



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



TIKAYICI UYKU APNESİ TEDAVİSİNDE
KULLANILAN CİHAZLARDA ZEKİ VE
ADAPTİF SİSTEM TASARIMI

Mehmet BALCI

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Aralık-2022
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mehmet Balcı tarafından hazırlanan “Tıkayıcı Uyku Apnesi Tedavisinde Kullanılan Cihazlarda Zeki ve Adaptif Sistem Tasarımı” adlı tez çalışması 08/12/2022 tarihinde aşağıdaki jüri tarafından oy birliği ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Unvanı Adı SOYADI

Danışman

Unvanı Adı SOYADI

Üye

Unvanı Adı SOYADI

Üye

Unvanı Adı SOYADI

Üye

Unvanı Adı SOYADI

İmza

Doç. Dr. Rahime CEYLAN

Prof. Dr. Şakir TAŞDEMİR

Doç. Dr. İlker Ali ÖZKAN

Dr. Öğr. Üyesi Adem GÖLCÜK

Dr. Öğr. Üyesi Sabri ALTUNKAYA

Yukarıdaki sonucu onaylarım.

Prof. Dr. Sait Gezin
FBE Müdürü

Bu tez çalışması Selçuk Üniversitesi BAP Koordinatörlüğü tarafından 18101016 nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

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

DECLARATION PAGE

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

İmza

Mehmet BALCI

08.12.2022

ÖZET

DOKTORA TEZİ

TIKAYICI UYKU APNESİ TEDAVİSİNDE KULLANILAN CİHAZLARDA ZEKİ VE ADAPTİF SİSTEM TASARIMI

Mehmet BALCI

**Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Şakir TAŞDEMİR

2022, 103 Sayfa

Jüri

Prof. Dr. Şakir TAŞDEMİR

Doç. Dr. İlker Ali ÖZKAN

Doç. Dr. Rahime CEYLAN

Dr. Öğr. Üyesi Adem GÖLCÜK

Dr. Öğr. Üyesi Sabri ALTUNKAYA

Uykuda solunum bozukluğu hastalıklarından en sık görülen ve yaşamı ciddi şekilde tehdit edenlerinden birisi tıkalı uyku apnesi sendromudur. Tıkalı uyku apnesi tedavisinde altın standart olarak kullanılan yöntem pozitif havayolu basıncı (positive airway pressure, PAP) cihazlarının kullanımıdır. PAP cihazlarının kullandığı fizyolojik sinyaller ve kullanılan algoritmalar cihazın hastaya uygulayacağı terapiyi ve hastalığın seyrini etkileyen ana unsurlardır.

Bu çalışmada PAP cihazları için hem kullanılabilecek en etkili sinyallerin belirlenmesi hem de makine öğrenmesi yöntemleri ile kişiselleştirilmiş terapi uygulayabilen bir sistem önerilmektedir. Çalışmada polisomnografi (PSG) sinyalleri sinyal işleme ile işlenmiş daha sonra çıkarılan sinyal özelliklerine göre özellik seçme yapılarak, geliştirilecek yeni nesil PAP cihazı için, en etkili sinyal tipleri belirlenmiştir. Bu sinyaller akış basıncı (pressure flow), horlama basıncı (pressure snore) ve göğüs (thorax) sinyalleridir. Tez çalışması sonunda geliştirilen PAP cihazı donanımı da bu üç sinyali algılayabilecek sensörlerle donatılmıştır. Daha sonra, bu üç sinyali kullanan gerçek zamanlı öğrenen zeki ve adaptif bir sistem geliştirilmiştir. Birçok makine öğrenmesi yönteminin sınıflandırma amacıyla kullanıldığı tez çalışmasında, geliştirilen cihaz için gerçek zamanlı öğrenen bir yapay sinir ağı oluşturulmuştur. Geliştirilen ağ, sisteme gelen her yeni veri ile performansını daha üst seviyeye çıkarmaya odaklanmış adaptif bir sistem yaklaşımı ile çalışmaktadır. Hastadan aldığı verilerle sürekli eğitilen sistemin, ön eğitimi için 75 hastaya ait polisomnografi (PSG) verileri kullanılmıştır. Sistemdeki yapay sinir ağı, apne tespiti yerine apneleri önceden tahmin etme amacıyla çıktı üretmektedir. Böylece hasta apne sorununu yaşamadan önleyici terapi uygulayabilen bir sistem geliştirilmiştir. Çalışmada %95,2 doğruluk oranıyla apne tahmin başarıları elde edilmiştir. Geliştirilen sistem, gerçek zamanlı öğrenme ve adaptif çalışma yöntemi sayesinde apne oluşmadan önce apne riskini tahmin ederek, riski ortadan kaldırmak için PAP cihazı basıncını otomatik olarak ayarlayabilmektedir. Böylece apneler önceden tahmin edilerek apne riskinin ortadan kaldırılması başarılmıştır. Bu amaçla gerçek hasta verileri kullanılarak bir simülasyon yapılmış ve sonuçları çalışma sonuçlarında sunulmuştur.

Anahtar Kelimeler: Adaptif sistem, apne tahmini, CPAP cihazı, gerçek zamanlı öğrenme, sinyal işleme, tıkalı uyku apnesi, yapay sinir ağları, yapay zekâ

ABSTRACT

Ph.D THESIS

INTELLIGENT AND ADAPTIVE SYSTEM DESIGN IN DEVICES USED IN THE TREATMENT OF OBSTRUCTIVE SLEEP APNEA

Mehmet BALCI

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
SELÇUK UNIVERSITY
THE DEGREE OF DOCTOR OF PHILOSOPHY
IN COMPUTER ENGINEERING**

Advisor: Prof. Dr. Şakir TAŞDEMİR

2022, 103 Pages

Jury

**Prof. Dr. Şakir TAŞDEMİR
Assoc. Prof. Dr. İlker Ali ÖZKAN
Assoc. Prof. Dr. Rahime CEYLAN
Assist. Prof. Dr. Adem GÖLCÜK
Assist. Prof. Dr. Sabri ALTUNKAYA**

Obstructive sleep apnea syndrome is one of the most common and life-threatening sleep disorders. The gold standard method used in the treatment of obstructive sleep apnea is the use of positive airway pressure (PAP) devices. The physiological signals used by PAP devices and the algorithms used are the main factors that affect the therapy that the device will apply to the patient and the course of the disease.

In this study, a system that can both determine the most effective signals that can be used for PAP devices and apply personalized therapy with machine learning methods is proposed. In the study, polysomnography (PSG) signals were processed by signal processing, and then the most effective signal types were determined for the next generation PAP device to be developed by selecting features according to the extracted signal characteristics. These signals are Pressure Flow, Pressure Snore and Thorax. The hardware of the PAP device developed at the end of the thesis is also equipped with sensors that can detect these three signals. Then, an intelligent and adaptive system that can learn in real time using these three signals has been developed. In the thesis study, in which many machine learning methods are used for classification, a real-time learning artificial neural network has been created for the developed device. The developed network works with an adaptive system approach focused on increasing its performance with each new data coming into the system. Polysomnography (PSG) data of 75 patients were used for pre-training of the system, which was continuously trained with the data obtained from the patient. The artificial neural network in the system produces output to predict apneas instead of apnea detection. Thus, a system that can apply preventive therapy without the patient experiencing apnea has been developed. Apnea prediction success was achieved with an accuracy rate of 95.2% in the study. The developed system can automatically adjust the pressure of the PAP device to eliminate the risk by estimating the risk of apnea before apnea occurs, thanks to its real-time learning and adaptive working method. Thus, apneas were predicted and the risk of apnea was eliminated. For this purpose, a simulation was made using real patient data and the results are presented in the study results.

Keywords: Adaptive system, apnea prediction, artificial intelligence, artificial neural networks, CPAP device, real-time learning, signal processing, obstructive sleep apnea,

ÖNSÖZ

Doktora çalışmam boyunca beni destekleyip yönlendiren, tecrübeleriyle yoluma ışık tutan Selçuk Üniversitesi Bilgisayar Mühendisliği öğretim üyesi danışman hocam sayın Prof. Dr. Şakir Taşdemir'e sonsuz teşekkürlerimi ve saygılarımı sunuyorum. Ayrıca çalışmalarına tecrübeleri ile katkı sağlayan ve bana kıymetli zamanlarını ayıran Doç. Dr. İlker Ali Özkan hocama, Dr. Öğr. Üyesi Adem Gölcük hocama ve Dr. Öğr. Üyesi Güzin Özmen hocama şükranlarımı sunarım. Çalışmada kullanılan verilerin temin edilmesindeki katkılarından dolayı Prof. Dr. Hüsamettin Vatansev, Doç. Dr. Hülya Vatansev ve Dr. Öğr. Üyesi Serkan Küçüktürk hocalarıma da teşekkürlerimi sunarım.

Tez çalışmam sırasında ve hayatımın her anında desteğini ve anlayışını esirgemeyen, bana sabırla destek ve moral veren çok sevdiğim eşim Ayşe Balcı'ya teşekkürü bir borç bilirim.

Mehmet BALCI
KONYA-2022

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
1.1. Teşhis ve Tedavi	2
1.2. Tezin Amacı ve Önemi	3
2. KAYNAK ARAŞTIRMASI	6
3. MATERYAL VE METOT	18
3.1. Biyomedikal Sinyal İşleme	18
3.1.1. Sinyaldeki gürültülerin giderilmesi	19
3.1.2. Spektral analiz.....	20
3.2. ReliefF Özellik Seçme Algoritması	29
3.3. Makine Öğrenmesi	29
3.3.1. Yapay sinir ağları.....	30
3.4. Gerçek Zamanlı Öğrenme	35
3.5. Adaptif Sistem.....	36
3.6. Performans Ölçütleri	37
3.7. Verilerin Elde Edilmesi.....	39
4. UYGULAMALAR	42
4.1. Sinyal İşleme Çalışmaları	42
4.1.1. Ön işleme	43
4.1.2. Sinyal özelliklerinin çıkarılması	47
4.1.3. Özellik seçme.....	51
4.2. Solunum Olaylarının Eş Zamanlı Tespiti.....	54
4.3. Apne Tahmin Zamanının Belirlenmesi.....	67
4.4. Gerçek Zamanlı Öğrenebilen Adaptif Sistem	69
4.4.1. Ön Eğitim.....	69
4.4.2. Sürekli eğitim ve adaptif çalışma.....	72
4.5. Gerçek Zamanlı Veri Toplama.....	74
4.5.1. Veri toplama kartı gömülü sistem programlaması.....	76
4.5.2. Verilerin bilgisayar ortamına aktarılması	77
4.5.3. Pozitif hava basıncının belirlenmesi	80
4.6. Cihaz Prototipinin Oluşturulması.....	83
5. SONUÇLAR VE ÖNERİLER	86
5.1. Sonuçlar.....	86
5.1.1. Solunum olaylarının eş zamanlı tespiti	88
5.1.2. Apne tahmini.....	89

5.1.3.	Gerçek zamanlı öğrenen adaptif sistemin geliştirilmesi	90
5.1.4.	Pozitif hava basıncının belirlenmesi	90
5.1.5.	Cihaz prototipinin oluşturulması	91
5.2.	Öneriler	91
KAYNAKLAR		93
ÖZGEÇMİŞ		102



SİMGELER VE KISALTMALAR

Simgeler

$w(n)$	:	Welch yönteminde periodogramların pencereleme fonksiyonu
$x(t)$	:	Zaman domenindeki sinyal
$x(\omega)$	:	Frekans domenine dönüştürülmüş sinyal

Kısaltmalar

Acc	:	Accuracy (Doğruluk)
ADD	:	Ayrık dalgacık dönüşümü
AFD	:	Ayrık Fourier dönüşümü
AHI	:	Apne-hipopne indeksi
AI	:	Apne indeksi
AIRS	:	Artificial Immune Recognition System
ANFIS	:	Adaptive neuro-fuzzy inference systems
ANN	:	Artificial Neural Network (Yapay sinir ağı)
APAP	:	Automatic continuous positive airway pressure
AR	:	Autoregressive
ARI	:	Arousal index (Uyarılma (uyanma) indeksi)
AS	:	Adaptif sistem
AUC	:	Area under ROC curve (ROC eğrisi altındaki alan)
BMI	:	Body mass index (Vücut kitle indeksi)
BP	:	Band pass (Bant geçiren)
BPAP	:	Bilevel positive airway pressure
BR	:	Band reject (Bant bastıran (geçirmeyen, durduran))
cmH ₂ O	:	Santimetre su
CNN	:	Convolutional neural network
CPAP	:	Continuous positive airway pressure
DC	:	Direct current (Doğru akım)
DD	:	Dalgacık dönüşümü
DT	:	Decision tree (Karar ağacı)
EKG	:	Elektrokardiyografi
EEG	:	Elektroensefalogram
EMG	:	Elektromiyogram
EOG	:	Elektrookülogram
FF	:	Feed-forward
GZÖ	:	Gerçek zamanlı öğrenme
HFD	:	Hızlı Fourier dönüşümü
HMM	:	Hidden markov modeli
HP	:	High pass (Yüksek geçiren)
Hz	:	Hertz
k-NN	:	k-Nearest-Neighbor (k-en yakın komşu)
KOAH	:	Kronik obstrüktif akciğer hastalığı
KZFD	:	Kısa zamanlı Fourier dönüşümü
LP	:	Low pass (Alçak geçiren)
LR	:	Logistic regression
MÖ	:	Makine öğrenmesi
MSE	:	Mean squared error

NB	:	Naive bayes
PAP	:	Positive airway pressure
PSD	:	Power spectrum density
PSG	:	Polismnografi
PST	:	percentage of sleep time (Uyku süresi yüzdesi)
PTT	:	Pulse transit time (Nabız geçiş süresi)
RBF	:	Radial basis function
RF	:	Random forest (Rastgele orman)
SaO ₂	:	Arteriyel oksijen doyumu
SDD	:	Sürekli dalgacık dönüşümü
SpO ₂	:	Oksijen satürasyonu
SVM	:	Support vector machine (Destek vektör makineleri)
YSA	:	Yapay sinir ağları (Artificial neural network)
YZ	:	Yapay zekâ



1. GİRİŞ

Uykuda solunum bozukluğu olayları insan yaşam kalitesini olumsuz etkileyen ve hayati tehlike oluşturabilecek hastalıklara yol açabilen sendromlardır. Uyku sırasında meydana gelebilecek solunum bozukluklarından en önemlileri apne ve hipopne olaylarıdır. Bunlar, Amerikan Uyku Tıbbı Akademisi tarafından (yetişkinler için) şu şekilde tanımlanmışlardır. Hipopne, hastanın solunumundaki hava akışının en az 10 saniye süreyle en az %30 oranda azalması ve buna bağlı olarak kandaki oksijen saturasyonunda en az %3'lük bir düşüşün meydana gelmesidir (American Academy of Sleep Medicine, 2014). Apne ise solunumun sinyalinin en az 10 saniye süreyle en az %90 oranda azalması olarak tanımlanmıştır (American Academy of Sleep Medicine, 2012). Bu rahatsızlığın toplumda yaygın olarak bulunduğu, özellikle yetişkin erkeklerde daha fazla görüldüğü birçok çalışmada bildirilmiştir (Al-Ani ve ark., 2005). Uyku apnesi rahatsızlığının görülme sıklığı yetişkin erkeklerde %13-33, yetişkin kadınlarda ise %6-19 olarak ifade edilmiştir (Reddy ve ark., 2009; Senaratna ve ark. 2017). Üç farklı apne tipi vardır. Bunlar tıkalı apne, santral apne ve karışık apne'dir. Kısaca bu apne tiplerini ayırt edebileceğimiz şekilde tanımlamak gerekirse; tıkalı apne, hastada solunum çabası bulunmasına karşın solunumun olmaması halidir. Santral apne ise, hastada solunumun durmasıyla birlikte solunum çabasının da bulunmaması durumudur. Uzmanlar bu durum hastanın sinir sistemi ile ilişkili olduğunu bildirmişlerdir. Karışık apne ise başlangıçta santral apne olarak başlayan durumun solunum çabasının başlaması ile tıkalı apneye dönüşmesi durumudur. Her iki durumda da hastanın solunum yolunda hava akışı olmadığı için apne durumu devam etmektedir (Akdeniz, 2012; Ursavaş ve Ege, 2004).

Apne ve hipopne geçiren hastanın uyku sırasında yeterli miktarda solunum yapamaması ve buna bağlı olarak kandaki oksijen miktarının hızla düşmesi ve gece boyunca sık sık uyanma ya da sık tuvalete gitme ihtiyacı, kalp ritminin bozulması gibi sonuçları doğurmaktadır. Ayrıca, uyku apnesi hastalığının kısa vadede gün içi uyku hali, dikkat dağınıklığı, stres ve buna bağlı davranış bozukluklarıyla birlikte hafıza problemlerine yol açtığı yapılan çalışmalarla ortaya konulmuştur. Yine benzer çalışmalar uykuda solunum bozukluklarının uzun vade etkileri olan hipertansiyon, miyokard infarktüs (kalp kasının bir bölümünün o bölgeye yetersiz kan akışından dolayı kalıcı hasara uğraması), serebrovasküler olaylar (beyni besleyen damarların tıkanması veya kanaması)

ile ortaya çıkan, hasar gören beyin bölgesi ile ilgili) ve narkolepsi (ani uyku atakları) ile olan ilişkisini ortaya koymuştur (Cooksey ve Balachandran, 2016).

1.1. Teşhis ve Tedavi

Tıkayıcı uyku apnesinin teşhis ve tedavisi için hastalar hastanelerin uyku servislerinde yatırılarak polisomnografi (PSG) olarak adlandırılan ve uyku esnasında birçok fizyolojik veriyi hastadan alarak kaydeden bir sistem kullanılmaktadır. Polisomnografi sistemi, elektroensefalogram (EEG), elektrookülogram (EOG), elektromiyogram (EMG), elektrokardiyografi (EKG), oksijen satürasyonu (SpO₂), nabız, solunum çabasını gösteren abdominal ve thorax hareketleri, solunum akış, horlama sinyalleri gibi birçok veriyi kaydetme olanağı sağlar. Bu sistemin verilerine göre uyku uzmanları tarafından hazırlanan bir raporla hastanın durumu ortaya koyulur ve hastanın hangi tipte ve hangi seviyede rahatsızlığı olduğu belirlenir. Hastanın hangi derecede uykuda solunum bozukluğu olduğunun belirlenmesi için saatte ortalama kaç kere apne ya da hipopne geçirdiğini gösteren apne-hipopne indeksi (AHI) adı verilen bir değer hesaplanmaktadır (del Campo ve ark., 2006; Douglas ve ark., 1992). AHI değeri 5 ile 15 arasında ise “hafif”, 15 ile 30 arasında ise “orta”, 30’dan fazla ise hastaya “ciddi” derecede apne hastalığı teşhisi koyulmaktadır.

Hastanın bir gece hastanede yatırılması teşhis için yeterli olsa da uygun tedavinin belirlenmesi için hastanın tekrar hastanede bir gece daha geçirmesi gerekebilmektedir. Hastanın tekrar hastaneye yatırılmasıyla uygun PAP (Positive Airway Pressure) tedavisinin belirlenmesi amacıyla titrasyon cihazları ile uyku sırasında hastanın hava yoluna belirli basınçlarda hava yollar. Bu işlem sabaha kadar sürer ve uyku teknisyenleri hastanın solunum problemini en aza indirecek uygun hava basıncı değerini deneme yanılma metodu ile belirlerler. Bu tespitlerin ardından hekim tarafından hastaya uygun PAP tedavisi reçete edilir. PAP cihazlarını hastalar evlerinde uykudayken kullanmaktadırlar. Hasta uyurken, cihaz hastanın havayoluna pozitif hava göndererek hastanın solunum yapmasını sağlamaktadır.

PAP cihazlarının birçok türü bulunmaktadır. Bunlardan en yaygın kullanılanları Continuous Positive Airway Pressure (CPAP), Automatic CPAP (APAP) ve Bilevel Positive Airway Pressure (BPAP) cihazlarıdır (Demir ve ark., 2012). CPAP cihazları önceden ayarlanan sabit bir basınçtaki ortam havasını hastanın hava yoluna bir maske aracılığıyla sürekli pompalayarak çalışmaktadırlar. Genellikle 4-20 cmH₂O basın

aralığında ayarlanan bu cihazların kullanımı, PAP tedavileri içerisinde standart etkili ve güvenli yöntem olarak kabul edilmektedir (Freedman, 2010; Kushida ve ark., 2006). APAP cihazları otomatik CPAP cihazı olarak da bilinir. Geleneksel CPAP cihazları gibi hastanın hava yoluna sürekli bir pozitif hava basıncı sağlamakla beraber, bu cihazların sağladığı hava basınç değeri sabit değildir. APAP cihazları, önceden belirlenen minimum ve maksimum aralıkların dışına çıkmadan sağlanan havanın basıncında değişiklik yaparlar. Bu değişikliği hastanın hava yolunda meydana gelen daralmanın direncine göre ayarlayarak artırma ya da azaltma şekilde gerçekleştirirler (Littner ve ark., 2002; Teschler ve ark., 1996). Bu cihazların farklı algoritmalara göre çalışan tipleri bulunsa da genellikle hava yolundaki direnç tespitine dayalı olarak çalışırlar ve mevcut durumda havayolunda tıkanıklık varsa basınç artırılır, havayolu açıksa basınç düşürülür (Firat, 2016; Xu ve ark., 2012). BPAP cihazları ise hastaya nefes alma ve nefes vermede (inspirasyon ve ekspirasyonda) farklı basınçta hava uygulayan cihazlardır (Gay ve ark., 2006; Reeves-Hoché ve ark., 1995; Strollo ve ark., 1998). Bu cihazlar özellikle uyku apnesi sendromu ile astım ya da KOAH (Kronik Obstrüktif Akciğer Hastalığı) gibi bir hastalığı da olan, yüksek basınçlı havaya karşı nefes vermekte zorlanan hastalar için geliştirilmiştir (Resta ve ark., 1998; Schäfer ve ark., 1998).

1.2. Tezin Amacı ve Önemi

İnsan özel bir varlıktır. Yaratılış gereği insanoğlu tek bir model üzere yaratılmış varlıklar olarak bilinse de bütün insanlar aslında birbirinden farklıdır. Hatta tek yumurta ikizi olan iki kardeşin bile birbirinden çok farklı insanlar olduklarına çoğu zaman şahitlik ederiz. Bu farklılık hayatın her alanında göze çarpmaktadır. Bu alanlardan birisi de sağlıktır. Aynı doktor tarafından aynı hastalık teşhisi koyulmuş iki bireyin hastalıklarının seyri de tedavi uygulamaları da birbirinden farklılık göstermektedir. Bu hastalıklara bir örnek de tıkalıcı uyku apnesidir. Yapılan tetkikler neticesinde AHI değerleri aynı olan, yani aynı derecede tıkalıcı uyku apnesi hastası olan, başka rahatsızlığı da olmayan iki birey düşünelim. İlk bakışta baktığımızda hastalık teşhisi aynı, bilimsel kriterlere göre hastalık ciddiyet seviyesi de aynı olduğuna göre bu iki hastanın tedavisi de aynı olacak gibi düşünülebilir. Doktor tarafından iki hastaya da aynı cihaz aynı hava basınç oranları ile reçete edilse bile cihazların hastalar üzerindeki etkileri farklı olacaktır. Çünkü uyku apnesi uyku sırasından herhangi bir düzene bağlı olmadan ve anlık olarak birçok durumdan etkilenecek ortaya çıkan bir rahatsızlıktır. İnsan dinamik bir varlık olmasından

dolayı hastanın gününü nasıl geçirildiğinden tutun, psikolojik durumu ya da uyku sırasındaki vücut pozisyonuna varıncaya kadar birçok etken anlık olarak uyku değerlerini değiştirebilir. Bu kadar hareketli ve değişken bir varlık olan insanlar için uyku apnesi tedavisinde önceden basınç değerleri ayarlanmış ve uyku sırasında belli başlı 1-2 verinin dışında insan vücudundaki değişimleri algılamayan cihazların kullanılması verimsizdir. Bu yüzden bütün hastalıklarda olduğu gibi uyku apnesi tedavisinde de olabildiğince kişiye özel tedavi uygulanması gereklidir. Bu yaklaşımla, geliştirilen sistemin klasik cihazlardan farklı ve kullanılan yöntemler açısından da özgün olması gerektiği düşünülmüştür. Bu sebepten dolayı, yapay zekâ (YZ) tekniklerini de kullanan zeki bir sistem geliştirilmesi amaçlanmıştır.

Klasik APAP cihazları genellikle iki tane sensörden gelen veriye göre hareket etmektedir. Bu sensörler akış ve basınç sensörleridir. Tez çalışması ile daha fazla veriyi hastadan alan ve aldığı bu veriler arasında ilişkiler kuran, hastadan anlık olarak aldığı bu verileri yapay zekâ tekniklerini kullanarak değerlendiren ve uygun çıkış parametrelerini ve kontrol sinyallerini üretebilen yeni nesil zeki PAP cihazı gerçekleştirilmesi amaçlanmıştır. Klasik APAP cihazları akış ve basınç sensörlerinden aldıkları verilere bakarak hastanın havayolunda daralma olup olmadığını tespit ederler. Bu tespite göre de hastaya verilecek pozitif hava basıncını ayarlarlar. Yani klasik APAP cihazları apne ya da hipopne olayı ortaya çıktıktan sonra tespit eder ve terapi uygulaması yapar. Geliştirdiğimiz yapay zekâ tabanlı cihaz ise hastadan aldığı fizyolojik veriler ile çalışma süresi boyunca sürekli olarak öğrenme faaliyeti gerçekleştirir. Buna ilaveten cihaz, her yeni öğrenme sonrası durum değerlendirmesi yaparak adaptif olarak parametrelerini güncelleyebilmektedir. Böylece sistem çalıştığı süre içerisinde hep daha başarılı sonuçlar üretebilme odaklı çalışmaktadır. Sistem öğrenme faaliyeti sayesinde terapi yapacağı hastayı tanır ve kişisel bir terapi uygulaması gerçekleştirir. Bu öğrenme sayesinde sistem, hasta apneye girmeden önce apneleri tahmin eder ve önleyici bir terapi uygular. Geliştirilen cihaz, apne tahmin sistemi üzerine çalıştığı için, hastadan bir epoka elde ettiği verilerle bir sonraki epokta henüz apne oluşmadan bunu tahmin edebilen ve apne oluşma riskini ortadan kaldırma amacıyla pozitif hava basıncını ayarlayan yapay zekâ tabanlı yeni nesil bir sistemdir. Bu yöntemle göre hasta apne yaşamadan önce cihaz bunu algılayarak önleyici terapi uygular ve apne riski apne oluşmadan ortadan kaldırılır. Böylece gece boyunca hastanın daha konforlu bir uyku uyuması sağlanır.

