED), 2017 7th International Symposium on*, 2017.
- [34] Mahajan, A., Kumar, S., and Bansal, R., "Diagnosis of Diabetes Mellitus Using PSO and KNN Classifier," in *Computing and Communication Technologies for Smart Nation (IC3TSN), 2017 International Conference on*, 2017, pp. 32–38.
- [35] Rachman, N.T., Tjandrasa, H., and Fatichah, C., "Alcoholism classification based on EEG data using Independent Component Analysis (ICA), Wavelet de-noising and Probabilistic Neural Network (PNN)," in *2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, 2016, pp. 17–20.
- [36] Zhao, J., Zhao, P., Liu, S., Liu, Y., Wang, Q., and Jiao, N., "A Fault Diganosis Method Based on Bispectrum-LPP and PNN," in *2017 International Conference on Dependable Systems and Their Applications (DSA)*, 2017, pp. 98–102.
- [37] Zhou, J., Zhong, T., and He, X., "Auxiliary Diagnosis of Breast Tumor Based on PNN Classifier Optimized by PCA and PSO Algorithm," in *2017 9th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)*, 2017, pp. 222–227.
- [38] Alsuwaidi, A., Grieve, B., and Yin, H., "Spectral-Texture Approach to Hyperspectral Image Analysis for Plant Classification with SVMs," in *Imaging Systems and Techniques (IST), 2017 IEEE International Conference on*, 2017.
- [39] Dongsong, Z., and Qi, M., "A load identification algorithm based on SVM," in *Electronics Instrumentation & Information Systems (EIIS), 2017 First International Conference on*, 2017, pp. 2–6.
- [40] Soofi, A.A., and Awan, A., "Classification Techniques in Machine Learning: Applications and Issues," *J. Basic Appl. Sci.*, vol. 13, pp. 459–465, 2017.

- [41] Swinkels, W., Claesen, L., Xiao, F., and Shen, H., “Real-time SVM-based Emotion Recognition Algorithm,” in *Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), 2017 10th International Congress on*, 2017, pp. 10–15.
- [42] Miravittles, M. *et al.*, “Evaluation of criteria for clinical control in a prospective, international, multicenter study of patients with COPD,” *Respir. Med.*, vol. 136, no. January, pp. 8–14, 2018.
- [43] Konno, S. *et al.*, “Acute bronchodilator responses to β 2-agonist and anticholinergic agent in COPD: Their different associations with exacerbation,” *Respir. Med.*, vol. 127, pp. 14–20, 2017.
- [44] Agarwal, A., Baechle, C., Behara, R., and Zhu, X., “A Natural Language Processing Framework for Assessing Hospital Readmissions for Patients with COPD,” *IEEE J. Biomed. Heal. Informatics*, vol. 2194, no. c, pp. 1–1, 2017.
- [45] Pazhaniraja, N., Paul, P.V., Priyadharshini, C., Maris, M.H., and Leticianathali, A., “A Survey on Various Prediction model for Chronic Obstructive Pulmonary Disease (COPD),” in *2017 International Conference on Computation of Power, Energy, Information and Communication (ICCPEIC)*, 2017, pp. 269–272.
- [46] Hosseini, M.P., Soltanian-Zadeh, H., and Akhlaghpour, S., “Assesing Lung Volumetric Variation To Detect And Stage COPD,” in *Biomedical Engineering (MECBME), 2011 1st Middle East Conference on*, 2011, pp. 312–315.
- [47] Bellos, C., Papadopoulos, A., Rosso, R., Fotiadis, D.I., and Member, S., “Categorization of COPD Patient’s Health Level through the Use of the CHRONIOUS Wearable Platform,” in *2014 IEEE 27th International Symposium on Computer-Based Medical Systems*, 2012, pp. 61–64.
- [48] Luo, L., Lian, S., Feng, C., Huang, D., and Zhang, W., “Data mining-based detection of rapid growth in length of stay on COPD patients,” *2017 IEEE 2nd Int. Conf. Big Data Anal. ICBDA 2017*, pp. 254–258, 2017.

ÖZGEÇMİŞ

Sedat ÖRENÇ, 26.08.1991'de Siirt'te doğdu. İlk, orta ve lise eğitimini Siirt'te tamamladı. 2009 yılında Siirt Atatürk Anadolu Lisesi'nden mezun oldu. 2009 yılında başladığı Dicle Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nü 2015 yılında bitirdi. 2016 yılında Sakarya Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde yüksek lisans eğitimine başladı. Halen Sakarya Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde yüksek lisans eğitimine devam etmektedir. 17 Aralık 2018 yılında Batman Üniversitesi Elektrik-Elektronik Bölümü'ne Araştırma Görevlisi olarak atandı.