Tez çalışmasının bir başka önemi de hastalığının teşhis ve tedavi sürecinin de değişeceği düşüncesidir. Yukarıda teşhis ve tedavi başlığı altında da belirtildiği gibi,

tıkayıcı uyku apnesi tedavisi için hastalar hastanelerin uyku servislerinde iki gece ya da daha fazla zaman geçirmektedirler. Hastaların uyku servislerinde geçirdikleri birinci gecede hastalığın teşhisi yapılırken ikinci gecede ise tedavi için kullanılacak cihazların hangi değerlerde çalışması gerektiği belirlenmektedir. Bu işlem hastaya gece boyu PAP cihazı terapisi uygulanarak ve deneme yanılma yöntemiyle en uygun titrasyon değerlerinin belirlenmesi şeklinde yapılmaktadır. Geliştirdiğimiz yeni nesil PAP cihazının gece boyunca hastayı tanıyarak sürekli bir öğrenme faaliyeti gerçekleştirmesi önceden deneme yanılma yöntemiyle titrasyon uygulamasına olan gereksinimi de ortadan kaldıracaktır. Hastanelerde uyku servislerindeki yoğunluğun ana nedeni hastaların en az iki gün uyku servislerinde yatırılmalarıdır. Yapay zekâ tabanlı yeni nesil PAP cihazlarının yaygınlaşması ile uyku servislerindeki yoğunluğun yarı yarıya azalacağı öngörüsünde bulunulabilir.

Ülkemizdeki uyku servislerinin yoğunluğu ve kurulum maliyeti düşünüldüğünde, teşhis ve tedavi aşamasında uyku servislerinde daha az zaman geçirilmesini sağlayacak, böylece ülke ekonomisine ciddi katkı sunacaktır. Yapay zekâ tabanlı yeni nesil PAP cihazı yerli üretim ve daha fonksiyonel olmasıyla, yoğunluğu yabancı menşeli olan PAP cihazlarının ithalatında ciddi bir azalma olması beklenmektedir. Bu durum dış ticaret açığının kapanmasına katkı sağlayacağından ülke ekonomisine olumlu yansıtacaktır. Bu çalışma yerli ve milli tıbbi cihaz üretimi konusunda ülkemizi uluslararası medikal piyasasında ileriye taşımayı hedeflemektedir. Böylece ülkemiz tıbbi cihaz ihracatı pazarındaki payını artıracaktır.

2. KAYNAK ARAŞTIRMASI

Tez çalışması kapsamında tıkayıcı uyku apnesi sendromunun teşhisi, tedavisi ve tedavide kullanılan cihaz ve teknikler hakkında detaylı bilgi toplanması amacıyla literatür taraması yapılmıştır.

Uyku apnesi tahmini için yapılmış en eski çalışmalardan biri Dagum ve Galper tarafından yapılan çalışmadır. Bu çalışmada, bayesian belief network modeli kullanılarak kalp atış hızı, göğüs hacmi, oksijen satürasyonu ve uyku durumu verileri ile apne tahmin modeli geliştirilmeye çalışılmıştır (Dagum ve Galper, 1995).

Apne tahmini üzerine yapılan önemli çalışmalardan biri de Bock ve Gough tarafından yapılan çalışmadır. Kalp hızı, solunum ve oksijen satürasyonu verilerinin kullanıldığı çalışmada, CPAP cihazların dinamik olarak geliştirilmesinde apne tahmininin önemi vurgulanmıştır (Bock ve Gough, 1998).

Literatürde yer alan bir başka çalışma ise Shin ve ark. (1998) tarafından yapılan çalışmadır. Bu çalışmada CPAP cihazlarının otomatik çalıştırılması amacıyla uykuda solunum bozukluğu miktarının belirlenmesi prensibine dayanan bir algoritma geliştirilmiştir. Geliştirilen algoritmada bulanık mantık tekniği önerilmiştir. Bulanık mantık sisteminin girişleri için hastanın nefes alımı sırasındaki nefes yolu daralması miktarı, son 15 nefese göre hipopne miktarı ve horlama yoğunluğu gibi veriler kullanılmıştır. Bulanık mantık sisteminin çıkışında ise hastanın uykuda solunum bozukluğu derecesini temsil eden bir indeks değeri üretilmiştir. Üretilen bu indeks değerinin hastanın uykuda solunum bozukluğunu ne derecede doğru ifade ettiğini doğrulamak amacıyla hastadan alınan ve analiz edilen pulmoner (akciğer) direnci, apne ve hipopne sayısı ve uyarılma (uyanma) sayısı gibi verilerle olan korelasyonları incelenmiştir. Bu korelasyon değerleri sırasıyla 0,89, 0,86 ve 0,87 olarak bulunmuştur. Bu değerlere dayanarak bulanık mantık sisteminin çıktısı olan indeks değerinin CPAP cihazının otomatik çalıştırılmasında kullanılabileceği kanısına varılmıştır (Shin ve Khoo, 1998).

Uyku apnesinin bilgisayar sistemleri vasıtasıyla tespit edilmesini esas alan çalışmalardan biri de Almas'ın (2001) biyomedikal mühendisliği alanında hazırlamış olduğu yüksek lisans tezidir. Yapılan çalışmada bir APAP makinesi için bulanık çıkarım algoritması geliştirilmeye çalışılmıştır. Çalışmada hava akış sinyali 3'er saniyelik aralıklarla analiz edilmiştir. Bu üç saniyelik dönemlerde normalleştirilmiş, alan ve

başlangıç ayarlı ve düzeltilmiş hava akım değerinin standart sapması parametre olarak alınmıştır. Bu parametreler C programlama dilinde geliştirilen bulanık mantık algoritmasına giriş olarak verilmiştir. Çalışmada toplam 9 bireyden alınan veriler kullanılmıştır. Laboratuvar ortamında yapılan ölçümler sonucunda uyku teknisyenin bulunduğu apne olaylarının sayısı ile geliştirilen bulanık mantık algoritmasının bulunduğu apne olayları kıyaslandığında %82,7'lik doğru tespit oranına ulaşılmıştır. Bu doğruluk oranı bulanık mantık prensibine göre çalışan yeni sistemin bir APAP makinesinde kullanılabileceğini göstermektedir. Çalışmada ayrıca ileride bu algoritmayı geliştirmek amacıyla yapay sinir ağları ve örüntü tanıma gibi yöntemlerin de kullanılabileceği ve bulanık mantık algoritmasındaki kurallar tabanının da bu doğrultuda geliştirilebileceği belirtilmiştir (Almas, 2001).

Nazeran ve ark. (2001) tarafından yapılan bir çalışmada tıkalı uyku apnesinin saptanması için bulanık bir çıkarım sistemi oluşturulması amaçlanmıştır. Bu çalışma için önce tıkalı uyku apnesi rahatsızlığı olan 9 hastadan uyku sırasında hava akış sinyalleri alınmıştır. Daha sonra bir uyku uzmanı tarafından test süresi boyunca apne ve hipopne olaylarını belirlenmiştir. Hastaların saat başına kaç apne olayına maruz kaldığı tespit edilerek buna apne indeksi (AI) adı verilmiştir. Geliştirilen bulanık çıkarım sisteminin tasarımında da bu AI değerleri kullanılmıştır. Çalışmada, hastadan uyku testi sırasında alınan diğer bir veri de hava akış sinyalleridir. Bu sinyaller bazı işlemlerden geçirdikten sonra 3 saniyelik aralıklarla sinyallerden elde edilen alan ve standart sapma değerleri de bulanık çıkarım algoritmasında kullanılmıştır. Sonuç olarak çalışmada 9 hasta üzerinde uyku uzmanı tarafından tespit edilen 808 adet apne olayının 668 adedi geliştirilen sistem tarafından da tespit edilerek %83 başarıya ulaşılmıştır. Buna karşın uzmanın tespit edip sistemin tespit edemediği apne sayısı 140 olarak gerçekleşmiş ve sistemin %17 oranında başarısız olduğu görülmüştür. Bunlara ilaveten, uyku uzmanının tespit etmediği fakat sistemin tespit ettiği 94 adet daha uyku apnesi olayı gerçekleşmiştir. Bunların toplam içindeki oranı ise %12 olarak hesaplanmıştır. Çalışmanın sonuç kısmında, apne tespitindeki doğruluk oranlarının hastadan hastaya da değişiklik gösterdiği özellikle belirtilmiştir. Çalışma ayrıca daha doğru sonuçlara ulaşılması için daha fazla hasta verisi ile birlikte horlama sıklığı gibi farklı bilgilerin ve sinir ağlarının kullanılmasının yararlı olacağını da önermektedir (Nazeran ve ark., 2001).

Magalang ve ark. (2003) tarafından yapılan çalışmada farklı iki uyku merkezinden uyku apnesi şüphesi ile polisomnografi ölçümleri yapılan toplam 224 hastaya ait veriler kullanılarak, çok değişkenli regresyon teknikleri ile AHI tahmini yapılmaya çalışılmıştır.

Kullanılan verilerden birisi de pulse oksimetre ile hastadan alınan SaO_2 verisidir. Çalışmada bu veriye dayanarak 3 farklı değer hesaplanmıştır. Çalışmada geliştirilen sistemin temelinde pulse oksimetre cihazı bulunduğu için ve bu cihaza erişim ucuz ve kolay olduğu için ile polisomnografiye benzer bir testin evde bile kolayca yapılabileceği ifade edilmektedir (Magalang ve ark., 2003).

Fontenla-Romero ve ark., (2005) tarafından yapılan bir çalışmada uyku apnesinin merkezi, tıkalı ya da karmaşık tiplerinden hangisine girdiği tespit edilmeye çalışılarak bir sınıflandırma yöntemi önerilmiştir. Sınıflandırıcı olarak ileri beslemeli bir yapay sinir ağı kullanılırken üç farklı denetimli öğrenme yöntemi kullanılmıştır. Yapay sinir ağına giriş verisi olarak hava akış sinyalleri ile toraks (göğüs) hareket verileri kullanılmıştır. Test işlemlerinde altı farklı hastadan veriler kullanılmıştır. Elde edilen sonuçların doğrulanması için 10 kat çapraz doğrulama uygulanmış ve sınıflandırma başarısı olarak %83,78 oranına ulaşılmıştır (Fontenla-Romero ve ark., 2005).

Tıkalı uyku apnesinin önem derecesinin tanımlanması için çift yönlü bir yaklaşım sunan bir çalışma Polat ve ark. (2008) yılında gerçekleştirilmiştir. Bu çalışmada artificial immune recognition system (AIRS) (yapay bağışıklık tanıma sistemi) ve bulanık mantık algoritmaları kullanılmıştır. Çalışmada deneyler 83 kişi üzerinde yapılmıştır ve tıkalı uyku apnesi sendromu teşhisi için bireyler 4 gruba ayrılmıştır. Bunlar normal (25 kişi), hafif (14 kişi), orta (18 kişi) ve ciddi (26 kişi). Normal olanlar uyku apnesi rahatsızlığı olmayan sağlıklı bireyler, hafif olanlar AHI değeri 5-15 arasında olanlar, orta olanlar AHI değeri 15-30 arasında olanlar, ciddi olanlar ise AHI değeri 30'dan büyük olanlar olarak belirlenmiştir. Tıkalı uyku apnesini karakterize eden bazı klinik veriler burada kullanılmıştır. Bunlar arousal (uyarılma (uyanma)) indeksi (ARI), AHI, REM dönemindeki minimum SaO_2 değeri ve SaO_2 değerinin %89'dan büyük olması durumunda percentage of sleep time (PST) (uyku süresi yüzdesi)'dir. Yapılan çalışmada dört farklı yöntemin sınıflandırma başarıları hesaplanmıştır bunlar AIRS, Fuzzy-AIRS, Pairwise AIRS ve Pairwise Fuzzy AIRS olarak belirtilmiştir. Bu yöntemlerin sınıflandırma başarıları sırasıyla %63,41, %63,41, %87,19 ve %84,4'tür. Buradan hareketle çalışmanın sonuçlarında tüm yaklaşımlara karşı en iyi sınıflandırıcı yöntemin Çiftli AIRS (Pairwise AIRS) olduğu belirtilmiştir. Çalışma aynı zamanda Pairwise AIRS ve Pairwise Fuzzy-AIRS sınıflandırıcılarını Pairwise ANFIS (Adaptive Neuro-Fuzzy Inference Systems) ile de karşılaştırmış ve tıkalı uyku apnesinin tanımlanmasında en iyi yöntemin çalışmadaki AIRS kombinasyonları olduğu kanısına varılmıştır (Polat ve ark., 2008).

Waxman ve ark., (2010) tarafından yapılan çalışmada LAMSTAR yapay sinir ağı kullanarak apne ve hipopne için otomatik tahmin ile apne ve hipopne atakları öngörülmeğe çalışılmıştır. Yapılan çalışmada dalgacık dönüşümüne dayalı ön işleme ile bir dizi polisomnografi çalışmasından elde edilen altı fizyolojik sinyal kullanılmıştır. Çalışmada en iyi tahmin REM uykusu sırasında gerçekleşmiştir. Burada geleceğe ait tahminler yapabilmek için 30 saniyelik periyotlar kullanılmıştır. Böylece gelecekteki 60 saniyelik zaman dilimlerine varan doğru tahminler yapılabilmektedir. Sistem apne ataklarını öngörmede %80,6 ve hipopne ataklarını öngörmede ise %74,4 kadar duyarlılık göstermiştir. Ayrıca çalışmanın sonuç kısmında apne ve hipopne öngörüsünde kullanılabilecek en önemli verilerde belirtilmiştir. Bunlar apne öngörüsü için çene ucu altı kaslarındaki hareketlilik (submental EMG), hipopne öngörüsü için ise çene ucu altı kaslarındaki hareketlilik (submental EMG) ve kalp hızı değişkenliği olarak belirtilmiştir (Waxman ve ark., 2010).

Tagluk ve Sezgin, (2011) tarafından yapılan çalışmada, EEG sinyallerinin bisektral özelliklerini ve yapay sinir ağları yöntemini kullanarak tıkayıcı uyku apnesinin tespit edilebilmesi için bir yöntem ortaya koyulmuştur. EEG sinyallerinden ön işleme ile hesaplanan değerler tasarlanan yapay sinir ağına giriş olarak verilmiş ve ağ biri normal durum, diğeri de apne durumunu gösteren iki çıkışlı olarak tasarlanmıştır. Ortaya koyulan teknik ile %96,15 oranında doğruluk elde edilerek önerilen yöntemin tıkayıcı uyku apnesi tanımlama sistemlerinin tasarlanmasında kullanılabileceği söylenmiştir (Tagluk ve Sezgin, 2011).

Marcos ve ark. (2012) tarafından yapılan bir çalışmada da geceleyin uyku sırasında alınan pulse oksimetre kayıtları kullanılarak AHI tahmini üzerine çalışılmıştır. AHI'nin belirlenmesinde PSG'nin maliyetli ve zaman alıcı bir yöntem olduğunun belirtildiği çalışmada pulse oksimetre ile ölçülen SaO_2 kayıtları kullanılarak yeni bir tahmin yaklaşımı sunulmuştur. Çalışma boyunca 96'sı eğitim amaçlı, 114'ü test amaçlı olmak üzere toplam 240 SaO_2 sinyal verisi kullanılmıştır. Uyku apnesi sendromunun SaO_2 değerlerinin değişimi üzerindeki etkisini ölçmek için 14 zaman alanı ve frekans bölgesi özellikleri kullanılmıştır. Çıkarılan bu özellikler ile AHI arasındaki ilişkiyi belirlemek için de regresyon analizi metodu kullanılmıştır. Çalışmada çoklu lineer regresyon modelinin yanı sıra çok katmanlı yapay sinir ağı modeli de kullanılmış ve karşılaştırılmıştır. Çoklu lineer regresyon modeli 0,80 regresyon katsayısı sağlarken, çok katmanlı ağ 0,91'lik bir regresyon katsayısına ulaşmıştır. Sonuç olarak çok katmanlı yapay sinir ağı tabanlı yöntemin elde ettiği 0,91'lik bir korelasyon katsayısı değeriyle,

PSG kullanılmadan uyku apnesi teşhisi için doğru ve uygun maliyetli bir yöntem olarak kullanılabileceği kanaatine varılmıştır (Marcos ve ark., 2012).

Tıkalıcı uyku apnesinin ciddiyet seviyesini gösteren AHI'yi tahmin etme amacıyla yapılan bir çalışmada, 155 hastadan solunum sırasından ses sinyalleri kaydedilmiş ve bu sinyallerden 127 özellik çıkarmıştır. Daha sonra genetik algoritmalar yöntemi ile özellik seçimi uygulanmış ve en etkili 3 özellik seçilerek bir regresyon modeli uygulanarak AHI değerleri tahmin edilmeye çalışılmıştır. Pearson korelasyonu, AHI hatası ve teşhis doğruluğu yöntemlerini baz alan çalışma sonucunda 0,89 korelasyon katsayısına ulaşılmıştır (Dafna ve ark., 2013).

Maali ve Al-Jumaily (2013) tarafından yapılan çalışmada, uyku apnesi tahmininde kullanılan üç farklı neural network performansları incelenmiştir. Bunlar, Elman, Radial Basis Function (RBF) network ve Feed-Forward (FF) back propagation yöntemleridir. Çalışmada 5 hastaya ait hava akımı, abdominal ve thorax hareket sinyalleri kullanılmıştır. Bu sinyaller 30, 60, 90 ve 120 saniyelik farklı pencere boyutları ile incelenmiştir. Area under ROC curve (AUC) sonuçlarına bakılarak yapılan karşılaştırmada en yüksek başarı %86 olarak elde edilmiştir. Bu değer 90 saniyelik pencere kullanımı ve Feed-Forward algoritması ile elde edilmiştir (Maali ve Al-Jumaily, 2013).

Apne sınıflandırmasıyla ilgili bir başka çalışma da Al-Mardini ve ark. (2014) tarafından yapılmıştır. Bu çalışmada hastanın oksijen seviyesini ölçmek için oksimetre, solunum çabasını algılamak için mikrofon, vücut hareketlerini tespit etmek için ivme ölçer ve bir de akıllı telefon kullanılmıştır. 15 hastadan alınan verileri üzerinde yapılan çalışmada hastalık teşhisi için yapılan sınıflandırma işlemlerinde %87,5 doğruluk oranına ulaşılmıştır (Al-Mardini ve ark., 2014).

Çocuklarda uyku apnesinin taranabilmesi için bir çalışma da Erazo ve Rios (2014) tarafından yapılmıştır. Bu çalışmada EKG, Air Flow ve SpO₂ verileri için ayrı ayrı sinyal işleme işlemleri gerçekleştirilmiştir. Özellik çıkarma amacıyla wavelet transform ile birçok dalgacık fonksiyonu denenmiştir. Yapılan çalışmada çıkarılan özellikler Support Vector Machine (SVM), Artificial Neural Network (ANN) ve Logit Model ile sınıflandırılmıştır. Çalışmada en yüksek doğruluk oranı SpO₂ sinyallerinin Harr dalgacık fonksiyonu ile işlenmesinden elde edilen özelliklerin Logit Model ile sınıflandırılmasından elde edilen %59,03'tür (Erazo ve Ríos, 2014).

İstanbul Teknik Üniversitesi'nde yapılan bir çalışmada tıkalıcı uyku apnesi sendromunun ciddiyet seviyesinin belirlenmesi amacıyla bir bulanık uzman sistem geliştirilmiştir. Yapılan çalışmada robotik cerrahi ameliyatı geçirmiş 24 hastanın ameliyat

öncesine ait vücut kitle indeksi, kanadaki oksijen çözünürlüğünü gösteren SaO_2 değeri, ağız açıklığını gösteren mallampati skoru ve boyun çevresi ölçüleri kullanılmıştır. 14 hastaya ait veriler sistemin tasarımında kullanılırken, 10 hastaya ait veriler ise test verileri olarak kullanılmıştır. Geliştirilen bulanık mantık sisteminde çıkarım yöntemi olarak mamdani metodu kullanılmıştır. Çalışma sonucunda hastaya ait AHI hesaplanmıştır. İlk başta bulanık olarak hesaplanan bu değerler durulaştırıldıktan sonra sistemin çıktısı olarak ciddiye seviyesini gösteren hafif, orta ve ağır şeklinde sınıflandırma verisi elde edilmiştir. Ayrıca çalışmanın sonuç kısmında bulanık uzman sistem ile AHI tespitinin klasik yöntemlerle AHI tespitinde bulunmayan “orta-yüksek”, “hafif-orta” gibi ara noktalara göre de sınıflandırma yapabilme imkânı sunduğu belirtilmiştir (Zoroğlu, 2015).

Samy ve ark. (2015) tarafından yapılan bir çalışmada, PSG sistemine alternatif olarak hastaların uyku kalitesi, uykusuzluk, kaygı, depresyon gibi psikolojik durumlarına ve 24 saatlik aktivite durumlarına dayanarak bir uyku apnesi tahmin aracı geliştirilmeye çalışılmıştır. 16 hasta verisi ile yapılan çalışmada sınıflandırıcı olarak SVM ve k-Nearest-Neighbor (k-NN) kullanılmıştır. Sınıflandırıcıların apne var-yok şeklinde iki çıktı üzerinde çalıştırıldığı çalışmada, k-NN %75,1 başarı gösterirken SVM %79,8 sınıflandırma başarısı göstermiştir (Samy ve ark., 2015).

Nandakumar ve ark. (2015) tarafından yapılan çalışmada hastaya bağlanan karın ve göğüs hareketlerini algılayan bir sensörden alınan veriler kablosuz olarak akıllı telefona aktarılmıştır. Geliştirilen sınıflandırıcı yazılım sayesinde hastanın geçirdiği santral apne, tıkalı apne ve hipopne gibi solunum olayları tespit edilmeye çalışılmıştır (Nandakumar ve ark., 2015)

Lee ve ark. (2015) tarafından yapılan bir çalışmada, PSG’nin pahalı ve karmaşık bir işlem olduğu belirtilerek, EKG ve karın hareketleri verilerine dayanarak uyku apnesinin tespitinde kullanılmak üzere bir sistem geliştirilmesi amaçlanmıştır. Çalışmada, verilere sinyal işleme uygulandıktan sonra çıkarılacak özelliklere dayanarak makine öğrenmesi teknikleri ile bir teşhis algoritması geliştirilmiştir. Geliştirilen algoritma apne tespitinde %85 doğruluk değerine ulaşmıştır (Lee ve ark., 2015).

Tek kanallı EKG sinyallerinden faydalanılarak otomatik uyku apnesi tespiti üzerine bir başka çalışma Varon ve ark. (2015) tarafından yapılmıştır. Bu çalışmada EKG sinyalinden elde edilen RR aralığının standart sapması ve seri korelasyon katsayıları kullanılmıştır. 80 adet EKG kaydının kullanıldığı çalışmada sınıflandırıcı olarak SVM yöntemi kullanılmıştır. Çalışma sonuçlarına bakıldığında %84,74 doğruluk oranı elde edildiği görülmüştür (Varon ve ark., 2015).

Cohen ve de Chazal (2015) tarafından yapılan bir çalışmada bebeklerde uyku apnesinin erken teşhis edilebilmesi için EKG ve pulse oksimetre verilerinden yararlanılmıştır. Bebeklere ait PSG kayıtları üzerinde yapılan çalışmada EKG ve nabız sinyalleri işlenerek özellikler çıkarılmıştır. Çıkarılan özellikler Linear Discriminant yöntemi ile sınıflandırma işlemine tabi tutulmuş ve geliştirilen algoritmanın %66,7 doğruluk gösterdiği tespit edilmiştir (Cohen ve de Chazal, 2015).

Hassan ve Haque (2016) tarafından yapılan çalışmada tek kanallı EKG verilerinden çıkarılan istatistiksel ve spektral özellikler sınıflandırma algoritmaları kullanılarak apne tespiti yapılmaya çalışılmıştır. Önerilen sistem apne tespitinde %85,97 doğruluk sağlamıştır (Hassan ve Haque, 2016).

Tıkalıcı uyku apnesinin sınıflandırılması için Öter ve ark. (2016) tarafından yeni bir yöntem önerilmiştir. Çalışmada 2'si sağlıklı birey olmak üzere toplam 10 kişinin yaklaşık 8 saatlik uykuları ile elde edilen PSG verileri kullanılmıştır. Yapılan çalışmada yapay sinir ağları (YSA) yöntemi ile dijital görüntü işlemede kullanılan morfolojik filtreler kullanılarak Uyku apnesinin belirlenmesi amacıyla bir yöntem önerilmiştir. Çalışmada kullanılan 3 katmanlı ileri beslemeli bir YSA yapısı oluşturulmuştur. Sadece YSA kullanılarak yapılan çalışmanın başarısı düşük olduğu için morfolojik filtre kullanılmış ve bu da başarıyı oldukça artırmıştır. Çalışma sonucunda yapılan skarlama ile uyku uzmanı hekimin yaptığı skarlama karşılaştırılmıştır. Önerilen bu yeni yöntemle ortalama %90,7 doğru sınıflandırma başarısı elde edilmiştir. Ayrıca çalışmanın apne tespitinde geçen zaman kaybını da ortadan kaldıracağı ileri sürülmüştür (Öter ve ark., 2016).

Literatürde yer alan bir başka çalışma da Doğan ve Ölmez (2016) tarafından yapılmıştır. Bu çalışmada solunum sinyallerinden bant spektral özelliklerin çıkarılması ve bu özelliklerin normal solunum ile apneli solunum durumlarının arasındaki fark kontrolü ile uyku apnesi tespiti yapmayı amaçlayan bant spektral özellikleri yöntemi esas alınmıştır. Bu doğrultuya uygun olarak solunum sinyalleri üzerinde gürültüleri gidermek amacıyla filtreler uygulanmış ve keskinleştirici ek özellikler ilave edilerek daha başarılı sonuçlar alınması sağlanmıştır. Çalışmada kullanılan veriler internet üzerindeki hazır veri tabanlarından elde edilen 100 hastaya ait PSG kayıtlarıdır. Apne tespiti için oluşturulan algoritmada önce solunum sinyalleri 0,7 Hz'lik kesim frekansına sahip bir alçak geçiren filtre ile gürültüden arındırılmıştır. Çalışmada apne tespitinde kullanılma üzere 0,2, 0,5, 1 ve 2 saniyelik hassasiyet aralıkları belirlenmiş ve her biri için testler yapılmıştır. Hassasiyet süresinin azalması apne tespitindeki bulgulara başarı artmış fakat hesaplama

süresi uzamıştır. Hesaplama süresi de göz önünde bulundurularak hassasiyet değeri 1 saniye olarak alınmıştır. Çalışmanın sonuç kısmında dört farklı veri tabanı üzerinde yapılan çalışmalarda apne tespitinde %84,6, %81,1, %70,5 ve %83,1 oranında başarı sağlandığı belirtilmiştir (Doğan ve Ölmez, 2016).

Tıkayıcı uyku apnesi tedavisinde PAP tedavisinin bireyin uyku kalitesi üzerinde ne derece etkili olduğunu ortaya koyması açısından Atan ve ark. (2017)'lerinin yaptıkları çalışma dikkat çekicidir. Bu çalışmada polisomnografi ölçümlerine göre orta ve ağır derecede tıkayıcı uyku apnesi olduğu teşhisi koyulan 114 hastadan alınan veriler kullanılmıştır. Alınan veriler ile PAP tedavisi devam ederken alınan verilerle elde edilen uyku evreleri verileri istatistiksel yöntemlerle karşılaştırılmıştır. Çalışma sonuçlarına göre evre 3 uykusu orta seviye hastalarda %22, ağır seviye hastalarda %45 artarken, REM uykusunun ise orta seviye hastalarda aynı kaldığı ve ağır seviye hastalarda %28 arttığı gözlenmiştir. Bu sonuçlar PAP tedavisinin tıkayıcı uyku apnesi tedavisindeki etkinliğini göstermesi açısından çok önemlidir (Atan ve ark., 2017).

Johnson ve Rapoport (2017) tarafından yapılan bir çalışmada gelecekte PAP cihazlarının geliştirilmesi için makine öğrenmesi ve ayarlanabilir algoritmalar aracılığıyla kişiselleştirilmiş PAP tedavisi gibi çalışmaların yapılabileceğinden bahsedilmiştir (Johnson ve Rapoport, 2017).

Uyku apsesinin tespit edilmesinde yalnızca pulse oksimetre sinyallerini kullanan iki yaklaşım Rolon ve ark. (2017) tarafından ortaya koyulmuştur. Ortaya koydukları bu yaklaşımlara disriminatif aktivasyon seçimi ve en ayırt edici sütun seçimi adını vermişlerdir. Çok katmanlı YSA kullanılan bu çalışmada en yüksek sınıflandırma başarısı en ayırt edici sütun seçimi yaklaşımı ile %86,25 olarak gerçekleşmiştir (Rolon ve ark., 2017).

Elwali ve Moussavi (2017) tarafından yapılan bir çalışmada, kişi uyanık iken tıkayıcı uyku apnesi taraması ve havayolu karakterizasyonu ile ilişkisi üzerinde durulmuştur. Çalışmada, önce PSG kayıtları alınan ve AHI'leri hesaplanan 147 hastadan uyanık iken sırtüstü pozisyonda solunum ses sinyalleri kaydedilmiştir. Bu sinyallerden 26 özellik çıkarılmıştır. Daha sonra en ayırt edici 3 özelliğin seçilmesi için özellik seçimi işlemi uygulanmıştır. Sınıflandırıcı olarak SVM kullanılan çalışmada %83,92 doğruluk oranına ulaşılmıştır (Elwali ve Moussavi, 2017).

Li ve ark. (2018) yılında yaptıkları çalışmada EKG sinyallerinin tıkayıcı uyku apnesini tespit etmede PSG'ye alternatif bir yöntem olarak kullanılabileceği belirtilmiştir. Bu sebeple EKG sinyallerini giriş olarak kullanan Hidden Markov modelini (HMM) derin

sinir ağılarına dayanan bir yöntem önerilmiştir. Bu yöntemle sadece etiketlenmiş EKG sinyallerini kullanarak bir öğrenme algoritması ortaya koyulmuştur. Çalışmada sınıflandırma doğruluğu olarak %85, hassasiyet olarak da %88,9 başarı elde edilmiştir. Deneysel sonuçlar önerilen yöntemin tıkayıcı uyku apnesi tespitinde kullanılabileceğini göstermektedir (Li ve ark., 2018).

Choi ve ark. (2018) tarafından yapılan çalışmada, uyku apnelerinin gerçek zamanlı tespiti için convolutional sinir ağıları kullanılmıştır. 179 hastaya ait nazal basınç sinyallerinin kullanıldığı çalışmada apne tespitinde %96,6 doğruluk oranı elde edilmiştir (Choi ve ark, 2018).

Arslan Tuncer ve ark. (2019) tarafından yapılan bir çalışmada tıkayıcı uyku apnesi tespiti için Pulse Transit Time (PTT) (Nabız Geçiş Süresi) sinyalleri bir derin öğrenme yöntem olan Convolutional Neural Network (CNN) ile işlenerek özellik çıkarma işlemi yapılmıştır. Elde edilen özellikler SVM ve k-NN algoritmaları ile sınıflandırılmıştır. Çalışma sonucunda en yüksek sınıflandırma başarısını %92,78 oranıyla SVM algoritması göstermiştir (Arslan Tuncer ve ark., 2019).

EKG verileri kullanılarak uyku apnesi tespiti yapan bir çalışma da Pinho ve ark. (2019) tarafından yapılmıştır. Sinyal işleme işlemlerinden sonra özellik seçimi gerçekleştirilen çalışmada birçok sınıflandırıcı denenmiş ve en yüksek sınıflandırma performansı olarak, YSA yöntemi ile %82,12 değerine ulaşılmıştır (Pinho ve ark., 2019).

Bozkurt ve ark. (2020) bir çalışmada, tıkayıcı uyku apnesi tanısında kullanılan solunum skorlaması yapmak amacıyla tek kanallı EKG sinyalleri kullanılmışlardır. Bu sinyallerden elde edilen özellikler Fisher özellik seçme algoritması ile azaltılmıştır. Çalışma sonunda apne tespiti için sadece 3 özellik ile %82,11, 13 özellik ile %85,12 doğruluk değerlerine ulaşılmıştır (Bozkurt ve ark., 2020).

Literatürde yer alan başka bir çalışma Tsouti (2020) tarafından yapılmıştır. Bu çalışmada abdominal ve thorax hareketlerinden elde edilen sinyaller kullanılarak makine öğrenmesi yöntemleri ile sınıflandırma yapılarak apneler tahmin edilmeye çalışılmıştır. Çalışma sonuçlarına göre ortalama %82 oranında doğruluk elde edilmiştir (Tsouti et al. 2020).

Molin ve ark. (2021) tarafından uyku apnesi üzerine yapılmış güncel bir çalışmada 42 hastadan gece boyunca solunum verileri akıllı telefonlar vasıtasıyla kaydedilerek apne riski tahmin edilmeye çalışılmıştır. Hızlı Fourier dönüşümü kullanılan çalışmada Random Forest (RF) sınıflandırıcı %93 ve SVM sınıflandırıcı %90 başarı elde etmiştir (Molin ve ark., 2021).

Watson ve Fernandez (2021) uyku tıbbında YZ kullanımını anlattıkları çalışmalarında, uyku bozuklukların taranması, teşhis ve tedavisinde kullanılabilecek YZ tekniklerinden ve bu tekniklerin öneminden bahsetmişlerdir. Buna ilave olarak, bu çalışmada YZ sayesinde kişiselleştirilmiş ve hassas uyku tıbbı çalışmalarının yapılabileceğinden bahsedilmiştir (Watson ve Fernandez, 2021).

Sharma ve ark. (2022) yaptıkları çalışmada doğum yapmamış hamile kadınlarda otomatik uyku apnesi tespiti sağlayan bir sistem önermişlerdir. 3012 hamile kadına ait verilerin kullanıldığı çalışmada, ortogonal bir dalgacık filtre bankası ile tek kanallı bir hava akımı sinyalinin kullanılmıştır. Çalışma sonuçlarında RUS Boosted ağaç sınıflandırıcı kullanılarak 0.91 F1 puanı ve %83,9'en yüksek doğruluk elde edildiği belirtilmiştir (Sharma ve ark., 2022).

Zhuang ve ark. (2022) yaptıkları çalışmada uyku apnesini için hastaya temas etmeden tespit edebilecek bir sistem önermişlerdir. Bu sistemde hastanın uyuduğu odada FMCW radar kullanılmış ve bu radardan elde edilen sinyaller işlenmiştir. İşlenen sinyaller makine öğrenmesi yöntemleri ile sınıflandırılarak apne var yok şeklinde iki sınıf belirlenmeye çalışılmıştır. Çalışma sonuçlarında önerilen sistemin %95,53 doğruluk, %72,60 duyarlılık, %97,32 özgüllük, 0,68 Kappa ve 0,84 F skor oranlarına ulaştığı belirtilmiştir (Zhuang ve ark., 2022).

Yu ve ark. (2022) uyku apnesinin otomatik tespiti ve alt tiplerinin sınıflandırılması amacıyla yaptıkları çalışmada, tek kanallı EEG, oronazal akış ve abdominal hareket sinyallerini kullanmışlardır. Tıkayıcı uyku apnesi, santral apne, karmaşık apne ve hipopnelerin sınıflandırılmasına çalışılan bu çalışma sonuçlarında genel sınıflandırma doğruluğunun %83,94 olduğu ifade edilmiştir (Yu ve ark., 2022).

Lin ve ark. (2022) tarafından yapılan bir başka çalışmada da hastaya temas edilmeden uyku apnelerinin tespiti üzerinde çalışılmıştır. Bu çalışmada, 32 hastaya ait horlama sinyalleri toplanmıştır. Toplanan bu sinyaller işlendikten sonra hibrit derin sinir ağlarına dayalı bir sınıflandırma modeli ile sınıflandırılmıştır. Çalışma sonuçlarında tıkayıcı apne horlamaları, santral apne horlamaları, hipopne ve normal horlamaların ortalama sınıflandırma doğruluğu %74,27 olarak hesaplanmıştır (Lin ve ark., 2022).

Wang ve ark. (2022) tarafından yapılan diğer bir çalışmada ise Uyku apnesi tespiti için tek kanallı EKG sinyalleri kullanılmıştır. Yapılan bu çalışmada çok ölçekli derin öğrenme yöntemi kullanan bir sinir ağı önerilmiştir. URNet' e ait Apne-EKG veri seti üzerinde yapılan çalışmada %90,4 doğruluk, %83,3 duyarlılık, %94,8 özgüllük ve %89,6 F1 elde edildiği ifade edilmiştir (Wang ve ark., 2022).

Yapılan literatür araştırmalarında, uyku apnesi tespiti için farklı fizyolojik sinyalleri kullanan çalışmalar olduğu görülmüştür. Fizyolojik sinyallerin yanı sıra radar sinyalleri, ses sinyalleri kullanan çalışmalar da mevcuttur. Literatürdeki yapay zekâ tekniklerinin kullanıldığı akademik çalışmaların çoğunda apne olaylarının varlığının tespiti, anpe tipinin sınıflandırılması ya da apne hipopne indeksinin belirlenmesi üzerine çalışılmıştır. Hasta uyuduğu esnada apneye girmeden yani hava yolunda bir daralma oluşmadan tahmin etmeye dönük çalışmaların sayısı oldukça sınırlıdır. Bu çalışmada ise, hem apne oluşmadan apnelerin tahmin edilmesinin ön habercisi olabilecek en etkili fizyolojik sinyallerin belirlenmesi, hem de bu sinyalleri kullanarak makine öğrenmesi yöntemleri ile apneleri oluşmadan tahmin etme işlemleri bir arada yapılmıştır. Bu çalışma apne tespiti değil apneyi tahmin üzerine temellendirilmiştir. Hastadan elde edilen biyomedikal sinyaller 30 saniyelik epoklara ayrıldıktan sonra, bir epokta yer alan veri ile bir sonraki epokta meydana gelebilecek apneler tahmin edilmiştir. Bu tez çalışmasında sadece teorik olarak apne tahmini ile yetinilmemiş apne tahmini ile çalışan bir PAP cihazı da geliştirilmiştir.

Tez kapsamında geliştirilen cihaz, apne tahmin sistemi üzerine çalıştığı için, hastadan bir epokta elde ettiği verilerle bir sonraki epokta henüz apne oluşmadan bunu tahmin edebilen ve apne oluşma riskini ortadan kaldırma amacıyla pozitif hava basıncını ayarlayan yapay zekâ tabanlı yeni nesil bir sistemdir. Bu yöntemle göre hasta apne yaşamadan önce cihaz bunu algılayarak önleyici terapi uygular ve apne riski apne oluşmadan ortadan kaldırılır. Böylece hastalar daha konforlu bir şekilde uyurlar.

Ayrıca, bu çalışmada sadece apne tahmini ile yetinilmemiş ve bir PAP cihazının apne riskini ortadan kaldırma amacıyla hastaya uygulayacağı pozitif hava basıncının da otomatik olarak belirlenmesini sağlayan, gerçek zamanlı öğrenen bir algoritma ortaya koyulmuştur. Buna ilaveten, gerekli gördüğünde sistemin kendi parametrelerini adaptif olarak güncellenmesi de sağlanmıştır. Yapılan literatür araştırmalarında, apne tespit veya tahmini üzerine yapılmış gerçek zamanlı makine öğrenmesi ile çalışan adaptif bir sistem çalışmasına rastlanmamıştır. Ayrıca, literatürdeki bu çalışmalarda cihaz uygulaması da bulunmamaktadır. Tüm literatür araştırmaları ile karşılaştırıldığında bu çalışma, hem gerçek zamanlı öğrenen ve adaptif bir yapıda çalışması, hem de sadece teoride kalmayıp cihaz uygulamasına dönük olmasından dolayı literatüre büyük bir yenilik kazandıracaktır. Gerçek zamanlı öğrenme yeteneğine sahip bu adaptif sistem ile hastalar apneye girmeden havayoluna gönderilecek pozitif hava ile apne riski ortadan kaldırılacak ve hastalar daha

konforlu bir şekilde uyuyabileceklerdir. Buna ilaveten, bu çalışma uyku servislerinin de iş yükünün azalmasına katkı sağlayacaktır.



3. MATERYAL VE METOT

3.1. Biyomedikal Sinyal İşleme

Sinyal, fiziksel büyüklüklerin değişimi hakkında bilgi taşıyan ve matematiksel olarak ifade edilebilen değerlerdir. Örneğin bir sesin havada oluşturduğu basınç dalgaları, ortamdaki sıcaklık, basınç, kuvvet, ışık değişimleri gibi birçok unsurun oluşturduğu eşdeğer elektrik voltaj ve akım seviyesinin zamana bağlı ifadesine sinyal denir.

Bu tip fiziksel büyüklükler doğada her alanda görülebildiği gibi canlılar üzerinde de görülebilir. Canlılar üzerinden elde edilebilen bu değerlere biyomedikal sinyaller denir. Biyomedikal sinyaller canlıların sinir sisteminde yer alan sinir hücrelerinin elektriksel aktiviteleri sonucunda oluşurlar. Bu elektriksel aktiviteler çeşitli sensörler vasıtasıyla algılanarak bir elektriksel büyüklük (voltaj, akım) olarak ifade edilebilen değerlere dönüştürülür. Sensörler belirli periyotta tekrarlayan şekilde bu algılamaya işlemini yaparak elektriksel büyüklüğü oluştururlar. Bu süreye örnekleme periyodu, bunun tekrarlama sıklığı olarak ifade edilmesine de örnekleme frekansı denir. Örneğin, saniyede 4 kere algılama yapan sensör 4 Hz, saniyede 32 kere algılama yapan sensör 32 Hz, saniyede 256 kere algılama yapan sensör 256 Hz örnekleme frekansına sahip demektir. Sensörlerden gelen elektriksel büyüklükler zamana bağlı ve sürekli değişen değerler olarak kaydedilir. Elde edilen ilk veriler analog sinyallerdir. Bu sinyaller çeşitli amaçlarla kullanılabilmesi için daha sonra sayısal formatta ifade edilecek şekilde dönüştürülebilir. Bu dönüşümden elde edilen sinyaller de sayısal (dijital) sinyaller olarak ifade edilir. Bunu yapan elektronik sistemlere Analog Digital Converter (ADC) (Analog sayısal çevirici) denilmektedir.

Canlılar üzerinden biyomedikal sinyallerin elde edilmesi için sensörlerin geliştirilmesi tıp dünyası için bir milat olduğu söylenebilir. Günümüzde birçok hastalığın teşhis ve tedavisinde biyomedikal sinyallerden faydalanılmaktadır. Bu amaçla birçok ölçüm ve sinyal tipi ortaya çıkmıştır. Bunlardan bazıları EKG, EMG, EEG, EOG, PTT, PLM, nabız, satürasyon, snore, thorax sinyalleridir. Tabii ki sadece sinyallerin analog ya da sayısal olarak elde edilmesi onların istenilen amaca uygun kullanılabilmesi için yeterli değildir. Elde edilen bu sinyallerden anlamlı bilgiler çıkarılabilmesi için yapılan tüm işlemlere biyomedikal sinyal işleme denilmektedir.


Sinyaller iki alanda değerlendirilirler. Zaman domen (alanı) ve frekans domen (alanı). Yukarıda da ifade edildiği gibi sensörler vasıtasıyla elde edilen sinyaller ilk başta zaman domeninde değerlendirilir. Sinyal işleme süreçlerinde sinyalden faydalı anlamlar çıkarabilmek için sinyallerin sadece zaman domeninde incelenmesi yeterli görülmez. Bu açıdan zaman domenindeki sinyallerin frekans domenine dönüştürülerek de ifade edilmesi gerekir. Bu dönüşüm işlemleri sinyal işlemenin en temel işlemlerindendir. Aşağıda bu tez çalışmasında kullanılan dönüşüm yöntemleri yer almaktadır. Ayrıca sinyal işleme süreçlerinden olan ön işleme işlemleri ve analiz işlemleriyle ilgili olarak da bilgiler sunulmuştur.

3.1.1. Sinyaldeki gürültülerin giderilmesi

Elektronik ve bilgisayar sistemlerinde veri bir iletken ya da elektromanyetik dalgalar vasıtasıyla sinyaller şeklinde iletilir. Bir sinyalin içerisinde kaydedilirken ya da bir yerden başka bir yere transfer edilirken verinin alındığı cihazlardan ya da taşındığı ortamlardan kaynaklanan ve istenmeyen bileşenler bulunabilir. Sinyal içerisine karışmış bu istenmeyen bileşenlere gürültü ya da parazit denir. Gürültü sinyal kalitesini olumsuz yönde etkiler ve o sinyalden çıkarılması amaçlanan asıl anlamlı verileri baskılar. Bu nedenle bir sinyal işlenirken sinyal analiz edilmeden önce gürültülerden arındırılması gerekmektedir. Sinyalin gürültüden arındırılması analog ya da sayısal filtreler vasıtasıyla yapılır. Filtreleme sinyaldeki frekans değeri baz alarak yapılan bir işlemdir. Dört tip filtreleme yapılabilmektedir. Bunlar aşağıdaki gibidir:

- Alçak geçiren filtre (LP, Low Pass),
- Yüksek geçiren filtre (HP, High Pass),
- Bant geçiren filtre (BP, Band Pass),
- Bant bastıran (geçirmeyen, durduran) filtre (BR, Band Reject)


Bu filtre tiplerine ait grafikler Şekil 3.1’de gösterilmiştir.



Şekil 3.1. Filtre tipleri

3.1.2. Spektral analiz

Sinyal işleme çalışmalarında sinyalden anlam çıkarabilmenin ilk adımı spektral analiz yapılmasıdır. Spektral analiz, sonlu uzunluktaki sabit bir veri dizisinde, bütün frekansların ya da dar spektral bir bant üzerinde dağılan toplam gücün tahminidir. Böylece verilerin hangi frekansta daha yoğun olduğu anlaşılabilir. Spektral analiz sonucunda verilerin zamana göre dağılımı elimizde olan verilerin frekansa göre dağılımı elde edilmiş olur. Biyomedikal sinyallerde frekans içeriğinin çözülmesi işlemi de bir spektral analizdir. Spektral analiz bir prizmanın ışığı renklerine ayırdığı gibi sinyali frekans bileşenlerine ayırır (Özmen, 2013). Biyolojik sinyallerin çoğu gibi PSG sinyalleri de durağan olmayan ve zamanla değişen sinyaller olduğu için spektral analiz oldukça önemlidir (Semmlow, 2004). Biyomedikal bir sinyale ait spektral analiz çıktısı Şekil 3.2’de gösterilmiştir.



Şekil 3.2. Spektral analiz (Subasi, 2019)

Spektral analiz, biyomedikal sinyallerde sinyalin tanım aralığını belirleme ve anlamlı frekans aralığındaki özellikleri çıkarmak için önemli bir işlemdir. Spektral analiz teknikleri, eğer sinyalin zamanı önemli değilse güçlü bir işaret işleme aracı olarak kullanılmaktadır. Spektral analiz teknikleri, Fourier dönüşümüne bağlı klasik (parametrik olmayan) yöntemler ve model parametrelerinin tahminine dayanan modern (parametrik) yöntemler olmak üzere iki grupta incelenebilir. (Özmen, 2019). Klasik ve modern yöntemler, statik dalgalar için uygun bir çözüm sağlar. Fakat biyomedikal sinyallerin hemen hemen hepsi statik değildir (Özmen, 2013; Semmlow, 2004). Fourier analizi dalga'nın frekansı ile ilgili önemli bilgiler sağlar ancak frekansların hangi zaman aralığında olduğunu göstermez. Fourier analizi durağan sinyaller için uygun bir yöntemdir, çünkü durağan sinyallerin frekansı zamana göre değişmez, ancak durağan olmayan sinyallerin frekansı zamana göre değiştiği için, zaman kavramının da ele alınması gereklidir. Dalgadan hem zaman hem de frekans bileşenlerini elde etmek için birçok yöntem geliştirilmiştir. Bu yöntemler de kendi aralarında zaman-frekans yöntemleri ve zaman ölçekli yöntemler olmak üzere ikiye ayrılmaktadır.

Klasik (parametrik olmayan) yöntemler:

- Fourier Dönüşümü
- Kısa Zamanlı Fourier Dönüşümü
- Dalgacık Dönüşümü
- Power spectrum density (Welch) Metodu

Modern (parametrik) yöntemler:

- AR Metodu
 - Yule Walker yöntemi
 - Burg yöntemi
 - Covariance yöntemi
- MA Metodu
- ARMA Metodu

3.1.2.1. Fourier dönüşümü

Zaman domenindeki sinyallerin frekans bileşenlerinin incelenebilmesi en iyi bilinen ve en sık kullanılan yöntem Fourier dönüşümüdür. Bir başka deyimle zaman tabanlı sinyali, frekans tabanlı hale getirir. Biyomedikal sinyallerin incelenmesinde de sinyallerin anlamlandırılmasında Fourier dönüşümü sıkça kullanılmaktadır. Frekans domenine dönüştürülmüş sinyallerin de incelenmesinde bazı dezavantajlar vardır. Bunlardan biri de sinyalden zaman bilgisinin olmamasıdır (Oppenheim, 1989). Zaman domenindeki $x(t)$ sinyalinin frekans domenine dönüştürülmüş $X(\omega)$ halini gösteren Fourier dönüşümünün matematiksel ifadesi Denklem 3.1’de gösterilmiştir.


$$X(\omega) = F(x(t)) = \int_{t=-\infty}^{\infty} x(t) \cdot \exp(j\omega t) \cdot dt \quad (3.1)$$

Sürekli zamanlı periyodik olmayan sinyallerin işlenmesinde kullanılan en yaygın yöntem Ayırık Fourier Dönüşümü (AFD)’dür. Bu yöntem zaman uzayındaki bir diziyi frekans uzayındaki eşdeğer bir diziye dönüştürür. Hızlı Fourier Dönüşümü (HFD) ise AFD tabanlı çok verimli bir yöntemdir ancak AFD’den çok daha az hesap yükü gerektirir.

Bu yüzden daha hızlıdır. HFD sayısal işaret işleme uygulamalarında zaman açısından avantajlı olduğu için frekans spektrum analizinde oldukça yaygın olarak kullanılır. HFD matematiksel ifadesi Denklem 3.2’de gösterilmiştir.

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-j\left(\frac{2\pi}{N}\right)kn} \quad ; \quad k=0, 1, \dots, N-1 \quad (3.2)$$

Bu yöntem MATLAB’da “fft” fonksiyonu ile yaptırılır. Örnek olarak bir EMG sinyalinin “fft” fonksiyonu çıktısı Şekil 3.3’te gösterilmiştir.



Şekil 3.3. EMG sinyalinin fft çıktısı


Şekil 3.3’te görüleceği gibi, bir EMG sinyali periyodik olmayan yani zaman içerisinde değişiklik gösteren bir sinyaldir. EMG gibi biyomedikal sinyallerin çoğu periyodik olmayan sinyallerdir. Bu tip sinyallerin işlenmesinde zaman domeninde incelenmesi yeterli değildir. Bu yüzden biyomedikal sinyallerden daha net bilgiler elde edilebilmesi için spektral analiz kullanılır.

3.1.2.2. Kısa zamanlı Fourier dönüşümü (KZFD)

Fourier dönüşümü sinyalin frekans domeninde incelenmesine fırsat verirken, biyomedikal sinyaller gibi durağan olmayan sinyallerin işlenmesinde zamansal değişim olmasından dolayı sinyalin sadece frekans domeninde incelenmesi yeterli değildir. Bu sebeple bu tip sinyaller, zaman-frekans yöntemleri diye adlandırılan yöntemlerle incelenmelidir. Bunlardan biri de KZFD’dir. KZFD, temelde Fourier dönüşümüne

dayanır ve sinyali zaman-frekans fonksiyonu olarak inceler. Bu yöntem, zaman-frekans yöntemlerinden klasik Fourier dönüşümünü temel alan, sinyali zaman ve frekansın bir fonksiyonu olarak iki boyutta inceleyen bir yöntemdir. KZFD ile durağan olmayan sinyal küçük segmentlere bölünür ve sinyalin bu segmentleri durağan kabul edilir (Koçyiğit ve ark., 2005). KZFD’de önemli olan iki parametre zaman ve frekans çözünürlüğüdür (Kıymık ve ark., 2002) Bu iki parametre pencere fonksiyonun boyu ile belirlenir (Miner, 1998). Uzun pencere boyu seçildiğinde, Fourier dönüşümünün doğal bir sonucu olarak frekans çözünürlüğü artar. Buna karşılık zaman çözünürlüğü azalmış olur. Pencere boyu sinyalin tamamını kapsayacak kadar büyük seçilirse sadece sinyalin frekans spektrumu elde edilmiş olur. Pencere boyu kısa seçildiğinde ise zaman çözünürlüğü artarken, frekans çözünürlüğü azalır. Ayrıca pencere boyu azaldığında sinyal içerisindeki düşük frekans bileşenleri de gözlenemez. Benzer şekilde pencere boyu çok kısa seçilirse sinyalin kendisi elde edilir (Özmen 2013; Semmlow 2004). O yüzden uygun pencere boyutunu seçmek oldukça önemlidir (Özmen, 2013). Bu yöntem zamanla değişen sinyallerin analiz edilmesini sağlar; ancak analizin çözünürlüğü seçilen pencere boyu ile sınırlıdır (Miner, 1998). KZFD, Denis Gabor tarafından, 1946 yılında ortaya koyulmuştur. Bu yöntemin diğer adı “spectrogram”dır. KZFD’nin matematiksel ifadesi Denklem 3.3’te gösterilmiştir. Şekil 3.4’te KZFD diyagramı gösterilmiştir.


$$X(t, f) = \int_{-\infty}^{\infty} x(\tau) w(t - \tau) e^{-i\pi f \tau} d\tau \quad (3.3)$$



Şekil 3.4. Kısa Zamanlı Fourier Dönüşümü

3.1.2.3. Dalgacık dönüşümü

Dalgacık dönüşümü (DD), temelleri 1805 yılında Joseph Baptiste Fourier tarafından atılan ve durağan olmayan sinyallerin analizine olanak sağlayan bir yöntemdir. Dalgacık dönüşümü, esnek zaman frekans bilgisi elde edilmesini sağladığı için biyomedikal sinyallerin incelenmesinde önemli bir yere sahiptir (Türkoğlu, 2002). Dalgacık dönüşümü de KZFD gibi zaman-frekans yöntemlerinden biridir. Bu yöntem KZFD'ye benzer bir prensibe dayanır ve KZFD'deki sinyali pencerelere ayırma yerine bir dalgacık fonksiyonu kullanır (Miner, 1998). Dalgacık dönüşümü yöntemi, düşük frekanslarda geniş bir pencere, yüksek frekanslarda ise sıkıştırılmış bir pencere kullanır (Vetterli ve Kovačević, 1995). HFD ve KZFD yöntemleri ile yapılan frekans analizinin tam olarak yeterli olmadığı kanaatine varılarak, zaman-frekans çözünürlüğündeki kısıtlılıklarını gidermek amacıyla geliştirilmiş bir yöntemdir (Özmen, 2013). Bu yöntemle zaman dizilerinin geneline ilişkin kararlar vermek yerine bölgesel ölçekte oluşan küçük dalgalanmaların önemli olabileceği gündeme gelmiştir. DD, zamanın ve frekansın belirli ölçeklere göre bölünmesi ile sinyalden daha fazla bilgi elde edilmesini sağlamaktadır (Semmlow, 2004). DD yönteminde, düşük frekanslarda geniş bir pencere, yüksek frekanslarda ise detayları analiz etmek için sıkıştırılmış pencere kullanılır (Özmen, 2013; Vetterli ve Kovačević, 1995). Şekil 3.5'te Fourier dönüşümü ve dalgacık dönüşümüne ait zaman-frekans diyagramları gösterilmiştir.



Şekil 3.5. (a) Dalgacık Dönüşümü ve (b) Kısa Zamanlı Fourier Dönüşümü zaman-frekans çözünürlükleri

İki tip dalgacık dönüşümü vardır.


- Sürekli Dalgacık Dönüşümü (SDD) (Continuous Wavelet Transform)
- Ayırık Dalgacık Dönüşümü (ADD) (Discrete Wavelet Transform)

Ayrık dalgacık dönüşümü:

ADD, ana dalgacığın belirli genişlemelerinde sinyali inceleyerek daha hızlı analiz yapılmasına olanak sağlar. ADD, yüksek frekanslarda yüksek zaman çözünürlüğü ve düşük frekans çözünürlüğü, alçak frekanslarda ise yüksek frekans çözünürlüğü ve düşük zaman çözünürlüğünü sağlar (Özmen, 2013). ADD Denklem 3.4'teki formülle ifade edilir.


$$D_{j,k}(f, \Psi_{j,k}) = 2^{-j/2} \int_{-\infty}^{\infty} f(x) \Psi(2^{-j}x - k) dx \quad (3.4)$$

Bu yöntemde sinyal ilk önce filtreleme ile alçak ve yüksek frekans bileşenlerine ayrılır. Alçak frekans bileşenlerine “approximation(yaklaşım)”, yüksek frekans bileşenlerine ise “detail (detay)” ismi verilir (Arı ve ark., 2008). Bu durum aşağıda Şekil 3.6’da gösterilmiştir.



Şekil 3.6. Sinyalin bileşenlerine ayrılması

Yukarıda gösterilen bileşenlerine ayırma işlemi, sinyal üzerinde çok seviyeli olarak istenildiği kadar uygulanabilir (Koçyiğit ve Korürek, 2005). Aşağıda Şekil 3.7’de çok seviyeli ayrıştırma gösterilmiştir.



Şekil 3.7. Çok seviyeli ayrıştırma (Arı ve ark., 2008; Özmen, 2013)

3.1.2.4. Power spectrum density (Welch)

PSG sinyalleri de diğer biyomedikal sinyaller gibi zaman domeninde elde edilen ve zamanla değişiklik gösteren işaretlerdir. Bu gibi sinyallerin incelenmesinde Fouier Dönüşümü ile frekans domenine dönüştürülen sinyallerin analizinde çoğu zaman kullanılan yöntemlerin başında PSD gelmektedir. Güç spektrumu, Fourier dönüşümünün doğrudan bir uygulamasıdır. Bu açıdan bakıldığında ortalama alma ile doğrudan ilgilidir ve bu yüzden periodogramların ortalaması olarak da bilinir. Periodogramda bölümleme ve ortalama alma önemlidir. Ortalama alma işlemi, dalgayı bölme, bölümlerin örtüştürülmesi ve her bir bölümün Fourier dönüşümünün alınması şeklinde yapılır. Spektral analiz güvenilirliğini artırmak için bölüm uzunluğunun küçük olması gerekir. Ancak, bu durum frekans çözünürlüğünü azaltır. Bir zaman serisi şeklindeki sinyallerin üst üste örtüşebilecek şekilde bölümlere ayrılması fikri Peter D. Welch tarafından ortaya atılmıştır (Özmen, 2013). Welch'in ortaya koyduğu bu yöntemde, örtüşen segmentler kullanılır ve pencereleme işlemi tüm segmentlere uygulanır (Semmlow, 2004). Böylece Welch, seğmenlerin örtüşmesi fikri ile periodogramda temel bir değişiklik yapmıştır (Proakis ve Manolakis, 2010). Welch'in yaptığı bir diğer temel değişiklik ise periodogram hesaplamasından önce bölümlerin pencerelenmesidir. Bunlara değiştirilmiş periodogram da denir. Değiştirilmiş periodogramın matematiksel ifadesi Denklem 3.5'te gösterilmiştir.

$$P_{xx}^{(i)}(f) = \frac{1}{MU} \left| \sum_{n=0}^{M-1} x_i(n)w(n)e^{-i2\pi fn} \right|^2, i = 0, 1, \dots, L-1 \quad (3.5)$$

Burada $w(n)$ pencereleme fonksiyonudur. P , $w(n)$ 'nin ortalamasıdır. U , ($U=(1/M) \sum_{n=0}^{M-1} w^2(n)$) olarak verilen normelleştirme sabitidir. Son olarak, L segmenti için periodogramların ortalaması ile güç yoğunluğu spektrum tahmini Denklem 3.6'da gösterildiği gibi hesaplanır (Proakis ve Manolakis, 2010).

$$P_{xx}^W(f) = \frac{1}{L} \sum_{i=0}^{L-1} P_{xx}^{(i)}(f) \quad (3.6)$$

Bu çalışmada coif1, coif2, coif3, coif4, coif5, db1, db2, db3, db4, db5, fk4, fk6, fk8, sym2, sym3 ve sym4 gibi farklı dalgacık tipleri ile birçok farklı uygulama yapılmış ve sonuçları değerlendirilmiştir.

3.1.2.5. Autoregressive Modeling

Spektral analizde klasik yöntemlerde ortaya çıkabilecek sıkıntılardan birisi spektral sızıntı diye adlandırılan ve verideki zayıf sinyallerin incelenememesi sorununu ortaya çıkaran durumdur. Bu durum, oluşturulan pencere tipinden kaynaklanabileceği gibi pencerelerin dışında kalan verilerin sıfır kabul edilmesi ile ortaya çıkabilir. Bu sorunu aşmak için model tabanlı yaklaşımlar kullanılabilir. Bu yöntemlerden birisi de autoregressive modeling'dir. Model tabanlı yaklaşımlar, pencerelemeye olan gereksinimi ortadan kaldırırlar. Bu tip yöntemlerin daha iyi bir çözünürlük sağladığı söylenebilir (Özmen, 2013). Bu yöntem yapısında ani tepeler olan sinyaller için uygun bir yöntemdir (Proakis ve Manolakis, 2010). AR, model parametrelerinin belirlenmesinde doğrusal denklemler kullandığı için yaygın olarak tercih edilen bir yöntemdir (M. R. Bozkurt, 2007). Bu yöntemde model parametrelerinin belirlenmesinde Denklem 3.7'de belirtilen matris denkleminde yararlanılmaktadır. Model parametrelerinin belirlenmesinde Yule-Walker, Burg ve Covariance yöntemleri kullanılabilir.

$$\begin{bmatrix} Y_{xx}(0) & Y_{xx}(-1) & \dots & Y_{xx}(-p) \\ Y_{xx}(1) & Y_{xx}(0) & \dots & Y_{xx}(-p+1) \\ \dots & \dots & \dots & \dots \\ Y_{xx}(p) & Y_{xx}(p-1) & \dots & Y_{xx}(0) \end{bmatrix} \begin{bmatrix} 1 \\ a_1 \\ \dots \\ a_p \end{bmatrix} = \begin{bmatrix} \sigma_\omega^2 \\ 0 \\ \dots \\ 0 \end{bmatrix} \quad (3.7)$$

3.2. ReliefF Özellik Seçme Algoritması

Relief algoritması Kira ve Rendell tarafından ortaya koymuştur (Kira ve Rendell, 1992a, 1992b). Nitelik tahminine dayalı bir yöntem olan Relief, hem sınıflandırma hem de regresyon problemlerinde kullanılmaktadır. Orijinal Relief algoritması artık nadiren kullanılmaktadır. Onun yerine yaygın olarak ReliefF algoritması kullanılmaktadır (Kononenko, 1994). Altı varyantı olan relief'in bilinen en iyi varyantı ReliefF'dir. ReliefF, veri集中的 her özelliğe bir ilişki düzeyi belirler (Arauzo-Azofra ve ark., 2004). Bu ilişki düzeylerinin belirlenmesinde her özellik için tahmini hedef değeri hesaplaması yapar. Bu hesaplama yönteminde ReliefF'in klasik Relief'ten en önemli farkı sadece bir tahmin değeri yerine birden çok tahmin değeri hesaplayarak bu değerler arasında en yakın komşu yöntemini uygulamasıdır. Bu sebeple ReliefF'te k-NN yöntemindeki k parametresi de kullanılır (Urbanowicz ve ark., 2018). Bu özellik ReliefF'in özellikle gürültülü verilerle ilgili problemlerde daha başarılı sonuç üretmesini sağlamıştır.

3.3. Makine Öğrenmesi


Bilgisayar sistemleri yazılım vasıtasıyla kendisine verilen komutları icra ederler. Ancak sadece sıradan algoritmalarla yazılmış programlar her türlü sorunun çözümü için yeterli değildir. Zaman geçtikçe insanlar bilgisayar sistemlerinin kendileri gibi düşünebilmesini ve birçok parametreye göre sonuçlar üretebilmesini istemiştir. Bu amaçla yapay zekânın bir alt dalı olan makine öğrenmesi (MÖ) kavramı ortaya atılmıştır. MÖ, bir problem için o probleme ait önceden edinilen bilgilere dayanarak çözüm üretmek amacıyla geliştirilmiş algoritmaların genel adıdır. Makine öğrenmesi yöntemleri elde olan bilgileri kullanarak belirli matematiksel formüller uygulayarak kalıplaşmış modeller geliştirir. Bu modellere dayanarak da sınıflandırma, tahmin, kümeleme, örüntü tanıma, bilgi çıkarımı gibi amaçlarla sonuçlar üretebilir. Makine öğrenmesi veri madenciliği, bilgisayarlı görme, konuşma tanıma, robotik, sağlık, üretim vb. alanlardaki birçok soruna çözüm bulmamıza yardımcı olur (Alpaydın, 2010).

Makine öğrenmesi için birçok yöntem geliştirilmiştir. Bunlardan bazıları, YSA, SVM, decision tree (DT), RF, k-NN, Logistic Regression (LR), Naive Bayes (NB) gibi yöntemlerdir. Bu tez çalışmasında bu yedi makine öğrenmesi yöntemi de kullanılmıştır.

Çalışmanın nihai amacı olarak geliştirilen adaptif sistem tasarımı ise YSA kullanılmıştır.

3.3.1. Yapay sinir ağları

Yapay sinir ağları, yapay zekâ teknolojisinin bir alt dalı olan makine öğrenmesi yöntemlerinden birisi olarak karşımıza çıkmaktadır. YSA en sık kullanılan makine öğrenmesi tekniklerinden biridir. Diğer MÖ yöntemleri gibi, YSA da insan beyninin en temel özelliği olan öğrenme fonksiyonunu gerçekleştiren bilgisayar yöntemlerdir. Öğrenme işlemini örnekler yardımı ile gerçekleştirirler (Öztemel, 2012). İnsan beyninin temel işlem elemanı olan nöronu (sinir hücresi) şekilsel ve işlevsel olarak basit bir şekilde taklit eden YSA, bu yolla biyolojik sinir sisteminin basit bir simülasyonu için oluşturulan programlardır (Yurtoğlu, 2005). Şekil 3.8’de biyolojik sinir sistemi hücresi ve yapay sinir hücresi modelini gösterilmiştir.



Şekil 3.8. a) Biyolojik sinir hücresi, b) Yapay sinir hücresi

Bu şekilde, insanoğluna özgü deneyerek (yaşayarak) öğrenme yeteneğini bilgisayar ortamına taşıyabildiği düşünülen YSA teknolojisi bir bilgisayar sistemine inanılmaz bir “girdi veriden öğrenme” kapasitesi sağlamaktadır ve birçok avantajlar sunmaktadır (Yurtoğlu, 2005). YSA özellikle;


- Sınıflandırma,
- Örüntü tanıma,
- Sinyal filtreleme,

- Veri sıkıştırma
- Optimizasyon

alanlarındaki çalışmalarda kullanılan en güçlü teknikler arasında sayılabilir.

YSA sistemin bağımsız değişkenleri olan girişleri, bağımlı kestirilen değişkenler olan çıkışlar ile ilişkilendirerek karmaşık, doğrusal olmayan modeller oluşturur. YSA modelleme ve karar verme işlemlerinde kullanılan en önemli araçlardandır. Bunun nedeni, sınırlı ve tamamlanmamış olan veri tabanlarından en iyi sonucu çıkarabilmesi ve farklı eğitim algoritmaları ile eğitilmeleri durumunda başarının artırılabilmesidir. Tıpta YZ uygulamalarında da YSA kullanımı oldukça yaygındır. YSA, klinik protokollerden çıkarılan veriler, ölçümlerden elde edilen laboratuvar verileri, işaretler veya görüntülerden çıkarılan öznitelikler gibi bir sistemin farklı yapıdaki verilerini birleştirerek tümleşik teşhis sistemi oluşturma özelliği de bulunmaktadır (Demirhan ve ark., 2010).

YSA hesaplama ve bilgi işleme gücü bakımından güçlü bir yöntemdir. YSA bu gücü paralel dağılmış yapısından, öğrenbilme ve genelleme yeteneğinden alır. Genelleme, YSA'nın eğitim ya da öğrenme sürecinde karşılaşmadığı girişler için de uygun tepkileri üretebilmesidir (Demirhan ve ark., 2010). Şekil 3.9'da birden çok girişe sahip bir yapay sinir hücresi gösterilmiştir.



Şekil 3.9. Yapay sinir hücresi

YSA'da kullanılan iki temel fonksiyon vardır. Bunlardan biri toplama (birleştirme) fonksiyonu diğeri de aktivasyon (transfer) fonksiyonudur. Yapay sinir

hücreleri dışarıdan gelen bilgileri bir toplama fonksiyonu ile toplar ve aktivasyon fonksiyonundan geçirerek çıktıyı üretilip ağıın bağlantılarının üzerinden diğer hücrelere gönderir. Çeşitli toplama ve aktivasyon fonksiyonları vardır. YSA’da bilgi aktarımında kullanılan etkinlik değerlerine ağırlık adı verilmektedir. Ağda yer alan sinir hücrelerinin birbirlerine paralel olarak 3 katman halinde bağlandığı bir yapı oluşturulur (Öztemel, 2012). Bu katmalar şunlardır:

- Girdi katmanı
- Gizli (ara) katmanlar
- Çıktı katmanı

İlk önce ağa gelen veriler girdi katmanından ağa alınır. Alınan bu giriş verileri gizli katmanlarda işlenirler. Son olarak da işlenen bu veriler çıktı katmanına gönderilirler. Giriş verilerinin işlenmesinde ağıın ağırlık değerleri kullanılır. Ağıın giriş verilerine göre doğru çıktıları üretebilmesi ağırlıkların doğru olmasına bağlıdır. Doğru ağırlıkların tespit edilmesi ise ağıın eğitilmesidir. Ağda kullanılacak ağırlık değerleri başlangıçta rasgele belirlenir.


Eğitim devam ettiği sürece ağıın öğrenme kuralına göre ağırlıklar değiştirilir. İdeal olan ağıın eğitim setindeki örneklerin tamamı için doğru çıktılar üretebilmesidir. En doğru ağırlık değerlerinin bulunabilmesi için süreç tekrarlanır. Eğitim süreci tamamlandıktan sonra test kümesindeki veriler ağıın doğru çıktılar üretmesi beklenir. Ağıın ne oranda doğru cevap verdiği ağıın başarısını ortaya koyar. Ağıın bir olayı öğrenip doğru çıktılar üretebilmesi ağırlık değerlerinin doğru tespit edilebilmesine bağlıdır. Ancak, ağıın kurulum aşamasındaki parametreler de başarıyı doğrudan etkiler. Bir ağıın modelini oluşturan temel parametreler şunlardır:

- Ağıın topolojisi
- Toplama fonksiyonu
- Aktivasyon fonksiyonu
- Öğrenme stratejisi
- Öğrenme kuralı

Bu parametrelere göre bir çok ağ modeli geliştirilmiştir (Öztemel, 2012).

3.3.1.1. Ağın topolojisi

Ağ topolojisi ağın kaç adet katmana sahip olduğu ve bu katmalarda kaç tane sinir hücresi bulunduğu ile ilgilidir. Her yapay sinir ağında bir giriş ve bir çıkış katmanı bulunur. Giriş katmanındaki sinir hücresi sayısı girecek veri miktarı ile belirlenirken, çıkış katmanındaki sinir hücresi sayısı ise elde edilmek istenen çıktı sayısına bağlıdır. Ağın kaç katmana sahip olduğu aslında giriş ve çıkış katmanları arasından yer alan gizli (ara) katman sayısı ile ilgilidir. Gizli (ara) katmanlarda yer alan sinir hücresi sayıları ise giriş ve çıkış katmanlarındaki hücre sayısından bağımsız olarak belirlenir. Gizli (ara) katmanlardaki hücre sayıları ağın başarısını ve ağın eğitim süresini doğrudan etkiler. Gizli (ara) katmanlardaki sinir hücresi sayılarının belirlenmesinde optimizasyon yöntemlerinden faydalanılabileceği gibi, hücre sayısı deneme yanılma yöntemiyle de belirlenebilir. Bu çalışmada 2 gizli (ara) katmana sahip bir ağ topolojisi oluşturulmuştur. Gizli katmanların birinde 55 diğesinde ise 50 adet sinir hücresi bulunmaktadır. Çalışmada kullanılan ağ topolojisi Şekil 3.10'da gösterilmiştir.



Şekil 3.10. Yapay sinir ağı topolojisi

3.3.1.2. Toplama fonksiyonu

Toplama fonksiyonu, bir yapay sinir hücresine gelen tüm verilerin ilgili ağırlık değeri ile işlendikten sonra toplanması suretiyle o hücrenin net girdisini hesaplayan fonksiyondur. Birçok toplama fonksiyonu bulunmaktadır. Bu çalışmada “Sum (Toplam)” toplama fonksiyonu kullanılmıştır. Sum (Toplam) fonksiyonu Denklem 3.8’de gösterilmiştir.

$$Net = \sum_{i=1}^N X_i * W_i \quad (3.8)$$

3.3.1.3. Aktivasyon fonksiyonu

Bu fonksiyon toplama fonksiyonu ile hesaplanan, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Aktivasyon fonksiyonu genellikle doğrusal olmayan bir fonksiyon seçilir. YSA’nın bir özelliği olan “doğrusal olmama” aktivasyon fonksiyonlarının doğrusal olmama özelliğinden kaynaklanmaktadır. YSA’da birçok farklı aktivasyon fonksiyonu kullanmak mümkündür. Bu çalışmada aktivasyon fonksiyonu olarak “Sigmoid Fonksiyonu” seçilmiştir. Aşağıda Sigmoid aktivasyon fonksiyonu Denklem 3.9’da verilmiştir.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.9)$$

3.3.1.4. Öğrenme stratejisi

Yapay sinir ağlarının oluşturulmasında tercih edilecek öğrenme stratejisi çok önemlidir. Öğrenme stratejisi ağın çalışma sistemini belirleyen en temel unsurdur. Farklı problemlerin çözümlerine farklı öğrenme stratejileri uygulamak gerekir. Literatürde geçen öğrenme stratejileri şunlardır (Öztemel, 2012):

- Öğretmenli (Supervised) Öğrenme
- Öğretmensiz (Unsupervised) Öğrenme
- Destekleyici (Reinforcement) Öğrenme
- Karma Stratejiler

3.3.1.5. Öğrenme kuralı

Yukarıda da anlatıldığı gibi, tüm eğitim verileri için doğru çıktılar üretecek ağırlık değerlerinin belirlenmesi gerekir. Bu işleme ağırlık eğitimi denilmektedir. Eğitim başlangıcında rastgele belirlenen ağırlık değerleri eğitim süresince değiştirilerek ideal ağırlık değerlerinin elde edilmesi amaçlanır. Ağırlık değerlerinin nasıl değiştirileceği ise öğrenme kuralı ile belirlenir. Literatürde yer alan öğrenme kuralları şunlardır (Öztemel, 2012):

- Çevrimiçi (On-line) Öğrenme Kuralları
- Çevrimdışı (Off-line) Öğrenme Kuralları
- Öğrenme Kurallarından Bazıları

3.4. Gerçek Zamanlı Öğrenme

MÖ tekniklerinde durağan olmayan verilerle çalışmak ve yeni gelen her veriye göre ağırlık sürekli yeniden öğrenmesini sağlamak önemli bir sorundur. Bir makine öğrenmesi algoritması, dış gereksinimler tarafından tanımlanan beklenen hızlı yanıt süresi içinde yeni bir uygulama için iyi bir genelleme performansı ile bir öğrenme prosedürünü tamamlayabiliyorsa, gerçek zamanlı öğrenme (GZÖ) sistemi olarak adlandırılır (G.-B. Huang, Zhu, ve Siew, 2006). Burada beklenen hızlı yanıt süresi yapılacak uygulamaya ve o uygulamadaki ihtiyaçlara göre değişebilir. Bu MÖ tekniğinin özellikle gerçek zamanlı sinyal işleme gerektiren problemlerde kullanılması çok önemlidir. Bu tip sinir ağlarında da, ağırlık çevrimiçi olarak eğitilmesi gereklidir (Malkoff, 1989) ve eğitim süresi ağırdaki gizli katman sayısı ve nöron sayıları ile orantılı olarak değişmektedir. Bunlar aynı zamanda ağırlık başarısını da etkileyen temel unsurlardır. Literatürde yer alan çalışmalarda tek gizli katmana sahip YSA'nın sınıflandırma yeteneği ortaya koyulmuştur. Bu çalışmalardan bazıları Huang ve ark. tarafından yapılan çalışmalardır (Guang-Bin Huang ve Babri, 1998; Guang-Bin Huang ve ark., 2000). Ancak, literatürdeki birçok çalışmada da iki gizli katmana sahip YSA'nın tek gizli katmana sahip ağlardan birçok durumda daha güçlü bir yapıya sahip olduğu belirtilmiştir (Ferrari ve Stengel, 2005; Guang-Bin Huang, 2003; Xiang ve ark., 2005).

3.5. Adaptif Sistem


Belirli bir sonuç üretmek için girdileri işleyen ve birbirine bağlı ve etkileşimli birimlerden oluşan ve bir plana göre oluşturulmuş yapılara sistem denir (Ataman, 2009). Her sistem bir düzen üzerine inşa edilir ve bu düzenin sürdürülmesini sağlayan ve istenilen çıktılara ulaşılmasını sağlayan yöntemler vardır. Her sistemin yapısındaki yöntemler de girdilerden istenilen çıktıyı üretebilmek için girdileri etkileyen çeşitli parametrelerle çalışırlar. Bu parametreler bazen sabit bazen de değişken olarak kullanılabilirler.

Sabit parametrelili sistemlerde sistem çalıştırılmadan önce parametreler belirlenir ve girdilerin o parametrelere göre çıktıya dönüştürülmesi amaçlanır. Bu tip sistemlerde başlangıçta belirlenen parametreler ile istenilen çıktıya ya da istenilen seviyede başarılı bir sonuca ulaşamaz ise sistem durdurularak parametrelerin değiştirilmesi ve sistemin yeniden çalıştırılması gerekir. Beklenen başarılı sonuca ulaşılan kadar deneme yanılma yöntemi sürdürülebilir. Böylece daha başarılı sonuçlara ulaşılması beklenir.

Değişken parametrelili sistemlerde ise başlangıçta belirlenen parametreler sistem çalıştığı sırada güncellenebilir. Bu gibi sistemlerde parametre güncellemesi için sistemin durdurulup yeniden çalıştırılmasına gerek yoktur. Parametrelerin dinamik olarak değiştirilme gerekçesi aslında Türkçe anlamı “uyum” olan “adaptasyon” kelimesi ile açıklanabilir. Sistemin çalışması sırasında birçok durum başlangıçta öngörülemez bir şekilde farklılaşabilir. Bunlar, ısı, nem, titreşim, gürültü, yük, vs. çalışma koşulları ile ilgili olabilir. Girdilerde yaşanan değişikliklerle de ilgili olabilir. Nihai amaç mevcut girdilerle ve o anlık tüm koşulları dikkate alarak uyumlu bir sistem meydana getirerek ideal çıktıyı elde etmektir. Sistemde öngörülemeyen değişiklikler meydana geldiğinde kabul edilebilir bir sistem performansını elde etmek ve sürdürmek için, “uyarlanabilir” yani “adaptif” bir kontrol yaklaşımı düşünülmelidir (Landau ve ark., 2011). Çalışma sırasında ideal çıktıyı sağlamak amacıyla sistem parametrelerini otomatik olarak güncelleyebilen sistemlere “adaptif sistem” (AS) denir.

Adaptif sistemlerde en önemli sorunlar parametrelerin hangi kurallara göre değiştirileceği, nasıl değiştirileceği ve ne zamana kadar değiştirileceğidir. Bu soruların cevapları bir adaptasyon mekanizması tarafından yapılan işlemlerde saklıdır. Adaptasyon mekanizması, sistem üzerinden gerçek zamanlı olarak topladığı verilere göre belirtilen kurallara uygun olarak bazı işlemler gerçekleştirerek sistemin yeni parametrelerini hesaplar ve sisteme aktarır. Bu işlem yine adaptasyon mekanizması tarafından yürütülen

durdurma kuralına göre devam ettirilir. AS'lerde parametrelerin güncellenmesini gerektiren kurallar aynı zamanda güncellenmenin ne zamana kadar süreceğinin de işaretçisidir. Sistem tasarımcısı kimi zaman sistem başarısına ya da hata değerine göre, kimi zaman giriş verilerine göre, kimi zaman da farklı koşullara göre parametre güncellemesi ve güncellenmenin durdurulmasını sağlar. Şekil 3.11'de bir adaptif kontrol sistemine ait blok diyagramı gösterilmiştir.



Şekil 3.11. Adaptif kontrol sistemi (Landau ve ark., 2011)

Bu çalışmada, biyomedikal sinyaller kullanılmıştır. Biyomedikal sinyaller durağan olmayan, kişiye ve zamana göre hızlı değişiklik gösteren verilerdir. Tez çalışması kapsamında geliştirilen PAP cihazı, anlık olarak tıkalı uyku apnesi hastalarına ait fizyolojik değişiklikleri algılayacak ve buna göre kişisel bir terapi uygulayacaktır. Bu amaçla hastaya uygulanacak pozitif hava basıncı değerinin belirlenmesi sistem çalışmadan önce belirlenen başlangıç parametreleriyle değil sistem çalışması sırasında adaptasyon mekanizması ile belirlenmiştir. Böylece adaptif sistem oluşturulmuştur. AS yaklaşımının YZ teknikleriyle birlikte kullanılması sonucunda zeki ve adaptif sistem tasarımı ortaya çıkarılmıştır.

3.6. Performans Ölçütleri

Bu çalışmada kullanılan makine öğrenmesi yöntemlerinin sınıflandırma başarılarını değerlendirmek ve karşılaştırmak için Acc (doğruluk), Recall (duyarlılık), Precision (kesinlik), F1 Score ölçütleri kullanılmıştır. Kullanılan ölçütlerin elde edilmesine dair formüller Denklem (3.10), Denklem (3.11), Denklem (3.12) ve Denklem

(3.13)'da gösterilmiştir. Bu denklemlerde kullanılan değerlerin karmaşıklık matrisi üzerinde gösterimi de Şekil 3.12'de gösterilmiştir.

		Tahmin	
		Pozitif	Negatif
Gerçek	Pozitif	Gerçek Pozitif	Yanlış Negatif
	Negatif	Yanlış Pozitif	Gerçek Negatif

Şekil 3.12. Karmaşıklık matrisi

$$Acc = \frac{Gerçek Pozitif + Gerçek Negatif}{(Gerçek Pozitif + Yanlış Pozitif + Gerçek Negatif + Yanlış Negatif)} \times 100 \quad (3.10)$$

$$Recall = \frac{Gerçek Pozitif}{(Gerçek Pozitif + Yanlış Negatif)} \times 100 \quad (3.11)$$

$$Precision = \frac{Gerçek Pozitif}{(Gerçek Pozitif + Yanlış Pozitif)} \times 100 \quad (3.12)$$

$$F1 Score = \frac{2 * Precision * Recall}{Precision + Recall} \times 100 \quad (3.13)$$

Bu çalışmada geliştirilen sistem gerçek zamanlı öğrenme yapabilen ve adaptif çalışma özelliğine sahip bir sistemdir. Sistem hastadan aldığı biyomedikal sinyal verileri ile yapay sinir ağları yöntemi ile sürekli öğrenme yapmaktadır. Sürekli öğrenme faaliyeti sırasında her test işleminden sonra sinir ağının ürettiği ağ hatası Mean Squared Error (MSE) yöntemine göre hesaplanmaktadır. MSE formülü Denklem 3.14'te verilmiştir. Buna bağlı olarak gerekli görüldüğü taktirde ağın ağırlık ve bias parametreleri daha başarılı olanları ile güncellenmektedir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (3.14)$$

Bu formüldeki n örnek sayısını göstermektedir. Y_i , tahmin edilmeye çalışılan gerçek sınıf değerini gösterirken, $\hat{Y}_i$ ise sınıflandırıcının tahmin ettiği değeri temsil etmektedir.


3.7. Verilerin Elde Edilmesi

Tıkayıcı uyku apnesi teşhisi için standart yöntem hastaların gece boyunca polisomnografi kayıtlarının alınmasıdır. Polisomnografi, hastaya ait birçok fizyolojik sinyalin aynı anda toplanmasına olanak veren gelişmiş bir sistemdir. Bu sistem sayesinde birçok hastalığın göstergesi olabilecek Pressure Flow, Pressure Snore, SpO₂, EKG, EEG, EMG, EOG, nabız, karın ve göğüs hareketleri gibi birçok sinyal toplanabilmektedir. Uyku apnesi teşhisi için de bu verilerden faydalanılmaktadır. Bu tez çalışmasında PAP cihazları için yeni bir sistem yaklaşımı geliştirilmeye çalışılmıştır. Bu amaçla tıkayıcı uyku apnesi için gösterge olabilecek fizyolojik sinyallerin incelenmesi gerekmiştir. Tez çalışmasında bu verilerin kullanılabilmesi için öncelikle Selçuk Üniversitesi Tıp Fakültesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu'na başvurularak 2019/61 sayılı karar ile etik kurul izni alınmıştır. Daha sonra Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Hastanesi'nin uyku servisine başvuran, yaşları 22 ile 78 arasında değişen, 48'i erkek, 27'si bayan toplam 75 hastaya ait PSG sinyalleri alınmıştır. Kullanılan PSG kayıtlarına ait özet bilgilere Çizelge 3.1'de yer verilmiştir. Ayrıca, hastaların cinsiyet dağılımlarını gösteren grafik Şekil 3.13'te gösterilmiştir. Apne rahatsızlıklarının ciddiyet seviyelerini gösteren grafik ise Şekil 3.14'te gösterilmiştir.

Çizelge 3.1. PSG kayıtları özet bilgileri


Hasta Sayısı	75
Yaş Aralığı	22 - 78
BMI (kg/m ²)	24,6 – 64,1
Uyuma Süresi Aralığı	57 d 30 sn – 07 s 54 d
Hastaların AHI Aralığı	5,2 – 110,8
Apne Ciddiyetleri	Hafif, Orta, Ağır

Cinsiyet Dağılımları




Şekil 3.13. 75 hastanın cinsiyet dağılımı

Apne Ciddiyeti



Şekil 3.14. 75 hastanın apne ciddiyet seviyelerinin dağılımı

PSG sinyalleri içerisinde birçok farklı sinyal tipi bulunmaktadır. Bu sinyallerden tıkalıcı uyku apnesi için gösterge olabilecek sinyaller belirlenerek çalışmaya dahil edilmiştir. Bu sinyal tiplerinin belirlenmesinde yapılan literatür araştırmaları ve alınan uzman hekim görüşleri etkili olmuştur. Bu doğrultuda çalışmaya dahil edilecek sinyaller, Pressure Flow, Pressure Snore, EKG, Thorax (göğüs hareketleri), SpO₂, Pulse (nabız) ve vücut pozisyonu olarak belirlenmiştir. Bu sinyaller Şekil 3.15'te görülmektedir.




Şekil 3.15. Ham PSG sinyalleri

4. UYGULAMALAR

4.1. Sinyal İşleme Çalışmaları

Geliştirilen sistemin girdileri olması amacıyla hastanenin uyku servisinden elde edilen Pressure Flow, Pressure Snore, EKG, Thorax (göğüs hareketleri), SpO₂, Pulse (nabız) ve vücut pozisyonu sinyalleri, makine öğrenmesi yöntemleri ile kullanılabilmesi için öncelikli olarak sinyal işleme süreçleri ile işlenmiştir. Elde edilen ham biyomedikal sinyallere örnek olarak Şekil 4.1’de ham akış basıncı (pressure flow) sinyalinin görüntüsü verilmiştir. Tüm biyomedikal sinyaller bu şekilde ham olarak elde edildikten sonra sinyal işleme çalışmaları yapılmıştır.




Şekil 4.1. Ham pressure flow sinyali

4.1.1. Ön işleme

Hastaneden alınan ham PSG sinyallerinin tez çalışmasında kullanılabilmesi için sinyal işleme çalışmaları yapılması gerekmektedir. Sinyaller üzerinde ilk önce ön işleme yapılmıştır. Yapılan ön işlemler şunlardır:

4.1.1.1. DC bileşenlerin temizlenmesi

Sinyallerde bulunma ihtimali olan kaymaların önlenmesi amacıyla, çalışmaya dahil edilecek tüm sinyallerde DC bileşenlerin temizlenmesi işlemi yapılmıştır. Bu işlem sonrasında oluşan akış basıncı (pressure flow) sinyalinin görüntüsü Şekil 4.2’de verilmiştir.




Şekil 4.2. DC Bileşeni atılmış pressure flow sinyali

4.1.1.2. Şebeke geriliminin temizlenmesi

Fizyolojik sinyallerin kaydedilmesini sağlayan sinyal toplayıcı cihazlar 50 Hz frekansa sahip şebeke gerilimi ile çalışmaktadırlar. Bu cihazların çalışmasını sağlayan

şebeke gerilimi toplanan sinyallere etki edebilmektedir. Doğru bir analiz yapılabilmesi için sinyalin saf olarak elde edilmesi gerekir. Bu sebepten dolayı sinyallerdeki şebeke geriliminin bertaraf edilmesi gerekir. Bu amaçla, çalışmada kullanılacak sinyaller 49-51 Hz arasında bant durduran filtreden geçirilerek şebeke geriliminin temizlenmesi sağlanmıştır. Bu işlem sonrasında oluşan akış basıncı (pressure flow) sinyalinin görüntüsü Şekil 4.3'te verilmiştir.




Şekil 4.3. 50 Hz. Şebeke gürültüsünden temizlenmiş pressure flow sinyali

4.1.1.3. Filtreleme

Bir sinyalin içerisinde birçok bileşen bulunabilir. Sinyalde yer alan bileşenlerin nihai amaca uygun olarak kullanılabilmesi gerekir. Bunun için sinyal içerisinde bulunan ve amaca hizmet etmeyen ve gürültü diye de ifade edilebilecek bileşenlerin temizlenmesi gerekir. Bu temizleme işlemleri filtreleme ile mümkün olmaktadır. Bir sinyalin filtrelenebilmesi için öncelikle hangi frekans aralıklarında anlamlı veriler içerdiğinin belirlenmesi gerekir. Her fizyolojik sinyal için anlamlı frekans aralıkları farklıdır. Bu tez çalışmasında kullanılan sinyaller için yapılan literatür araştırmaları neticesinde, pressure flow sinyali için alt kesim frekansı 0,05 Hz, üst kesim frekansı 5 Hz olan bir bant geçiren

filtre (Díaz ve ark., 2014; Huang ve ark., 2017), EKG sinyali için alt kesim frekansı 0,05 Hz, üst kesim frekansı 40 Hz olan bir bant geçiren filtre (Buendía-Fuentes ve ark., 2012; Ondráček ve ark., 2005; Parola ve Garcia-Niebla, 2017), pressure Snore sinyali için kesim frekansı 10 Hz olan bir yüksek geçiren filtre (Hyo-Ki Lee ve ark., 2013), SpO₂ sinyali için kesim frekansı 0,5 Hz olan bir yüksek geçiren filtre (Gupta ve ark., 2017; Song ve ark., 2018), pulse (nabız) sinyali için alt kesim frekansı 0,5 Hz, üst kesim frekansı 2 Hz (Das ve ark., 2018) olan bir bant geçiren filtre ve Thorax sinyali için de üst kesim frekansı 0,5 Hz (De la Fuente ve ark., 2019) olan bir alçak geçiren filtre uygulanmıştır. Vücut pozisyon sinyali için bir filtre uygulanmasına gerek duyulmamıştır. Filtreleme yöntemi olarak 3. dereceden butterworth filtre yöntemi kullanılmıştır. Şekil 4.4'te filtreleme işlemine örnek olarak bant geçiren sonrasında oluşan akış basıncı (pressure flow) sinyalinin görüntüsü verilmiştir.



Şekil 4.4. Band geçiren filtre uygulanmış pressure flow sinyali


4.1.1.4. Normalizasyon

Sinyallerden elde edilen sayısal verilerin değer aralıklarını dengelemek amacıyla normalizasyon işlemi uygulanmıştır. Normalizasyon için max-min yöntemi

kullanılmıştır. Bu yöntemde, sinyaldeki minimum değer sinyalden çıkarıldıktan sonra bulunan değer maksimum ve minimum değer arasındaki farka bölünür. Elde edilen sonuç normalleştirilmiş sinyaldir. Uygulanan normalizasyon formülü Denklem 4.1’de gösterilmiştir.

$$Y = \frac{[X - \min(X)]}{[\max(X) - \min(X)]} \quad (4.1)$$

Yukarıdaki formülde X her ham sinyal verisini ifade ederken, Y ise verinin normalleştirilmiş halini göstermektedir. Bu denklem, veriler içerisindeki en büyük ve en küçük değerleri baz alarak diğer bütün verileri, bu değerlere göre normalleştirilir. Bu yöntemde amaç en küçük değeri 0 ve en büyük değeri 1 olacak şekilde normalleştirmektir. Böylece bütün verileri bu 0-1 aralığına yayılarak veri seti yeniden düzenlenmiştir. Normalizasyon işleminin etkisini göstermek amacıyla filtrelenmiş ve normalizasyon uygulanmış akış basıncı (pressure flow) sinyalinin görüntüsü Şekil 4.5’te gösterilmiştir.



Şekil 4.5. Normalleştirilmiş pressure flow sinyali

4.1.2. Sinyal özelliklerinin çıkarılması


Bir fizyolojik sinyalin ham olarak kullanılması hem boyut olarak çok büyük olacağından dolayı hem de sinyalin doğru anlamlandırılmasında hatalara sebep olacağı için uygun bir yöntem değildir. Bu yüzden bir sinyalden anlamlar çıkarabilmek için özellik çıkarma yöntemleri uygulanır. Biyomedikal sinyaller durağan olmayan sinyallerdir. Bu nedenle, sinyalden özellik çıkarabilmek için öncelikle sinyaller belirli zaman aralıklarına göre parçalara ayrılır. Bu parçalara epok denir. Bu tez çalışmasında kullanılan biyomedikal sinyaller gerek literatür araştırması gerekse uzman görüşüne dayanarak, epok süresi 30 saniye olacak şekilde parçalara ayrılmıştır. Daha sonra hastanede uzman hekimlerce yapılan analiz sonuçlarından her epokta apne olayının varlığı o epoka karşılık sınıf değeri olarak eşleştirilmiştir. Çizelge 4.1’de akış basıncı (pressure flow) sinyalinin epoklara ayrılmış hali ve apne sınıf değeri temsili olarak gösterilmiştir.

Çizelge 4.1. Epoklara ayrılmış biyomedikal sinyal verileri ve apne sınıfları

	Epok 1	Epok 2	Epok 3	Epok 4	...	Epok 54553
1	0,23041	0,42210	0,57593	0,48076	...	0,49074
2	0,47689	0,41405	0,57619	0,49513	...	0,47980
3	0,46007	0,39800	0,51644	0,47009	...	0,48716
4	0,42515	0,38760	0,49669	0,49976	...	0,50069
5	0,46758	0,40180	0,50091	0,43735	...	0,48968
6	0,49103	0,42214	0,59428	0,48008	...	0,47603
7	0,41263	0,45022	0,49816	0,50733	...	0,50121
...	...	...	...	...	...	...
7680	0,41175	0,47437	0,50442	0,50387	...	0,53420
Sınıf	1	0	1	1	...	0

Bu tez çalışmasında her sinyal için sinyalin yapısına uygun olarak farklı öznitelik çıkarma teknikleri kullanılarak sinyale ait öznitelikler çıkarılmıştır. Öznitelik çıkarma işlemi her epok için tekrarlanmıştır. PSG sisteminden elde edilen her biyomedikal sinyal için ayrı ayrı, hem zaman domeninde hem de frekans domeninde sinyal özellikleri çıkarılmıştır. Her sinyal için kullanılacak nihai özellik çıkarma yönteminin belirlenmesi amacıyla, bir biyomedikal sinyale tüm özellik çıkarma yöntemleri ve bu yöntemlerde yer alan çeşitli parametreler ayrı ayrı uygulanmıştır. **Bu şekilde 595 kez özellik çıkarma ve sınıflandırma işlemi yapılmıştır.** Daha sonra her sinyal için, uygulanan yöntemlerden elde edilen özellikler ile sınıflandırma işlemi yapılarak en başarılı sınıflandırma sonucunu veren özellik çıkarma yöntemleri belirlenmiştir.

Böylece nihai olarak, çalışmada kullanılan pressure flow sinyali için KZFD, EKG sinyali için AR-Burg, pressure snore sinyali için KZFD, SpO₂ sinyali için KZFD, nabız sinyali için AR-Burg, thorax sinyali için zaman domenî özellikleri ve vücut pozisyonu sinyali için KZFD yöntemlerinden elde edilen özellikler kullanılmıştır. 75 hastadan alınan tüm PSG sinyalleri, her biyomedikal sinyal için belirlenen özellik çıkarma yöntemi ve çıkarılan özellik sayıları Şekil 4.6'da gösterilmiştir.



Şekil 4.6. Özellik çıkarma yöntemleri ve özellik sayıları

Çalışmada kullanılan özellik çıkarma çalışmalarını zaman domeninde ve frekans domeninde olarak iki grupta inceleyebiliriz.

4.1.2.1. Zaman domeninde özellik çıkarma

Bu çalışmada biyomedikal sinyallerin her bir epogu için zaman domeninde aşğıdaki özellikler çıkarılmıştır.

- Mutlak değerlerin aritmetik ortalaması,
- Standart sapma,
- Eğiklik,
- Basıklık,
- Sinyalin enerjisi,
- Entropilerin ortalaması

Zaman domenindeki incelemelerle elde edilen özellikler kullanılarak durağan olmayan sinyaller hakkında bilgi edinilmesi oldukça güçtür. Özellikle hastalık teşhisi gibi uygulamalarda bu özelliklerden ziyade frekans domeninde yapılan incelemelerin daha doğru sonuçlar üretebileceğı literatürde belirtilmiştir (Mahmoud et al., 2006; Özmen, 2013). Bu sebeple tez çalışmasında zaman domeninde özellik çıkarma ile yetinilmemiş ve frekans domeninde de özellik çıkarma işlemleri yapılmıştır.

4.1.2.2. Frekans domeninde özellik çıkarma

Spektral analiz için kullanılan birçok yöntem mevcuttur. Zaman domenindeki bir sinyalin frekans bileşenlerine ayrılmasını sağlayan en temel yöntem Fourier dönüşümüdür (Denklem 3.1) (Oppenheim, 1989). Spektral analiz yöntemleri Fourier dönüşümü temelli klasik yöntemler ve parametre tahminine dayalı modern yöntemler olarak iki grupta toplanabilir. Bölüm 3'te bu yöntemler anlatılmıştır. Bu çalışmada Kısa zamanlı Fourier dönüşümü, power spectrum density (Welch), ayrık dalgacık dönüşümü ve autoregressive modeling yöntemleri ile özellik çıkarma çalışmaları yapılmıştır. AR için Yule-Walker, Burg ve Covariance yöntemleri ile uygulamalar yapılmıştır. Bu çalışmadaki tüm sinyal özellik çıkarma çalışmaları MATLAB yazılımı kullanılarak gerçekleştirilmiştir.

Kısa zamanlı Fourier dönüşümü uygulaması:

Bu çalışmada kısa zamanlı Fourier dönüşümünü gerçekleştirmek için MATLAB yazılımındaki (4.2) komut satırı kullanılmıştır;

$$[S, F, T, P] = spectrogram(x, window, noverlap, Nfft, fs) \quad (4.2)$$

Bu komut satırındaki x , sinyalin her bir epöğünü, $window$, pencere yapısını belirleyen parametrelerdir. Bu çalışmada $window$ parametresi olarak 512'lik uzunluğa sahip rectwin pencere yapısı kullanılmıştır. $Noverlap$ parametresi ise her pencerenin orijinal işaret üzerinde kaydırılma oranını belirlemektedir. Bu çalışmada $noverlap$ değeri 256 kullanılarak %50'lik bir kaydırma uygulanmıştır. $Nfft$ parametresi ise frekans hesaplanacak nokta sayısını yani frekans çözünürlüğünü göstermektedir. Bu çalışmada $Nfft$ örnekleme frekansının 2 katı olarak seçilmiştir. pressure flow sinyalinin örnekleme frekansı 256 Hz olduğu için $Nfft$ parametresi 512, pressure snora sinyalinin örnekleme frekansı 256 Hz olduğu için $Nfft$ parametresi 512, vücut pozisyonu sinyalinin örnekleme frekansı 4 Hz olduğu için $Nfft$ parametresi 8 olarak belirlenmiştir. F_s parametresi örnekleme frekansı olup pressure flow sinyali için 256 Hz, pressure snore sinyali için 256 Hz, vücut pozisyonu sinyali için 4 Hz olarak seçilmiştir.

MATLAB yazılımında *spectrogram* komutunun çalıştırılması sonucu oluşan 'P' matrisi özellik çıkarma amacıyla kullanılmıştır. Bu matriste sinyalin her bir epöğü için güç spektrum yoğunluğunu hesaplanmaktadır. Güç spektrum yoğunluğunu gösteren P matrisinin;

- Entropy değeri,
- Ortalaması,
- Standart sapması

KZFD ile çıkarılan **3 öznitelik vektörü** olarak çalışmada kullanılmıştır.

Autoregressive modeling uygulaması:

Parametreye dayalı model yaklaşımı kullanan AR gibi yöntemlerde, model parametrelerinin belirlenmesi başarıyı önemli oranda etkilemektedir. Model

parametrelerinin belirlenmesinde de farklı yöntemler kullanılabilir. Bu çalışmada başlangıçta tüm sinyaller üzerinde Yule-Walker, Burg ve Covariance özbağlanım katsayıları farklı derecelerde denenmiştir. Sonuç olarak, sınıflandırma başarılarına göre EKG ve nabız sinyalleri için AR özellik çıkarma yöntemi belirlenmiştir. Çalışmada, AR yöntemi 10. dereceden burg özbağlanım katsayıları, **11 öznitelik vektörü** olarak kullanılmıştır

4.1.3. Özellik seçme

Şekil 4.6’da görüldüğü gibi yedi tip fizyolojik sinyalden toplam 38 adet özellik vektörü elde edilmiştir. Çalışma kapsamında geliştirilen yeni nesil PAP sistemi algoritmasında bu 38 özelliğin tamamının kullanılması yedi sinyalin de hasta üzerinden anlık olarak alınması gerekliliğini ortaya çıkarmaktadır. Bu durum hem maliyet açısından hem de geliştirilecek sistemin hastalar tarafından rahat kullanımı açısından bakıldığında ciddi sorunlar doğurmaktadır. Yazılımsal olarak değerlendirildiğinde de gerçek zamanlı öğrenen makine öğrenmesi sisteminde sürekli olarak yedi sinyalden 38 özelliğin çıkarılması da sistemin işlediği veri yoğunluğunu oldukça artırmakta ve öğrenme süresini uzatmaktadır. Bu sebeplerden dolayı sistemin başarısı üzerinde en etkili özellikler ve bu özelliklerin elde edildiği fizyolojik sinyallerin belirlenmesi amacıyla özellik seçimi algoritmalarının kullanılması gerekmektedir. Bu çalışmada apne tahmini üzerinde etkinliği olan bütün sinyal tiplerinin etki düzeylerinin belirlenmesi amacıyla PSG sisteminden alınan tüm sinyaller ve çıkarılan özellikler özellik seçme işlemine dahil edilmişlerdir. Özellik seçimi algoritması olarak “Filter Methods” başlığı altında yer alan Relief’in altıncı varyantı olan ReliefF yöntemi uygulanmıştır. Bu çalışmada ReliefF yöntemi kullanılırken k-NN algoritması için k değeri 5 olarak uygulanmıştır. Tüm sinyallerden çıkarılan 38 özelliğin Relief ile elde edilen sıralaması Çizelge 4.2’de verilmiştir.

Çizelge 4.2. 38 özellik vektörünün ReliefF ile sıralaması

Sıra Numarası	Özellik kodu	Sinyal Tipi
1	F12	Pressure Flow
2	F15	Pressure Snore
3	F31	Thorax
4	F14	Pressure Flow
5	F13	Pressure Flow
6	F30	Thorax
7	F2	EKG
8	F33	Thorax
9	F3	EKG
10	F29	Nabız
11	F32	Thorax
12	F22	Nabız
13	F4	EKG
14	F10	EKG
15	F23	Nabız
16	F16	Pressure Snore
17	F25	Nabız
18	F24	Nabız
19	F34	Thorax
20	F26	Nabız
21	F5	EKG
22	F11	EKG
23	F9	EKG
24	F28	Nabız
25	F17	Pressure Snore
26	F6	EKG
27	F8	EKG
28	F7	EKG
29	F27	Nabız
30	F19	SpO ₂
31	F20	SpO ₂
32	F35	Thorax
33	F36	Vücut Pozisyonu
34	F38	Vücut Pozisyonu
35	F37	Vücut Pozisyonu
36	F18	SpO ₂
37	F1	EKG
38	F21	Nabız

Çizelge 4.2’de yer alan ReliefF ile özelliklerin sıralamasına göre ilk önce etkili 10 özellik belirlenmiştir. Bunlar Çizelge 4.3’te gösterilmiştir.

Çizelge 4.3. ReliefF ile seçilen ilk 10 özellik ve sinyaller


Sinyal Tipi	Özellik kodu	Seçilen ilk 10 özellik
EKG	F1	F2
	F2	F3
	F3	
	F4	
	F5	
	F6	
	F7	
	F8	
	F9	
	F10	
	F11	
Pressure Flow	F12	F12
	F13	F13
	F14	F14
Pressure Snore	F15	F15
	F16	
	F17	
SpO ₂	F18	
	F19	
	F20	
Nabız	F21	F29
	F22	
	F23	
	F24	
	F25	
	F26	
	F27	
	F28	
	F29	
Thorax	F30	F30
	F31	F31
	F32	F33
	F33	
	F34	
	F35	
Vücut Pozisyonu	F36	
	F37	
	F38	

Çizelge 4.3'te görüldüğü üzere en etkili ilk 10 özellik 5 tip sinyale aittir. Bu sinyaller EKG, Pressure Flow, Pressure Snore, Nabız ve Thorax sinyalleridir. Geliştirilen sistem çalışma esnasında hasta üzerinden mobil olarak veri alınmasını gerektirecektir. EKG verilerinin mobil olarak elde edilmesi her ne kadar mümkün olsa da tez kapsamında geliştirilecek sistemde EKG verilerinin kullanılması düşünülmemektedir. Bunun nedenlerinden biri, EKG verilerinin hastadan alınabilmesi için çok sayıda elektrodun hastanın çıplak teni üzerine yapıştırılması gerekliliğidir. Bu hem yatarken hastanın bir uzmandan yardım almadan kendisi tarafından doğru bir şekilde yapılması mümkün olmayan bir işlemdir. Hem de uyku sırasında hastanın vücut hareketleri neticesinde

bağlanan elektrotların kolayca hastanın vücudundan çıkabilmesi riski vardır. Bu durum sistemin veri akışını olumsuz etkileyecektir. Ayrıca yukarıdaki Çizelge 4.2’de görüldüğü gibi EKG verisi tahmine etki sırası açısından bakıldığında da 7. ve 9. sıralarda yer almaktadır. Bu da diğer sinyallere göre daha etkisiz olduğunu göstermektedir. Tüm bu nedenler, EKG verisinin geliştirilecek olan sistemde kullanılmaması düşüncesini doğurmuştur.

Nabız verisinin okunabilmesi için pulse oksimetre cihazı ile uyku sırasında hastadan anlık veri alınması işlemi de uygulama bakımından EKG verisine benzer sorunlar çıkarabilir. Ayrıca nabız verisinin de etkinliği 10. sırada olduğu da görülmektedir. Bu bakımdan bakıldığında nabız verisi de geliştirilen sistem üzerinde kullanılmamıştır.

ReliefF ile özellik seçimi sonucunda hem uygulama kolaylığı açısından hem de sistem başarısına etkileri bakımından üç fizyolojik sinyal sistemin ana giriş parametreleri olarak belirlenmiştir. Bu sinyaller Pressure Flow, Pressure Snore ve Thorax sinyalleridir. Bu sinyaller Şekil 4.7’de gösterilmiştir.



Şekil 4.7. Sistemin giriş parametreleri olan sinyaller

4.2. Solunum Olaylarının Eş Zamanlı Tespiti

Sinyal işleme çalışmalarından sonra elde edilen sinyal özellikleri kullanılarak uykuda solunum bozukluklarının tespit edilmesi için öncelikli olarak skorlama çalışması yapılmıştır. Skorlama, bir zaman diliminde meydana gelen solunum bozukluğu tipinin, o eş zamanlı olarak tespit edilmesi demektir. Skorlamada uyku uzmanları tarafından belirlenen 3’ü apne (tıkayıcı apne, santral apne ve karmaşık apne)1’i de hipopne olmak üzere 4 tip solunum bozukluğunun yapay zekâ yöntemleri ile tespiti üzerinde çalışılmıştır. Bir de solunum bozukluğu olmayan durum göz önüne alındığında 5 sınıflı bir sınıflandırma çalışması yapılmıştır. Sınıflandırmada kullanılan sınıf değerleri Çizelge 4.4’te gösterilmiştir.

Çizelge 4.4. Solunum olayları ve sınıf değerleri

Solunum Olayı	Sınıf Değeri
Normal	0
Hipopne	1
Tıkayıcı Apne	2
Karmaşık Apne	3
Santral Apne	4

Skorlama çalışmalarında önce 5 sınıfın tamamı için sınıflandırma yapılmıştır. Daha sonra sınıf sayısı azaltılarak sınıflandırma işlemleri tekrarlanmıştır. Son olarak da tez konusu olan tıkayıcı apnelerin tespiti için 2 sınıflı bir sınıflandırma işlemi gerçekleştirilmiştir. Yapılan tüm sınıflandırma çalışmalarında bir sınıflandırıcı yerine yedi farklı sınıflandırıcı kullanılarak sonuçlar karşılaştırılmıştır. Çizelge 4.5'te 5 sınıflı sınıflandırma sonuçları gösterilmiştir.

Çizelge 4.5. Beş sınıflı (0,1,2,3,4) sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	75	70	75	70,2
Artificial Neural Network	74	71,7	74	72,5
Decision Tree	73,3	69,4	73,3	69,8
K Nearest Neighborhood	71,3	61,3	71,3	63,9
Logistic Regression	71,1	59,8	71,1	63,2
Random Forest	76,3	73,2	76,3	72,5
Naive Bayes	57,4	68,3	57,4	60,6

Yukarıdaki sınıflandırma işlemlerinde kullanılan tüm sınıflandırıcılara ait karmaşıklık matrisleri Şekil 4.8, Şekil 4.9, Şekil 4.10, Şekil 4.11, Şekil 4.12, Şekil 4.13 ve Şekil 4.14'te verilmiştir.

		Tahmin				
		0	1	2	3	4
Gerçek	0	%73.70	%36.80	%26.80	NA	NA
	1	%13.10	%21.10	%7.00	NA	NA
	2	%11.00	%31.60	%53.10	NA	NA
	3	%1.00	%5.30	%9.20	NA	NA
	4	%1.30	%5.30	%3.90	NA	NA

NA (Not Applicable): Uygulanabilir değil

Şekil 4.8. KNN için karmaşıklık matrisi

		Tahmin				
		0	1	2	3	4
Gerçek	0	%72.00	NA	%29.10	%17.00	%100.00
	1	%13.10	NA	%4.90	%6.40	%0.00
	2	%11.60	NA	%61.90	%17.00	%0.00
	3	%1.80	NA	%2.70	%40.40	%0.00
	4	%1.50	NA	%1.40	%19.10	%0.00

NA (Not Applicable): Uygulanabilir değil

Şekil 4.9. Logistic Regression için karmaşıklık matrisi

		Tahmin				
		0	1	2	3	4
Gerçek	0	%84.40	%67.80	%45.80	%41.90	%62.60
	1	%9.70	%28.20	%11.30	%5.80	%1.70
	2	%5.40	%3.90	%41.40	%22.60	%16.90
	3	%0.10	%0.00	%0.80	%20.70	%6.50
	4	%0.40	%0.10	%0.80	%9.10	%12.30

Şekil 4.10. Naive Bayes için karmaşıklık matrisi

		Tahmin				
		0	1	2	3	4
Gerçek	0	%81.80	%51.00	%25.00	%22.80	%35.40
	1	%11.20	%40.30	%7.40	%4.20	%6.90
	2	%5.60	%8.20	%61.60	%22.80	%18.90
	3	%0.70	%0.10	%3.30	%36.10	%13.10
	4	%0.80	%0.40	%2.70	%14.10	%25.70

Şekil 4.11. Artificial Neural Network için karmaşıklık matrisi

		Tahmin				
		0	1	2	3	4
Gerçek	0	%79.10	%38.00	%19.00	%13.40	%13.20
	1	%12.20	%52.50	%5.60	%4.90	%0.00
	2	%6.70	%9.50	%68.70	%22.80	%18.40
	3	%0.90	%0.00	%3.70	%44.70	%10.50
	4	%1.00	%0.00	%2.90	%14.20	%57.90

Şekil 4.12. Random Forest için karmaşıklık matrisi

		Tahmin				
		0	1	2	3	4
Gerçek	0	%78.10	%40.80	%21.80	%16.80	NA
	1	%12.90	%45.60	%6.40	%4.60	NA
	2	%7.10	%13.60	%64.50	%20.60	NA
	3	%0.80	%0.00	%4.60	%42.90	NA
	4	%1.20	%0.00	%2.70	%15.10	NA

NA (Not Applicable): Uygulanabilir değil

Şekil 4.13 SVM için karmaşıklık matrisi

Gerçek	Tahmin				
	0	1	2	3	4
0	%78.20	%50.40	%26.20	%24.60	%33.30
1	%12.40	%41.50	%7.00	%2.80	%2.70
2	%7.50	%8.10	%61.10	%26.90	%22.70
3	%1.00	%0.00	%3.60	%30.50	%2.70
4	%1.00	%0.00	%2.10	%15.10	%38.70

Şekil 4.14. Decision Tree için karmaşıklık matrisi

Ayrıca, sınıflandırma işleminde yer alan tüm sınıflara ait verilerin kendi aralarındaki sınıflandırma sonuçları Çizelge 4.6, Çizelge 4.7, Çizelge 4.8, Çizelge 4.9 ve Çizelge 4.10’de verilmiştir.

Çizelge 4.6. Normal sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	77,8	78,1	94	85,3
Artificial Neural Network	78,1	81,8	87,5	84,5
Decision Tree	76,4	78,2	91	84,1
K Nearest Neighborhood	73,6	73,7	95,6	83,2
Logistic Regression	72	72	96,5	82,5
Random Forest	79	79,1	94,1	86
Naive Bayes	64,9	84,4	59,7	69,9

Çizelge 4.7. Hipopne sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	87,5	45,6	6,6	11,5
Artificial Neural Network	86,3	40,3	22,7	29,1
Decision Tree	87	41,5	11,5	18
K Nearest Neighborhood	87,5	21,1	0,2	0,4
Logistic Regression	87,6	0	0	0
Random Forest	87,8	52,5	12,6	20,4
Naive Bayes	80,7	28,2	36,2	31,7

Çizelge 4.8. Tıkayıcı Apne sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	88,5	64,5	59,5	61,9
Artificial Neural Network	88,2	61,6	66	63,7
Decision Tree	87,5	61,1	56,1	58,5
K Nearest Neighborhood	85	53,1	37,6	44
Logistic Regression	86,2	61,9	31,7	41,9
Random Forest	89,6	68,7	61,2	64,8
Naive Bayes	80,1	41,4	64,7	50,5


Çizelge 4.9. Karmaşık Apne sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	97,9	42,9	30,4	35,6
Artificial Neural Network	97,5	36,1	38,2	37,1
Decision Tree	97,3	30,5	32,5	31,5
K Nearest Neighborhood	98,1	0	0	0
Logistic Regression	98	40,4	5,7	9,9
Random Forest	97,9	44,7	32,8	37,9
Naive Bayes	94,1	20,7	73,1	32,3


Çizelge 4.10. Santral Apne sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	98,4	0	0	0
Artificial Neural Network	97,9	25,7	16,5	20,1
Decision Tree	98,3	38,7	10,7	16,7
K Nearest Neighborhood	98,4	0	0	0
Logistic Regression	98,4	0	0	0
Random Forest	98,5	57,9	8,1	14,2
Naive Bayes	95,1	12,3	34,2	18,1

Bu sınıflandırma işlemlerine ait ROC eğrileri de Şekil 4.15, Şekil 4.16, Şekil 4.17, Şekil 4.18 ve Şekil 4.19’da gösterilmiştir.





Şekil 4.15. 0 sınıfı sınıflandırma ROC eğrisi



Şekil 4.16. 1 sınıfı sınıflandırma ROC eğrisi

Şekil 4.18. 3 sınıfı sınıflandırma ROC eğrisi





Şekil 4.19. 4 sınıflı sınıflandırma ROC eğrisi

Yukarıda verilen sınıflandırma sonuçlarından da anlaşılacağı gibi her sınıfta yer alan veriler için sınıflandırma başarıları farklı çıkmaktadır. Bunda sınıflara ait veri sayıları etkili olabileceği gibi, solunum olaylarının yapısı ve o solunum olayındaki hastadan alınan sinyallerdeki farklılık da etkilidir. Yukarıdaki bilgilerden hareketle sınıf sayısının azaltılmasının sınıflandırma başarıları üzerine olumlu etkileri olacağı öngörüsünde bulunmak mümkündür. Sınıf sayısını azaltarak yapılan bazı sınıflandırma işlemlerine ait sonuçlar da aşağıda sunulmuştur. Burada yukarıdaki gibi tüm sınıflara ait başarı oranlarının ayrı ayrı verilmesine gerek görülmemiştir. Öncelikle “4-Santral Apne” sınıfına ait veriler veri setinden çıkarılarak aynı sınıflandırma işlemleri tekrarlanmıştır. Sınıf sayısının azaltılmasının başarı oranlarına etkisini görmek için sadece 0, 1, 2 ve 3 sınıflarına ait verilerin olduğu veri setinin sınıflandırma sonuçları Çizelge 4.11’de verilmiştir.

Çizelge 4.11. Dört sınıflı (0,1,2,3) sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	76,4	72,4	76,4	71,9
Artificial Neural Network	74,8	73,1	74,8	73,7
Decision Tree	74,4	71	74,4	71,8
K Nearest Neighborhood	72,5	63,5	72,5	65,5
Logistic Regression	72,3	61,9	72,3	64,8
Random Forest	77,3	74	77,3	73,7
Naive Bayes	59,6	68,8	59,6	62,2

Yine dört sınıflı bir sınıflandırma işleminde veri setinden “3-Karmaşık Apne” sınıfı veriler veri setinden çıkarılarak yeniden sınıflandırma işlemi yapılmış ve farklı sonuçlar elde edilmiştir. Aşağıda sadece 0, 1, 2 ve 4 sınıflarına ait verilerin olduğu veri setine ait sınıflandırma sonuçları Çizelge 4.12’de verilmiştir.

Çizelge 4.12. Dört sınıflı (0,1,2,4) sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	76,4	71,8	76,4	71,6
Artificial Neural Network	74,4	72,2	74,4	73
Decision Tree	74,8	71,1	74,8	71,7
K Nearest Neighborhood	72,7	65,5	72,7	65,8
Logistic Regression	72,4	61,2	72,4	64,8
Random Forest	77,4	74,3	77,4	73,5
Naive Bayes	58,1	68,9	58,1	61,3

Benzer şekilde sınıf sayısında azaltma yaparken apne türlerinden birisi olan “2-Tıkayıcı Apne” sınıfı veriler veri setinden çıkarılarak yeniden sınıflandırma işlemi yapılmış ve farklı sonuçlar da elde edilmiştir. Aşağıda sadece 0, 1, 3 ve 4 sınıflarına ait verilerin olduğu veri setine ait sınıflandırma sonuçları Çizelge 4.13’te verilmiştir.

Çizelge 4.13. Dört sınıflı (0,1,3,4) sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	81,9	77	81,9	76,2
Artificial Neural Network	79,3	77,8	79,3	78,4
Decision Tree	80,6	76,1	80,6	77,1
K Nearest Neighborhood	81,1	71,1	81,1	72,8
Logistic Regression	81,2	67,1	81,2	73
Random Forest	82,3	78,8	82,3	77,6
Naive Bayes	66,5	75,9	66,5	70

Bir başka dört sınıflı sınıflandırma işlemi de “1-Hipopne” sınıfına ait veriler veri setinden çıkarılarak yapılmıştır. Aşağıda Çizelge 4.14’te 0,2,3 ve 4 sınıflarının bulunduğu veri setinin sınıflandırma sonuçları verilmiştir.

Çizelge 4.14. Dört sınıflı (0,2,3,4) sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	85,7	83,3	85,7	84,4
Artificial Neural Network	84,7	84,4	84,7	84,5
Decision Tree	84,3	82,7	84,3	83,1
K Nearest Neighborhood	81,5	76,4	81,5	78,3
Logistic Regression	81,7	78	81,7	78,8
Random Forest	86,6	85,4	86,6	85,4
Naive Bayes	70,6	81,5	70,6	74,2

Benzer şekilde sınıf sayısında daha fazla azaltma işlemi uygulanarak farklı sonuçlar da elde edilmiştir. Aşağıda sadece 0, 1 ve 2 sınıflarına ait verilerin olduğu veri setine ait sınıflandırma sonuçları Çizelge 4.15’te verilmiştir.

Çizelge 4.15. Üç sınıflı (0,1, 2) sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	77,6	73,8	77,6	73,2
Artificial Neural Network	75,8	74	75,8	74,7
Decision Tree	75,8	72,3	75,8	73
K Nearest Neighborhood	73,9	67,4	73,9	67,4
Logistic Regression	73,6	63,3	73,6	66,4
Random Forest	78,7	75,4	78,7	75,1
Naive Bayes	61,9	69	61,9	63,9

Tez çalışmasının nihai amacının “2-Tıkayıcı Apne” sınıfı üzerine odaklandığını düşünerek 2 sınıflı sınıflandırma işlemi için sadece 0 ve 2 sınıflarının yer aldığı bir veri seti oluşturularak sınıflandırma işlemi uygulanmıştır. Elde edilen sonuçlar aşağıda Çizelge 4.16’da verilmiştir.


Çizelge 4.16. İki sınıflı (0,2) sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	88,9	88,4	88,9	88,5
Artificial Neural Network	87,2	87,2	87,2	87,2
Decision Tree	87,5	86,8	87,5	87
K Nearest Neighborhood	84,9	83,3	84,9	83,2
Logistic Regression	85,1	83,5	85,1	83,4
Random Forest	89,7	89,2	89,7	89,2
Naive Bayes	77,1	83,1	77,1	79

Skorlama (eş zamanlı tespit) için yapılan sınıflandırma çalışmalarının doğruluk oranları toplu halde Çizelge 4.17 ve Şekil 4.20’de sunulmuştur.

Çizelge 4.17. Skorlama için sınıflandırma doğrulukları (Acc)

	5 Sınıflı (0,1,2,3,4) (%)	4 Sınıflı (0,1,2,3) (%)	4 Sınıflı (0,1,2,4) (%)	4 Sınıflı (0,1,3,4) (%)	4 Sınıflı (0,2,3,4) (%)	3 Sınıflı (0,1,2) (%)	2 Sınıflı (0,2) (%)
Logistic Regression	71,1	72,3	72,4	81,2	81,7	73,6	85,1
Decision Tree	73,3	74,4	74,8	80,6	84,3	75,8	87,5
KNN	71,3	72,5	72,7	81,1	81,5	73,9	84,9
Naive Bayes	57,4	59,6	58,1	66,5	70,6	61,9	77,1
Random Forest	76,3	77,3	77,4	82,3	86,6	78,7	89,7
Neural Network	74	74,8	74,4	79,3	84,7	75,8	87,2
SVM	75	76,4	76,4	81,9	85,7	77,6	88,9



Şekil 4.20. Skorlama sınıflandırma doğrulukları (Acc)

Yukarıdaki sınıflandırma sonuçları ve grafik incelendiğinde veri setindeki sınıf sayısının azaltılmasının sınıflandırma başarısına olumlu yönde katkı sağladığı söylenebilir. Dört sınıflı uygulamalarda en yüksek başarı oranının 1- Hipopne sınıfının dahil edilmediği veri setinde (0,2,3,4) olduğu görülmektedir. Aynı şekilde üç sınıflı sınıflandırmadaki 1- Hipopne sınıfı veri setinden çıkarılarak veri seti iki sınıflı (sadece 0 ve 2) hale getirilince sınıflandırma başarısı ciddi anlamda bir sıçrama göstererek %89,7'ye kadar çıkmıştır.

Bunun nedeni, solunum bozukluğu olaylarının yapısı dikkate alındığında hipopne olayının diğer apne olaylardan yapısal olarak da farklı olduğu olarak yorumlanmaktadır. Yukarıda anlatıldığı gibi hipopne olayında solunumun azalması söz konusu iken, apne olaylarında solunumun tamamen durmaktadır. Bu durum hastadan alınan PSG sinyallerine de yansıdığı için hipopne veri setindeki en belirgin sinyal farklılığını oluşturmaktadır. Bu nedenle sadece hipopne sınıfına ait sinyaller kendi arasında sınıflandırmaya tabi tutulduğunda %87,8 gibi yüksek bir sınıflandırma başarısı gerçekleşmişken, tüm verilerle birlikte sınıflandırmaya girdiğinde sınıflandırma başarısını düşürdüğü görülmüştür.

Son olarak, tez çalışmasının odak noktasının “tıkayıcı uyku apnesi” rahatsızlığı yani, “2-Tıkayıcı Apne” sınıfının tespit edilmesi olduğu için skorelama başarısında en yüksek oranın %89,7 olduğunu tekrar ifade etmekte fayda vardır.

Tüm skorelama işlemlerinde en başarılı sınıflandırıcı Random Forest olarak ortaya çıkmıştır. Random Forest algoritması binlerce değişkene ve fazla sayıda sınıf etiketine sahip kategorik değişken içeren, kayıp verili veya dengesiz bir dağılım sergileyen veri setlerini kullanarak sonuçlar üretebilir. Bu sebeple de biyomedikal veriler üzerinde başarılı sonuçlar üreten bir algoritma olarak bilinir. Bu çalışmada kullanılan veri seti de çok fazla sayıda değişken içeren ve dengesiz bir biyomedikal veri setidir. Veri setinin gerçek hasta verilerinden oluştuğu daha önce belirtmiştir. Random Forest'in bu çalışmada en başarılı sonucu üreten algoritma olması, veri setimizin algoritmanın başarılı çalışabileceği uygun bir veri seti olmasına dayanmaktadır.

4.3. Apne Tahmin Zamanının Belirlenmesi

Yukarıda anlatıldığı gibi sinyal işleme PSG sinyalleri ön işleme yapıldıktan sonra 30 saniyelik epoklara ayrılmıştı. Her bir epok PSG sisteminden elde edilen ve solunum olaylarını gösteren skorelama verileri ile eşleştirildi. Bu eşleştirme neticesinde her epokta

meydana gelen apneler fizyolojik sinyallerden elde edilen verilerle 30 saniyelik zaman aralıkları ile eşleştirilmiş oldu. Ancak, bu eşleştirme eş zamanlı olarak her sinyalin o epokta ortaya çıkardığı apne durumunu göstermektedir. Çalışmanın amaç kısmında belirtildiği üzere, çalışmada apne olayı ortaya çıkmadan tahmin etmek amaçlanmaktadır. Bu bakımdan bakıldığında sistem, her epoka karşılık gelen apne durumunu değil bir epok sonrasındaki apne durumunu tespit edebilmelidir. Bu amaçla, her epoktan çıkarılan sinyal özellikleri kullanılarak bir sonraki epogun sınıf değeri tahmin edilmeye çalışılmıştır. Her bir epogun hangi sınıf değeriyle eşleştirilerek veri setinin nasıl düzenlendiğini Şekil 4.21’de görebilirsiniz.

	Epok 1	Epok 2	Epok3	Epok4	Epok 5	Epok 6
1						
2						
3						
4						
5						
6						
7						
...						
7680						
Sınıf:		?	?	?	?	?

Şekil 4.21. Apne tahmini için epoklar ile sınıf eşleştirmeleri

Yukarıda Şekil 4.21’de apne durumunu gösteren her bir sınıf değerinin 60 saniyelik yani 2 epokluk veri ile eşleştirildiği görülmektedir. Her sınıf değerinin tahmin edilmesinde hem o epoktaki hem de bir önceki epoktaki veriler kullanılmıştır. Bu tahmin edilmeye çalışılan her sınıf değeri için bu şekilde ayarlanmıştır. Böylece epoklardaki verilerin üst üste binmiş bir görüntü oluşmuştur. Bunun amacı, meydana gelen bir apne olayının tahmin edilmesi öncesinde olası bir veri sızıntısının önlenmesidir. Böylece bir

epokta meydana gelecek olan apne olayının en az 30 saniye en fazla 60 saniye öncesindeki veriler ile tahmin edilmesi sağlanmıştır.

4.4. Gerçek Zamanlı Öğrenebilen Adaptif Sistem


Bu tez çalışmasındaki veriler durağan olmayan biyomedikal sinyallerden elde edilmektedir. Geliştirilen zeki PAP cihazının çalışmasında da durağan olamayan ve hastadan gerçek zamanlı olarak toplanan veriler kullanılmıştır. Zeki PAP cihazının anlık olarak hastadan gelen verilere göre sürekli öğrenen ve her çıkış vereceğinde de en uygun eğitim verilerini kullanarak çıkış üretmesi amaçlanmaktadır. Bu amaca bağlı olarak belirli bir periyotla gerçek zamanlı öğrenme yapabilen ve her öğrenme sonrası performans değerlendirmesi yaparak ağ parametrelerini güncelleyen adaptif bir sistem tasarımı düşünülmüştür. Bu çalışmada, içerisinde iki gizli katmana sahip bir yapay sinir ağının yer aldığı bir adaptif sistem tasarlanmıştır. Çalışmadaki işlemler MATLAB yazılımı kullanılarak gerçekleştirilmiştir.

4.4.1. Ön Eğitim

Bu çalışmada 75 hastaya ait 54553 epokluk sinyal verisinden çıkarılan öznelikler üzerinde apne tahmin sistemi kurulabilmesi için, Desicion Tree, Logistic Regression, Support Vector Machine, Naive Bayes, kNN ve Artificial Neural Network olmak üzere altı farklı makine öğrenmesi yöntemi ile sınıflandırma yapılmış ve en başarılı sonucu üreten Artificial Neural Network tercih edilmiştir. Kullanılan tüm makine öğrenmesi algoritmalarına ait sonuçlar Çizelge 4.18’de gösterilmiştir. Sonuçlara ait grafik de Şekil 4.22’te gösterilmiştir.

Çizelge 4.18. Apne tahmini için sınıflandırma sonuçları

Model	Acc (%)	Precision (%)	Recall (%)	F1 Score (%)
Support Vector Machine	86,6	95,8	88,6	92,1
Artificial Neural Network	95,2	96,5	97,7	97,1
Decision Tree	84,1	92,8	88,3	90,5
K Nearest Neighborhood	86,3	94,7	89,2	91,9
Logistic Regression	81,4	96,6	83,2	89,4
Naive Bayes	81,5	84,9	91,7	88,2




Şekil 4.22. Apne tahmini için sınıflandırma sonuçları

Bu çalışmada gerçek zamanlı öğrenen, iki gizli katmana sahip, ileri beslemeli bir YSA tasarlanmıştır. Bu ağ, cihaz çalıştığı sürece hastadan sensörler vasıtasıyla online olarak toplanan verilerden elde edilen özellikleri giriş olarak alarak, hastanın hava yolunda meydana gelebilecek apnelerin önceden tahmin edilmesini sağlamaktadır. Pressure flow sinyalinin 3, pressure snore sinyalinin 1 ve thorax sinyalinin 3 özellik vektörü olmak üzere yapay sinir ağına toplam 7 sinyal özelliği giriş parametresi olarak verildiği için, 7 girişli bir YSA yapısı oluşturulmuştur. Hazırlanan ağın çıkışında sadece apne riski olup olmadığı tahmin edilmektedir. Bu yüzden ağ tek çıkışlıdır. Ağ, yaptığı sınıflandırma sonucunda apne riski olduğunda 1, risk olmadığı durumlarda 0 verisini çıkış olarak üretmektedir. Oluşturulan yapay sinir ağının parametreleri Çizelge 4.19’da topolojik tasarım görünümü de Şekil 4.23’te verilmiştir

Çizelge 4.19. Yapay sinir ağı parametreleri

Parametre	Değeri
Ağ tipi	İleri beslemesi
Eğitim fonksiyonu	Trainbr (Bayesian Regularization)
Gizli katman sayısı	2
Gizli katman nöron sayıları	55, 50
Aktivasyon fonksiyonu	Tansig (Sigmoid)
Maksimum iterasyon sayısı	1000
Performans fonksiyonu	MSE
Eğitim oranı	%70
Test oranı	%15
Doğrulama oranı	%15



Şekil 4.23. Yapay sinir ağı

Ön eğitim için en başarılı sınıflandırmayı yapan yapay sinir ağı, online verilerle ilk çıkışı üretebilmesi için hastaneden elde edilen 75 hastaya ait PSG verilerinden çıkarılan özellikler kullanılarak eğitilmiştir. Bu eğitim sonucunda %95,2 doğruluk oranı, %97,7 recall oranı, %96,5 precision oranı ve %97,1 F1 Skoru elde edilmiştir. Yapay sinir ağına ait ön eğitim başarısını gösteren karmaşıklık matrisi Şekil 4.24'te gösterilmiştir. Sınıflandırma işlemleri MATLAB yazılımında yapılmış ve uygulanan tüm sınıflandırma yöntemlerinde verilerin %70'i eğitim, %15'i test, %15'i de doğrulama için kullanılmıştır.

		Tahmin	
		0	1
Gerçek	0	%79.60	%1.80
	1	%2.90	%15.60


Şekil 4.24. Ön eğitim sınıflandırma başarısı

Cihaz çalışmaya başladığında hastadan alınan ilk verilerle yapay sinir ağının apne tahmini yapabilme kabiliyeti kazanması için, ağın kullanacağı weight ve bias değerlerinin önceden belirlenmesi gerekir. Bu amaçla 75 hastadan alınan verilerle ön eğitimi tamamlayan sistemin ilk çıkışı üretebilmesi sağlanır. Daha sonraki süreç içerisinde sistem belirlenen bir periyotta sürekli olarak hastadan aldığı her yeni biyomedikal sinyalleri kullanarak ağın eğitimine devam etmektedir. Yapay sinir ağı performans fonksiyonu olarak MSE'yi kullanan sistem ağ performans değerlendirmesi yaparak gerekli gördüğünde eğitimini güncellemektedir.

4.4.2. Sürekli eğitim ve adaptif çalışma

Sinir ağı, ilk eğitimini hastaneden alınan 75 hastaya ait veriler ile gerçekleştirerek işe başlamıştır. Daha sonra sinir ağı, gerçek zamanlı öğrenen bir yapıda olması için, belirlenen bir periyotta sensörlerden gelen her yeni veri ile öğrenme faaliyetine devam etmektedir.

Bu çalışmada uygulanan adaptif sistem, her yeni veri ile çıkış ürettikten sonra ağın performansını MSE (Denklem 3.10) yöntemiyle değerlendirmekte ve daha başarılı bir performans elde edebilmek için gerekiyorsa ağı yeniden eğiterek ağın weight ve bias değerlerini güncellemektedir. Böylece bir sonraki gelen veriler, yeniden eğitilmiş ve daha başarılı performansa sahip bir ağ ile işlenerek çıkış üretilmesi sağlanmıştır. Bu adaptif sistem döngüsü belirli bir periyotta sürekli olarak devam etmektedir. Gerçek zamanlı öğrenen adaptif sistem tasarımı Şekil 4.25'te gösterilmiştir.



Şekil 4.25. Gerçek zamanlı öğrenen adaptif sistem tasarımı

Çalışmada elde edilen sonuçlar, adaptif sistem döngüsü periyodu 2 saniye olarak ayarlandığında elde edilen sonuçlardır. Adaptif sistem döngüsü periyodunun 2 saniye olarak belirlenmesi uzman hekim tavsiyesi üzerine tercih edilmiştir. Ancak, bu değer yazılım vasıtasıyla istenildiği gibi değiştirilebilmektedir. Aşağıda 2 saniyelik adaptif sistem döngüsünde gerçekleştirilen işlemler maddeler halinde verilmiştir:

- Hastadan yeni verilerin alınması.
- Alınan ham fizyolojik sinyal verilerinin ön işlemeden geçirilmesi.
- Bu sinyallerden özellikler çıkarılması.
- Çıkarılan sinyal özellikleri ile YSA'nın, apne tahmin çıkışını (0-1) üretmesi.
- Performansa göre gerekirse ağın yeniden eğitilerek ağ parametreleri güncellenmesi.

4.5. Gerçek Zamanlı Veri Toplama


Hastaneden alınan 75 hasta verisi sistemin giriş parametrelerinin belirlenmesinde kullanılmıştır. Bu veriler aynı zamanda sistemin çalışmaya başladığında kullanacağı ilk öğrenme verilerdir. Ayrıca, geliştirilen sistemin gerçek zamanlı öğrenen bir yapıda olduğu bilgisine dayanarak, ilk öğrenmeden sonra hasta üzerinden aldığı fizyolojik verilerle öğrenme faaliyetini devamlı olarak sürdüren ve bu öğrenmeye göre çıkış üretebilen bir sistem geliştirilmiştir. Bu amaçla özellik seçimi sonrası belirlenen Pressure Flow (256 Hz), Pressure Snore (256 Hz) ve Thorax (32 Hz) sinyallerinin hasta üzerinden okunabilmesi için üzerinde gömülü bilgisayar sistemi bulunan bir veri toplama kartı ve yazılımı geliştirilmiştir. Veri okuma kartında STM32F407 gömülü sistem kullanılmaktadır. Bu sistem 168 MHz İşlemci frekansına ve 192 KB RAM'e ve 1 MB depolama belleğine sahiptir. Pressure Flow ve Pressure Snore sinyallerinin elde edilebilmesi için Sleep Sense firmasına ait Multi-Press (AC/DC Pressure Flow / Snore Sensor) sensör kiti kullanılmıştır. Bu kite ait teknik özellikler Çizelge 4.20'de verilmiştir. Thorax sinyallerinin elde edilmesi için de yine Sleep Sense firmasına ait Multi-Rip (Two Channels + Sum) sensör kiti kullanılmıştır. Bu kite ait teknik özellikler Çizelge 4.21'de verilmiştir. Geliştirilen veri toplama kartı Şekil 4.26'da baskı devre şeması da Şekil 4.27'de görülmektedir.

Çizelge 4.20. Multi-Press Sensör Kiti Teknik Özellikleri


Teknik Özellik	Değeri
DC Sinyali çıkış kalibrasyonu	50mV/1cm H2O
Basınç aralığı	-3 - 40cm H2O, -0.15V -2V DC çıkış
Genel doğruluk	20°C - 40°C aralığında +/- 0,7cm H2O
AC çıkış hassasiyeti	Orta seviye - Normal solunum için yaklaşık 1mV
Snore çıkış hassasiyeti:	Orta seviye - Orta dereceli solunum için yaklaşık 1mV
Depolama sıcaklığı	-20°C (-4°F) - 60°C (140°F)
Çalıştırma ve saklama nemi:	%5 - %95 (Yoğuşmasız)

Çizelge 4.21. Multi-Rip Sensör Kiti Teknik Özellikleri

Teknik Özellik	Değeri
Önerilen filtre ayarları	0,1 Hz - 40 Hz veya sistem talimatları
Çalışma koşulları	5°C (40°F) - 40°C (104°F)
Depolama sıcaklığı	-20°C (-4°F) - 60°C (140°F)
Çalıştırma ve saklama nemi:	%5 - %95 (Yoğuşmasız)



Şekil 4.26. Gömülü bilgisayar sistemi ve veri toplama kartı



Şekil 4.27. Veri toplama kartı baskı devre şeması

4.5.1. Veri toplama kartı gömülü sistem programlaması

Yukarıda bahsedilen gömülü bilgisayar sisteminin hastalardan alınması gereken verileri istenilen frekanslarda ve istenilen formatta elde edilmesini sağlamak için C programlama dili kullanılarak gömülü sistem programlaması gerçekleştirilmiştir. Geliştirilen bu veri okuma yazılımı, PSG sistemi tarafından verilen ham sinyal verileriyle birebir uyumlu verilerin elde edilmesini sağlamıştır.

4.5.2. Verilerin bilgisayar ortamına aktarılması

Gömülü bilgisayar sistemi ve veri toplama kartı kullanılırken hastanede PSG sistemlerinde yapılan veri okuma sisteminin bir benzerinin geliştirilmesi amaçlanmıştır. Hastaneden elde edilen hazır hasta verileri ile geliştirilen sinyal işleme ve YZ yazılımlarının hasta üzerinden anlık elde edilen verilerle de uyumlu çalışabilmesi açısından bu bir zorunluluktur. Bu bakımdan, analog olarak elde edilen sensör verileri PSG sisteminin çıktıları ile aynı formatta sayısal veriler olarak bilgisayar ortamına aktarılması gerçekleştirilmiştir. Aşağıda Şekil 4.28’de hasta üzerinden anlık veri okuma işleminin nasıl gerçekleştirildiğini gösteren bir fotoğraf yer almaktadır.




Şekil 4.28. Hastadan anlık veri okuma işlemi

Geliştirilen bu kart ve yazılım ile PSG sisteminin verdiği ham sinyal verileri ile birebir uyumlu veriler edilmesi sağlamıştır. Bu yazılım, belirlenen periyotta sürekli olarak iki epokluk veri okuyarak gerçek zamanlı öğrenen sisteme aktarmaktadır. Burada belirlenen periyot aynı zamanda gerçek zamanlı öğrenme faaliyetinin çalışma periyodunu

da belirlemektedir. Şekil 4.29’de sensörlerden elde edilen biyomedikal sinyallerin veri toplama kartına, veri toplama kartından bilgisayar sistemine oradan da yeni nesil PAP cihazının ana kartına aktarılması blok diyagram olarak gösterilmiştir.






Şekil 4.29. Veri okuma blok diyagramı

4.5.3. Pozitif hava basıncının belirlenmesi

Otomatik PAP cihazları belirli bir basınç aralığında pozitif hava üretirler. Bunun için öncelikle minimum ve maksimum basınç değerleri belirlenir. Her hastaya uygulanacak minimum ve maksimum basınç değerleri uzman hekim tarafından belirlenmelidir. Ayrıca, geliştirilen sistem, apne riski algıladığında ve risk devam ettiğinde, oluşacak apneleri önlemesi için basınç değerini bu iki değer arasında adım adım artırmaktadır. Her adımdaki artış değeri, uzman hekim tarafından minimum ve maksimum basınç değerleri arasındaki fark büyükse daha büyük, fark az ise daha küçük belirlenebilmektedir. Her adımdaki artış değerinin ne kadar olacağı da yine uzman hekim tarafından belirlenmelidir. Cihazın çalışma esnasındaki pozitif basınç aralığını belirleyen minimum ve maksimum basınç değerleri, her adımdaki artış miktarı ve adaptif sistem döngüsü periyodu geliştirilen cihazın yazılımı ile belirlenebilmektedir. Blower motor pozitif hava basınç değerini belirleme algoritması Şekil 4.30'daki akış diyagramında gösterilmiştir.



Şekil 4.30. Pozitif hava basıncı belirleme algoritması

Bu çalışmada yapılan testlerde aşağıdaki değerler uzman hekim tavsiyesi üzerine belirlendikten sonra sistem çalıştırılmıştır.

- Minimum basınç: 2 cmH₂O
- Maksimum basınç: 10 cmH₂O
- Artış adımı: 0,5 cmH₂O
- Periyot = 2 saniye

Sistemin ürettiği çıkış değerleri Çizelge 4.22’da gösterilmiştir.


Çizelge 4.22. Sistem simülasyon çıktıları

Zaman	YSA Çıktısı	Basınç (cmH ₂ O)
00.00.00	0	2,0
00.00.02	0	2,0
00.00.04	1	2,5
00.00.06	1	3,0
00.00.08	1	3,5
00.00.10	0	2,0
00.00.12	0	2,0
00.00.14	1	2,5
00.00.16	1	3,0
00.00.18	1	3,5
00.00.20	1	4,0
00.00.22	1	4,5
00.00.24	1	5,0
00.00.26	1	5,5
00.00.28	1	6,0
00.00.30	1	6,5
00.00.32	1	7,0
00.00.34	1	7,5
00.00.36	1	8,0
00.00.38	1	8,5
00.00.42	1	9,0
00.00.44	1	9,5
00.00.46	1	10,0
00.00.48	1	10,0
00.00.50	1	10,0
00.00.52	0	2,0
00.00.54	0	2,0
00.00.56	0	2,0
00.00.58	1	2,5
00.01.00	1	3,0

Sistem, YSA'nın çıkışında 1 değerini her gördüğünde basıncı 0,5 cmH₂O artırmaktadır. Sistem, çıkışta 1 görmeye devam ettikçe basıncı da artırmaya devam etmektedir. YSA arka arkaya 1 değerleri üretiyorsa apne riski devam ediyor ve risk verilen hava basıncı ile ortadan kaldırılamamış, yani daha fazla basınca ihtiyaç var demektir. Bu açıdan bakıldığında, YSA'nın çıkışında 0 değerini görünceye kadar, yani apne riski ortadan kalkıncaya kadar, sistem hava basıncını artırmaya devam etmektedir.

Ancak, bu artışın da bir sınırı olmalıdır. O da başlangıçta belirlenen maksimum basınç değeridir. Sistem YSA'nın çıkışında 0 (sıfır) değerini görünce apne riski ortadan kalktığı için hava basıncını minimum basınç değerine düşürmektedir. Şekil 4.30'da gösterilen, algoritmadaki pozitif hava basıncı belirleme prensipleri, apne riski devam ettiği sürece basınç artırma ve apne riskini ortadan kaldırdıktan sonra minimum basınç değerine dönmesi, tamamen uzman hekimin uygun görüşü alınarak belirlenmiştir.

Ayrıca sistemin nasıl çalıştığını gösteren simülasyon eğrisi de Şekil 4.31'de görülmektedir.



Şekil 4.31. Sistem simülasyon eğrisi

4.6. Cihaz Prototipinin Oluşturulması

Tez çalışması kapsamında tıkalı uyku apnesi hastalarının uyurken evlerinde kullanabileceği bir sistem üzerinde çalışılmıştır. Geliştirilen sistem yapay zekâ tabanlı yeni nesil bir PAP cihazıdır. Bu çalışmada geliştirilen cihaz, geleneksel PAP cihazlarının aksine apneyi tespit ettikten sonra terapi uygulayan bir cihaz değil, apneleri oluşmadan önce tahmin edebilen bir cihazdır. Bu sistem, hastadan anlık olarak aldığı fizyolojik verileri makine öğrenmesi yöntemleri ile işleyerek hastanın havayoluna apne oluşmadan pozitif hava göndererek apne riskini ortadan kaldırmayı amaçlamaktadır. Böylece hastanın uyku konforu bozulmadan apneleri önlemeye yönelik bir terapi uygulaması gerçekleştirilebilecektir.

Makine öğrenmesi ile hastanın uyku davranışlarını öğrenerek hastayı tanıyan sistem, kişisel bir tedavi uygulamayı amaçlamaktadır. Hastanelerin uyku servislerinde hastaların 2 gün yatırılmasının da önüne geçecek bir sistem olacaktır. Böylece, uyku servislerindeki doluluk yarı yarıya düşecek, insanlar daha kısa süre içerisinde randevu alabilecek ve bu servislere yapılan yatırım maliyetleri de azalacaktır. Bunlara ek olarak bu çalışma, ülkemizde uyku servislerine olan ihtiyacı azaltacağından dolayı gerek yatırım maliyeti gerekse personel giderlerinin azaltılması ile ekonomik olarak da ülkemize katkısı olacak bir çalışmadır. Ayrıca çalışmanın, uyku cihazı üreticileri için de bir rol model olacağı düşünülmektedir.


Geliştirilen prototip cihazda şu donanım birimleri yer almaktadır:

- Abdominal ve Thorax sensörleri
- Solunum akış ve horlama sensörleri
- Veri toplama kartı
- Cihaz ana kartı
- Dokunmatik ekran
- Blower motor
- Hava akış hortumu
- Maske
- Nazal kanül

Geliştirilen prototip cihazın dış görünüşü Şekil 4.32’de iç görünüşü ise Şekil 4.33’de gösterilmiştir.



Şekil 4.32. Prototip cihaz dış görünüşü



Şekil 4.33. Prototip cihaz iç görünüşü

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

Uyku apnesi sendromu hem bireylerin yaşam konforunu kötüleştiren hem de ciddi sağlık sorunlarına yol açabilen bir hastalıktır. PAP cihazları bu hastalığın tedavisinde çok önemli rol oynamaktadır. PAP cihazlarının geliştirilmesi için kullanılacak veriler ve bu cihazlarda kullanılan algoritmalar, cihazın hastaya nasıl bir terapi uygulayacağını belirlemektedir. Uygulanan terapi, hastalığın seyrini ve hasta sağlığını doğrudan etkilemektedir.

Literatürde yer alan çalışmalarda, genellikle uyku apnesinin tespiti üzerine çalışılmıştır. Literatürdeki akademik çalışmaların çoğunda apne olaylarının tespiti, apne sınıflandırması ya da AHI'nin tespiti için çalışmalar yapılmıştır. Literatürde apne oluşmadan tahmin etmeye dönük çalışmalar yok denecek kadar azdır. Bu çalışma ise apne tespiti değil apneyi tahmin üzerine temellendirilmiştir. Bu amaçla, etkili PSG sinyallerinin tespit edilebilmesi amacıyla sinyal işleme yöntemlerinden yararlanılırken aynı zamanda birçok makine öğrenmesi yöntemi de kullanılmıştır. Bu tez çalışmasında sadece teorik olarak apne tahmini ile yetinilmemiş apne tahmini ile çalışan bir PAP cihazı da geliştirilmiştir.

Bu tez çalışmasında yeni nesil zeki ve adaptif sisteme sahip bir PAP cihazının geliştirilmesi amacıyla hastanelerin uyku servislerine başvurmuş ve 75 hastanın PSG sinyalleri alınmıştır. Alınan PGS sinyalleri Pressure Flow, Pressure Snore, EKG, Thorax (göğüs hareketleri), SpO₂, nabız ve vücut pozisyonu olarak belirlenmiştir. Bu yedi fizyolojik sinyalin tamamı DC bileşenlerin temizlenmesi, şebeke geriliminin temizlenmesi, filtreleme ve normalizasyon gibi ön sinyal işleme süreçlerinden geçirilmiştir. Bu sinyallerin örnekleme frekansları ve anlamlı oldukları frekans aralıkları da farklıdır. Filtreleme işleminde tüm sinyaller için literatüre dayalı bir filtreleme gerçekleştirilmiştir.

Ön işleme tamamlanan sinyallerin ham olarak kullanılması, sinyallerden anlam elde edilebilmesi açısından doğru bir yöntem değildir. Bu yüzden sinyallerden anlamlı veriler elde edebilmek için özellik çıkarma işlemi gereklidir. PSG sinyalleri durağan olmayan sinyallerdir. Durağan olmayan sinyallerden özellik çıkarabilmek için belirli zaman aralıklarında sinyallerin parçalara ayrılması gerekir. Bu parçalara epok denir. Bu

tez çalışmasında kullanılan biyomedikal sinyaller gerek literatür araştırması gerekse uzman görüşüne dayanarak, epok süresi 30 saniye olacak şekilde parçalara ayrılmıştır. 75 hastaya ait 7 tip PSG sinyalinden 54553 epok sinyal verisi elde edilmiştir. Daha sonra sinyallerden özellik çıkarma için hem zaman domeninde hem de frekans domeninde özellik çıkarma işlemleri üzerine çalışılmıştır. Zaman domeninde mutlak değerlerin aritmetik ortalaması, standart sapma, eğiklik, basıklık, sinyalin enerjisi ve entropilerin ortalaması özellikleri çıkarılmıştır. Frekans domeninde yapılan çalışmalarda ise farklı özellik çıkarma algoritmaları uygulanmıştır. Bu çalışmada PSD, KZFD, ADD ve AR için Yule-Walker, Burg ve Covariance yöntemleri kullanılmıştır. Hem zaman hem de frekans domeninde belirtilen özellik çıkarma yöntemlerin tamamı (yönteme ait farklı parametre değerleriyle birlikte ayrı ayrı) bütün fizyolojik sinyaller için uygulanmış ve her sinyal için en başarılı sonucu üreten yöntem o sinyal tipi için tercih edilmiştir. PSG sinyalleri, her sinyal için tercih edilen özellik çıkarma yöntemi ve özellik sayıları Şekil 4.6'da detaylı olarak gösterilmiştir. 7 tip PSG sinyalinden toplam 38 adet özellik elde edilmiştir.

Tez çalışması kapsamında geliştirilen zeki ve adaptif sistem tasarımında elde edilen bu 38 özelliğin de kullanılması geliştirilen cihazda da hastadan bu 7 fizyolojik sinyali toplayabilecek donanımın bulunması gerekliliğini ortaya koyar. Bu gereklilik hem maliyet hem kullanılabilirlik hem de sistem çalışma performansı açısından sorunlar doğurmaktadır. Bu yüzden sistem başarısında en etkin özelliklerin belirlenmesi amacıyla ReliefF özellik seçme algoritması kullanılmıştır. 38 özelliğin etkinlik sıralaması Çizelge 4.2'de gösterilmiştir. Bu etkinlik sıralamasına dayanarak ilk önce en etkin 10 sinyal özelliğinin çıkarıldığı EKG, Pressure Flow, Pressure Snore, nabız ve Thorax sinyalleri belirlenmiştir. Daha sonra ise, cihaz kullanılabilirliği açısından EKG ve nabız sinyalleri de çalışma dışında bırakılmıştır. Böylece nihai olarak Pressure Flow, Pressure Snore ve Thorax sinyallerine ait 7 adet sinyal özelliği sistem girdisi olarak belirlenmiştir.

Sistem girdisi olarak 3 tip sinyalden 7 sinyal özelliğinin kullanılacağı belirlendikten sonra, çalışma beş aşamalı olarak sürdürülmüştür. Bunlar şunlardır:

1. Solunum olaylarının eş zamanlı tespiti
2. Apne tahmini
3. Gerçek zamanlı öğrenebilen adaptif sistemin geliştirilmesi
4. Pozitif hava basıncının belirlenmesi
5. Cihaz prototipinin oluşturulması

5.1.1. Solunum olaylarının eş zamanlı tespiti

Bu işlem, bir epoktaki verilere dayanarak o epokla aynı zaman dilimi içerisinde hangi solunum bozukluğunun meydana geldiğinin tespit edilmesidir. Bu işlemin diğer adı “skorlama”dır. Çalışmada 3’ü apne (tıkayıcı apne, karmaşık apne ve santral apne) 1’i de hipopne olmak üzere 4 tip solunum bozukluğunun yapay zekâ yöntemleri ile tespiti üzerine uygulamalar yapılmıştır. İlk önce tüm solunum olaylarının yer aldığı veri seti üzerinde sınıflandırma çalışması yapılmıştır. Sonuç olarak en yüksek sınıflandırma doğruluk oranı %76,3 ile Random Forest sınıflandırıcısı tarafından gerçekleştirilmiştir. Daha sonra veri setindeki solunum olaylarının sayısı azaltılarak sınıflandırma çalışmaları tekrar edilmiştir. Öncelikle sadece “Santral Apne” sınıfına ait veriler veri setinden çıkarılarak aynı sınıflandırma işlemi tekrarlanmıştır. Bu sınıflandırmada en yüksek sınıflandırma doğruluk oranı %77,3 ile Random Forest sınıflandırıcısı tarafından gerçekleştirilmiştir. Bir sonraki skorlama uygulamasında veri setinden sadece “Karmaşık Apne” sınıfı veriler veri setinden çıkarılarak yeniden sınıflandırma işlemi yapılmış ve farklı sonuçlar elde edilmiştir. Bu sınıflandırma işleminde en yüksek doğruluk oranı %77,4 ile Random Forest sınıflandırıcısı tarafından gerçekleştirilmiştir. Daha sonra öncekilere benzer şekilde sadece “Tıkayıcı Apne” sınıfı veriler çıkarılarak sınıflandırma işlemi yapılmıştır. Bu sınıflandırma işleminde en yüksek doğruluk oranı %82,3 ile Random Forest sınıflandırıcısı tarafından gerçekleştirilmiştir. Son olarak sadece “Hipopne” sınıfı veriler çıkarılarak yapılan sınıflandırmadan elde edilen sonuçlara göre de en başarılı sınıflandırıcı %86,6 doğruluk oranı ile yine Random Forest sınıflandırıcı olmuştur.

Sınıflandırma işlemi için veri setinde yer alan sınıf sayısının azaltılmasının sınıflandırma doğruluğu üzerinde olumlu etki yaptığı görülmüştür. Kademeli olarak sınıf sayıları azaltılarak sınıflandırma işlemleri tekrar edilmiştir. Bir sonraki adımda veri setinden “Santral Apne” ve “Karmaşık Apne” verileri çıkarılmış ve yapılan sınıflandırmada Random Forest sınıflandırıcı ile %78,7 doğruluk oranına ulaşılmıştır.

Son olarak, tez çalışmasının nihai amacının “Tıkayıcı Apne” sınıfı üzerine odaklandığını düşünerek sadece diğer solunum bozukluğu tipleri veri setinden çıkarılarak sadece “Tıkayıcı Apne” tespiti yapan bir skorlama gerçekleştirilmiştir. Bu işlem sonucunda Random Forest sınıflandırıcı %89,7 ile en yüksek doğruluk oranına ulaşmıştır.

Skorlama çalışmalarında elde edilen sınıflandırma doğruluk oranları Çizelge 5.1’de toplu olarak gösterilmiştir.

Çizelge 5.1. Skorlama için sınıflandırma sonuçları

	0,1,2,3,4 * (%)	0,1,2,3 (%)	0,1,2,4 (%)	0,1,3,4 (%)	0,2,3,4 (%)	0,1,2 (%)	0,2 (%)
Logistic Regression	71,1	72,3	72,4	81,2	81,7	73,6	85,1
Decision Tree	73,3	74,4	74,8	80,6	84,3	75,8	87,5
KNN	71,3	72,5	72,7	81,1	81,5	73,9	84,9
Naive Bayes	57,4	59,6	58,1	66,5	70,6	61,9	77,1
Random Forest	76,3	77,3	77,4	82,3	86,6	78,7	89,7
Neural Network	74	74,8	74,4	79,3	84,7	75,8	87,2
SVM	75	76,4	76,4	81,9	85,7	77,6	88,9

* 0-Normal, 1-Hipopne, 2-Tıkayıcı Apne, 3-Karmaşık Apne, 4-Santral Apne

Çizelge 5.1 analiz edildiğinde, sınıflandırma başarısında en yüksek sıçramanın hipopne sınıfı verilerin çıkarılması ile elde edildiği görülmektedir. Bunun nedeni diğer solunum bozukluğu tipleri olan apneler ile hipopne arasındaki fiziksel farktır. Tez çalışmasının çalışma alanı tıkayıcı apneler olduğundan dolayı tıkayıcı apne skortlama başarısındaki doğruluk oranının %89,7 olduğunu tekrar belirtmek gerekir.

5.1.2. Apne tahmini

Apne tahmini bir epoktaki PSG sinyal verileri ile daha sonraki bir zaman diliminde meydana gelme ihtimali olan apneyi öngörme işlemidir. Yapay zekâ tekniklerini kullanmadan önce tahmin süresi belirlenmiştir. Çalışmada ideal olan epok süresi 30 saniye olarak seçildiği için bir epokta meydana gelme ihtimali olan apnelerin bir önceki epoktaki verilerle tahmin edilmesi 30-60 saniye arasında bir tahmin süresi anlamına gelmektedir. Sinyal verileri apne tahmini uygun şekilde dizayn edildikten sonra sinyal özellikleri çıkarılarak yapay zekâ yöntemleri uygulanmıştır. Apne tahmini için de farklı sınıflandırıcılar ile uygulamaları yapılmış ve en yüksek tahmin doğruluk oranı %95,2 ile Yapay Sinir Ağları ile elde edilmiştir. Tüm sınıflandırıcılar ile elde edilen sınıflandırma sonuçları toplu olarak Çizelge 5.2’de gösterilmiştir.

Çizelge 5.2. Apne tahmini için sınıflandırma sonuçları

Sınıflandırıcı	Doğruluk (%)
Support Vector Machine	86,6
Artificial Neural Network	95,2
Decision Tree	84,1
K Nearest Neighborhood	86,3
Logistic Regression	81,4
Naive Bayes	81,5

Yukarıdaki Çizelge 5.2’den anlaşılacağı gibi bir epokta meydana gelme ihtimali olan apneler henüz meydana gelmeden bir önceki epoktaki verilerle %95,2 oranında doğru tahmin edilebilmiştir. Bu sonuç, apneleri önceden tahmin ederek hastalara terapi uygulayabilecek bir sistem ortaya çıkarılabileceğini göstermiştir.

5.1.3. Gerçek zamanlı öğrenen adaptif sistemin geliştirilmesi

Yukarıdaki sonuçlar doğrultusunda, ilk önce başlangıç verileri ile ilk eğitimini %95,2 doğrulukla tamamlayan ve sonrasında hastadan aldığı yeni fizyolojik sinyal verileri ile gerçek zamanlı olarak öğrenen bir sistem geliştirilmiştir. Geliştirilen bu sistem belirli periyotta öğrenme faaliyetini yenileyerek sınıflandırma başarısını kontrol etmektedir. Sınıflandırma başarısını daha yukarılara çıkarmak için adaptif bir yapıda çalışmaktadır. Geliştirilen zeki ve adaptif sistem tasarımı belirli bir periyotta sürekli olarak şu işlemleri gerçekleştirmektedir.

- Hastadan yeni verilerin alınması.
- Alınan ham fizyolojik sinyal verilerinin ön işlemeden geçirilmesi.
- Bu sinyallerden özellikler çıkarılması.
- Çıkarılan sinyal özellikleri ile YSA’nın, apne tahmin çıkışını (0-1) üretmesi.
- Performansa göre gerekirse ağı yeniden eğitilerek ağ parametreleri güncellenmesi.

5.1.4. Pozitif hava basıncının belirlenmesi

Başlangıçta %95,2 doğruluk oranı ile apne tahmini yapabilen sistem, gerçek zamanlı öğrenen ve adaptif olarak çalışarak apne tahmini yapmayı sürdürmektedir. Yukarıda da belirtildiği gibi sistem çıktısı apne riski yok (0) ya da apne riski var (1) şeklindedir. Tez kapsamında fiziki olarak yeni nesil bir PAP cihazı geliştirildiğinden

dolayı cihazın hastaya ileteceği pozitif hava basıncı da apne riskini ortadan kaldıracak bir algoritma ile belirlenmiştir. Bu algoritmanın akış diyagramı Şekil 4.30’da gösterilmiştir. Bu algoritma hazırlanırken prensip olarak apne riski ortadan kalkıncaya kadar belirli bir adım miktarı kadar hava basıncının artırılması sağlanmıştır. Bu artış uzman hekim tarafından reçete edilecek maksimum basınç değeri ile sınırlandırılmaktadır. Cihaz apne riski ortadan kalktığı anda ise hava basıncını yine uzman hekim tarafından reçete edilecek minimum değere düşürmektedir. Tez çalışması kapsamında yapılan simülasyon sonuçları Çizelge 4.22 ve Şekil 4.31’de gösterilmiştir.

5.1.5. Cihaz prototipinin oluşturulması

Tez çalışması kapsamında yapay zekâ tabanlı yeni nesil bir PAP cihazı geliştirilmiştir. Geliştirilen cihaz çalışma mantığı olarak bir APAP (otomatik CPAP) gibi çalışmaktadır. Ancak, klasik APAP cihazları hastanın hava yolunda meydana gelmiş apneleri algılayarak tıkanıklığı açma amacıyla hava basıncını ayarlarken, tez kapsamında geliştirilen cihaz, apneleri oluşmadan önce öngörebilen ve apne riskini ortadan kaldırma amacıyla terapi uygulayan bir cihazdır. Apne oluşmadan ortadan kaldırmak, hastalara uyku konforu açısından çok büyük bir rahatlık sağlamaktadır.

Cihaz üzerinde hastadan uyku sırasında anlık olarak fizyolojik veri toplama amacıyla 3 adet sensör bulunmaktadır. Bu sensörler tez çalışması süresince yapılan çalışmalarda sistemin giriş sinyalleri olarak belirlenmiş olan Pressure Flow, Pressure Snore ve Thorax sinyallerini toplayan sensörlerdir. Geliştirilen cihaz gerçek zamanlı makine öğrenmesi yöntemi ile hastayı ve uyku davranışlarını sürekli öğrenebilmektedir. Böylece kişisel terapi uygulayabilen bir cihaz ortaya çıkarılmıştır. Cihaza ait görseller Şekil 4.32 ve Şekil 4.33’te gösterilmiştir.

5.2. Öneriler

Bu çalışmada yeni nesil PAP cihazlarında yapay zekâ yöntemlerinin kullanılması gerektiği gerçeğinden hareketle PAP cihazları için yeni bir yaklaşım ortaya koyulmuştur. Ortaya koyulan bu yaklaşımın yeni nesil PAP cihazlarının geliştirilmesinde önemli bir rol oynayacağı düşünülmektedir. Bu yeni yaklaşımla geliştirilen ve gerçek zamanlı makine öğrenmesi sayesinde kişisel terapi uygulayabilen yeni nesil PAP cihazlarının yaygınlaşması ile hastanelerin uyku servislerinde ikinci gün uygulamalarına gerek

kalmayacak ve iş yükü önemli ölçüde azalacaktır. Buna ilaveten, bu çalışma sayesinde, PAP cihazlarının asıl amacının apneleri tespit etmek değil apneleri ortaya çıkmadan önce tahmin edip apneleri önlemek olması gerektiği ve bunun mümkün olduğu görülmüştür.

Bu çalışmada tıkalı uyku apnelerinin oluşmadan önce tahmin edilmesi ve önlenmesi için yeni nesil adaptif bir cihaz tasarımı gerçekleştirilmiştir. Bir başka çalışmada bu çalışmadaki yöntemler referans alınarak, uykuda solunum bozukluğunun diğer tiplerinin önlenmesi üzerine de çalışmalar yapılarak farklı tiplerde yapay zekâ tabanlı yeni nesil uyku cihazlarının geliştirilmesi sağlanabilir.

Yeni uyku cihazlarının geliştirilmesi için yapılacak tüm çalışmalarda otomatik kontrol yöntemlerinin yanı sıra YZ yöntemlerinin de mutlaka kullanılması önerilmektedir. Tıp elektroniği alanında yapılan tüm çalışmalarda olduğu gibi uyku cihazlarında da artık tedavi edici yöntemler yerine önleyici terapi yöntemlerinin geliştirilmesi daha uygun olabilir. Bu amaca uygun olarak, gelecek çalışmalarda, apnelerin önlenmesine yönelik birçok farklı YZ tekniği kullanan benzer çalışmalar yapılarak bu yöntemler arasında karşılaştırmalar yapılabilir. Buna ilaveten, biyomedikal sinyaller durağan olmayan sinyaller olduğu için bu sinyallerden online olarak çok fazla miktarda veri elde edilebilir. Elde edilen çok fazla veriye dayanarak büyük verilerle çalışabilen ve derin öğrenme yöntemlerini kullanan farklı bir çalışma yapılması da gelecek çalışma konularından biri olabilir. Bu çalışmada yapamadığımız ama daha sonraki zamanlarda üzerinde çalışmayı düşündüğümüz hususlardan biri de derin öğrenme yaklaşımlarının apne tahmini prensibine göre çalışan PAP cihazlarında kullanılmasıdır.

KAYNAKLAR

- Akdeniz, F., 2012, Obstrüktif Uyku Apne Sendromu Hastalarında Pozitif Hava Yolu Basıncı (Cpap) Tedavisi Öncesi ve Sonrasında Otonomik Fonksiyonların Değerlendirilmesi, Tıpta Uzmanlık Tezi, *Cumhuriyet Üniversitesi Tıp Fakültesi*, Sivas, Türkiye.
- Al-Ani, T., Novak, D., Hamam, Y., Ozzo, P., Lhotska, L., Lofaso, F., Isabey, D. ve Redouane, F., 2005, Noninvasive Automatic Sleep Apnea Noninvasive Automatic Sleep Apnea Classification System Classification System, *BioMedSim'05*, Linköping, Sweden, 45-55.
- Al-Mardini, M., Aloul, F., Sagahyroon, A. ve Al-Husseini, L., 2014, Classifying Obstructive Sleep Apnea Using Smartphones, *Journal of Biomedical Informatics*, 52, 251-259.
- Almas, A. M., 2001, Computerized Detection of Sleep Apnea Using Fuzzy Logic, Yüksek Lisans Tezi, *The University of Texas at Arlington*, Texas, USA.
- Alpaydın, E., 2010, Introduction to Machine Learning. Second Edition. London, England, *The MIT Press Cambridge*, Massachusetts, USA.
- American Academy of Sleep Medicine, 2012, The AASM Manual for the Scoring of Sleep and Associated Events The 2007 AASM Scoring Manual vs. the AASM Scoring Manual v2.0, *AASM v2.0*, USA, 10-11.
- American Academy of Sleep Medicine, 2014, The AASM Manual for the Scoring of Sleep and Associated Events Summary of Updates in Version 2.1, *AASM v2.1*, USA, 1-8.
- Arauzo-Azofra, A., Benitez, J. M. ve Castro, J. L., 2004, A Feature Set Measure Based on Relief, *Proceedings of the 5th International Conference on Recent Advances in Soft Computing*, Nottingham, United Kingdom, 104-109.
- Arı, N., Özen, Ş., ve Çolak, Ö. H., 2008, Wavelet Theory, *Palme Yayıncılık*, Ankara, Türkiye.
- Arslan Tuncer, S., Akılotu, B. ve Toraman, S., 2019, A Deep Learning-Based Decision Support System for Diagnosis of OSAS Using PTT Signals. *Medical Hypotheses*, 127, 15-22.
- Ataman, G., 2009, İşletme Yönetimi; Temel Kavramlar ve Yeni Yaklaşımlar, *Türkmen Kitabevi*, İstanbul, Türkiye.
- Atan, D., Özcan, K. M., Yurtsever Kum, N. ve Dere, H., 2017, The Effect of Obstructive Sleep Apne Syndrome and Continuous Positive Airway Pressure Titration on Stage 3 and REM Sleeps, *The Turkish Journal of Ear Nose and Throat*, 27(3), 141-45.

- Bock, J. ve Gough, D. A., 1998, Toward Prediction of Physiological State Signals in Sleep Apnea, *IEEE Transactions on Biomedical Engineering*, 45(11), 1332-1341.
- Bozkurt, F., Uçar, M. K., Bozkurt, M. R. ve Bilgin, C., 2020, Detection of Abnormal Respiratory Events with Single Channel ECG and Hybrid Machine Learning Model in Patients with Obstructive Sleep Apnea, *IRBM*, 41(5), 241-251.
- Bozkurt, M. R., 2007, Preprocessing and Classification of EMG Signals with Modern Methods, Doktora Tezi, *Sakarya University Institute of Science and Technology*, Sakarya, Türkiye.
- Buendía-Fuentes, F., Arnau-Vives, M. A., Arnau-Vives, A., Jiménez-Jiménez, Y., Rueda-Soriano, J., Zorio-Grima, E., Osa-Sáez, A., Martínez-Dolz, L. V., Almenar-Bonet, L. ve Palencia-Pérez, M. A., 2012, High-Bandpass Filters in Electrocardiography: Source of Error in the Interpretation of the ST Segment, *ISRN Cardiology*, 2012, 1-10
- Choi, S. H., Yoon, H., Kim, H. S., Kim, H. B., Kwon, H. B., Oh, S. M., Lee, Y. J. ve Park, K. S., 2018, Real-Time Apnea-Hypopnea Event Detection during Sleep by Convolutional Neural Networks, *Computers in Biology and Medicine*, 100, 123-131.
- Cohen, G. ve de Chazal, P., 2015, Automated Detection of Sleep Apnea in Infants: A Multi-Modal Approach, *Computers in Biology and Medicine*, 63, 118-123.
- Cooksey, J. A., ve Balachandran, J. S., 2016, Portable Monitoring for the Diagnosis of OSA, *Chest*, 149(4), 1074-1081.
- Dafna, E., Tarasiuk, A. ve Zigel Y., 2013, OSA Severity Assessment Based on Sleep Breathing Analysis Using Ambient Microphone, *35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Osaka, Japan, 2044-2047.
- Dagum, P. ve Galper, A., 1995, Time Series Prediction Using Belief Network Models, *International Journal of Human-Computer Studies*, 42(6), 617-632.
- Das, D. M., Gupta, A., Srivastava, A., Vidwans, A., Ahmad, M., Shelke, A., Kale, S., Ananthapadmanabhan, J., Sharma, D. K. Ve Baghini, M. S., 2018, A Pulse Oximeter System, OxiSense , with Embedded Signal Processing Using an Ultra-Low Power ASIC Designed for Testability, *Microelectronics Journal*, 72, 1-10.
- De la Fuente, C., Weinstein, A., Guzman-Venegas, R., Arenas, J., Cartes, J., Soto, M. ve Carpes, F. P., 2019, Use of Accelerometers for Automatic Regional Chest Movement Recognition during Tidal Breathing in Healthy Subjects, *Journal of Electromyography and Kinesiology*, 47, 105-112.
- del Campo, F., Hornero, R., Zamarrón, C., Abasolo, D.E. ve Álvarez, D., 2006, Oxygen Saturation Regularity Analysis in the Diagnosis of Obstructive Sleep Apnea, *Artificial Intelligence in Medicine*, 37(2), 111-118.

- Demirhan, A., Kılıç, Y. A. ve Güler, İ., 2010, Tıpta Yapay Zeka Uygulamaları, *Yoğun Bakım Dergisi*, 9(1), 31-41.
- Díaz, J. A., Arancibia, J. M., Bassi, A. ve Vivaldi, E. A., 2014, Envelope Analysis of the Airflow Signal To Improve Polysomnographic Assessment of Sleep Disordered Breathing, *Sleep*, 37(1), 199-208.
- Doğan, B. ve Ölmez, T., 2016, Solunum Sesleri Yardımıyla Uyku Apnesi Tespit Edilmesi, *Tıp Teknolojileri Kongresi-TIPTEKNO'16*, Antalya, Türkiye, 30-33.
- Douglas, N. J., Thomas, S. ve Jan, M. A., 1992, Clinical Value of Polysomnography, *The Lancet*, 339(8789), 347-350.
- Elwali, A. ve Moussavi, Z., 2017, Obstructive Sleep Apnea Screening and Airway Structure Characterization During Wakefulness Using Tracheal Breathing Sounds, *Annals of Biomedical Engineering*, 45(3), 839-850.
- Erazo, L., ve Ríos, S. A., 2014., A Benchmark on Automatic Obstructive Sleep Apnea Screening Algorithms in Children, *Procedia Computer Science*, 35, 739-746.
- Ferrari, S. ve Stengel, R. F., 2005, Smooth Function Approximation Using Neural Networks, *IEEE Transactions on Neural Networks*, 16(1), 24-38.
- Fırat, H., 2016, PAP Treatment and Device Selection in OSAS, *Güncel Göğüs Hastalıkları Serisi*, 2(2), 184-191.
- Fontenla-Romero, O., Guijarro-Berdiñas, B., Alonso-Betanzos, A. ve Moret-Bonillo, V., 2005, A New Method for Sleep Apnea Classification Using Wavelets and Feedforward Neural Networks, *Artificial Intelligence in Medicine*, 34(1), 65-76.
- Freedman, N., 2010, Treatment of Obstructive Sleep Apnea Syndrome, *Clinics in Chest Medicine*, 31(2), 187-201.
- Gay, P., Weaver, T., Loube, D. ve Iber, C., 2006, Evaluation of Positive Airway Pressure Treatment for Sleep Related Breathing Disorders in Adults, *Sleep*, 29(3), 381-401.
- Guang-Bin, H., 2003, Learning Capability and Storage Capacity of Two-Hidden-Layer Feedforward Networks, *IEEE Transactions on Neural Networks*, 14(2), 274-281.
- Guang-Bin, H., ve Babri, H. A., 1998, Upper Bounds on the Number of Hidden Neurons in Feedforward Networks with Arbitrary Bounded Nonlinear Activation Functions, *IEEE Transactions on Neural Networks*, 9(1), 224-229.
- Guang-Bin, H., Yan-Qiu, C. ve Babri, H. A., 2000, Classification Ability of Single Hidden Layer Feedforward Neural Networks, *IEEE Transactions on Neural Networks*, 11(3), 799-801.
- Gupta, G. P., Nair, R. R. ve Jeyanthi, R., 2017, An ANN Based SpO2 Measurement for Clinical Management Systems, *Energy Procedia*, 117, 393-400.

- Hassan, A. R. ve Haque, M. A., 2016, Computer-Aided Obstructive Sleep Apnea Screening from Single-Lead Electrocardiogram Using Statistical and Spectral Features and Bootstrap Aggregating, *Biocybernetics and Biomedical Engineering*, 36(1), 256-266.
- Huang, G. B., Zhu, Q. ve Siew, C. K., 2006, Real-Time Learning Capability of Neural Networks, *IEEE Transactions on Neural Networks*, 17(4), 863-878.
- Huang, W., Guo, B., Shen, Y. ve Tang, X., 2017, A Novel Method to Precisely Detect Apnea and Hypopnea Events by Airflow and Oximetry Signals, *Computers in Biology and Medicine*, 88, 32-40.
- Hyo-Ki, L., Jeon L., Hojoong K. ve Kyoung-Joung, L., 2013, Automatic Snoring Detection from Nasal Pressure Data, *35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Osaka, Japan, 6870-6872.
- Johnson, K. G. ve Rapoport, D. M., 2017, Future of Positive Airway Pressure Technology, *Sleep Medicine Clinics*, 12(4), 617-622.
- Kıymık, M. K., Subaşı, A., Dizibüyük, A. ve Özer, M., 2002, Darbeli Dopler Laminar Kan Akış Sinyal Simülasyonuna STFT ve AR Spektral Analizlerinin Uygulanması, *KSÜ Fen ve Mühendislik Dergisi*, 5(2), 14-27.
- Kira, K. ve Rendell, L. A., 1992, A Practical Approach to Feature Selection, *Machine Learning Proceedings 1992*, Peter Edwards, Derek Sleeman, *Elsevier*, USA, 249-256.
- Kira, K. ve Rendell, L. A., 1992, The Feature Selection Problem: Traditional Methods and a New Algorithm, *Association for the Advancement of Artificial Intelligence (AAAI)*, San Jose, California, USA, 129-134.
- Koçyiğit, Y., Karlık, B. ve Fidan, C. B., 2005, EMG İşaretlerini Sınıflamada Kullanılan İşaret İşleme Tekniklerinin Karşılaştırılması, *13. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU'05)*, Kayseri, Türkiye.
- Koçyiğit, Y., ve Korürek, M., 2005, EMG Signal Classification Using Wavelet Transform and Fuzzy Logic Classifier, *ITU Journal Series D: Engineering*, 4(3), 25-31.
- Kononenko, I., 1994, Estimating Attributes: Analysis and Extensions of RELIEF, *European Conference on Machine Learning Machine Learning: ECML-94*, Catania, Italy, 171-182.
- Kushida, C. A., Littner, M. R., Hirshkowitz, M., Morgenthaler, T. I., Alessi, C. A., Bailey, D., Boehlecke, B., Brown, T. M., Coleman, J., Friedman, L., Kapen, S., Kapur, V. K., Kramer, M., Lee-Chiong, T., Owens, J., Pancer, J. P., Swick, T. J. ve Wise, M. S., 2006, Practice Parameters for the Use of Continuous and Bilevel Positive Airway Pressure Devices to Treat Adult Patients With Sleep-Related Breathing Disorders, *Sleep*, 29(3), 375-380.

- Landau, I. D., Lozano, R., M'Saad, M. ve Karimi, A., 2011, Introduction to Adaptive Control Communications and Control Engineering, *Springer-Verlag London Limited*, London, England, 1-33.
- Lee, J. H., Park H. J., ve Kim, Y. N., 2015, Monitoring Obstructive Sleep Apnea with Electrocardiography and 3-Axis Acceleration Sensor, *8th ACM International Conference on Pervasive Technologies Related to Assistive Environments*, New York, USA.
- Li, K., Pan W., Li, Y., Jiang Q. Liu G., 2018, A Method to Detect Sleep Apnea Based on Deep Neural Network and Hidden Markov Model Using Single-Lead ECG Signal, *Neurocomputing*, 294, 94-101.
- Lin, X., Cheng, H., Lu, Y., Luo, H., Li, H., Qian, Y., Zhou, L., Zhang, L. ve Wang, M., 2022, Contactless Sleep Apnea Detection in Snoring Signals Using Hybrid Deep Neural Networks Targeted for Embedded Hardware Platform with Real-Time Applications, *Biomedical Signal Processing and Control*, 77, 103765.
- Littner, M., Hirshkowitz, M., Davila, D., Anderson, W. M., Kushida, C. A., Woodson, B. T., Johnson, S. F. ve Wise, M. S., 2002, Practice Parameters for the Use of Auto-Titrating Continuous Positive Airway Pressure Devices for Titrating Pressures and Treating Adult Patients with Obstructive Sleep Apnea Syndrome, *Sleep*, 25(2), 143-147.
- Maali, Y., ve Al-Jumaily, A., 2013, Multi Neural Networks Investigation Based Sleep Apnea Prediction, *Procedia Computer Science*, 24, 97-102.
- Magalang, U. J., Dmochowski, J., Veeramachaneni, S., Draw, A., Mador, M. J., El-Solh, A. ve Grant, B. J. B., 2003, Prediction of the Apnea-Hypopnea Index From Overnight Pulse Oximetry*, *Chest*, 124(5), 1694-1701.
- Mahmoud, S. S., Hussain Z. M., Cosic I ve Fang, Q., 2006, Time-Frequency Analysis of Normal and Abnormal Biological Signals, *Biomedical Signal Processing and Control*, 1(1), 33-43.
- Malkoff, D. B., 1989, A Neural Network for Real-Time Signal Processing, *2nd International Conference on Neural Information Processing Systems, NIPS'89*, USA, 248-255.
- Marcos, J. V., Hornero, R., Álvarez, D., Aboy, M. ve Del Campo, F., 2012, Automated Prediction of the Apnea-Hypopnea Index from Nocturnal Oximetry Recordings, *IEEE Transactions on Biomedical Engineering*, 59(1), 141-149.
- Miner, N.E., 1998, An Introduction to Wavelet Theory and Analysis, *Sandia National Laboratories (SNL) SAND98-2265 ON: DE00001896* , USA,
- Molin, N. L., Molin, C., Dalpatadu, R. J. ve Singh, A. K., 2021, Prediction of Obstructive Sleep Apnea Using Fast Fourier Transform of Overnight Breath Recordings, *Machine Learning with Applications*, 4, 100022.

- Nandakumar, R., Gollakota, S. ve Watson, N., 2015, Contactless Sleep Apnea Detection on Smartphones, *3th Annual International Conference on Mobile Systems, Applications, and Services*, New York, USA, 45-57.
- Nazeran, H., Almas, A., Behbehani, K., Burk, J. ve Lucas, E., 2001, A Fuzzy Inference System for Detection of Obstructive Sleep Apnea, *2001 Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, İstanbul, Türkiye, 1645-1648.
- Ondráček, O., Púčik, J. ve Cocherová, E., 2005, Filters for ECG Digital Signal Processing, *International Conference "Trends in Biomedical Engineering"*, Žilina, Slovak Republic, 91-96.
- Oppenheim, A. V., 1989, Signals and Systems (Prentice-Hall Signal Processing Series), *Prentice Hall*, New Jersey, USA.
- Öter, A., Aydoğan, O., Kıymık, M. K. ve Tuncel, D., 2016, Tıkayıcı Uyku Apnesinin Yapay Sinir Ağları ve Morfolojik Filtreler Kullanılarak Sınıflandırılması İçin Yeni Yöntem, *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 19(2), 52.
- Özmen, G., 2013, Servikal Bölgede Oluşan Kas Yorgunluğunun Yüzey Elektromiyogram Bilgileri İle Değerlendirilmesi, Yüksek Lisans Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, Türkiye.
- Özmen, G., 2019, Biyomedikal Sinyal İşleme Ders Notu, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, Türkiye
- Öztemel, E., 2012. Yapay Sinir Ağları, Rıfat Çölkesen, *Papatya Yayıncılık Eğitim*, İstanbul, Türkiye.
- Parola, F. ve Garcia-Niebla, J., 2017, Use of High-Pass and Low-Pass Electrocardiographic Filters in an International Cardiologial Community and Possible Clinical Effects, *Advanced Journal of Vascular Medicine*, 2(1), 34-38.
- Pinho, A., Pombo, N., Silva, B. M. C., Bousson, K. ve Garcia, N., 2019, Towards an Accurate Sleep Apnea Detection Based on ECG Signal: The Quintessential of a Wise Feature Selection, *Applied Soft Computing*, 83, 105568.
- Polat, K., Yosunkaya, Ş. ve Güneş, S., 2008, A New Approach to Diagnosing of Importance Degree of Obstructive Sleep Apnea Syndrome: Pairwise AIRS and Fuzzy-AIRS Classifiers, *Journal of Medical Systems*, 32(6), 489-497.
- Proakis, L.G. ve Manolakis, D. G., 2010, Digital Signal Processing, Özgül Salor, *Nobel Yayın*, Ankara, Türkiye.
- Reddy, E. V., Kadiravan, T., Mishra, H. K., Sreenivas, V., Handa, K. K., Sinha, S. ve Sharma, S. K., 2009, Prevalence and Risk Factors of Obstructive Sleep Apnea among Middle-Aged Urban Indians: A Community-Based Study, *Sleep Medicine*, 10(8), 913-918.

- Reeves-Hoché, M. K., Hudgel, D. W., Meck, R., Witteman, R., Ross, A. ve Zwillich, C. W., 1995, Continuous versus Bilevel Positive Airway Pressure for Obstructive Sleep Apnea, *American Journal of Respiratory and Critical Care Medicine*, 151(2), 443-449.
- Resta, O., Guido, P., Picca, V., Sabato, R., Rizzi, M., Scarpelli, F. ve Sergi, M., 1998, Prescription of NCPAP and NBIPAP in Obstructive Sleep Apnoea Syndrome: Italian Experience in 105 Subjects. A Prospective Two Centre Study, *Respiratory Medicine*, 92(6), 820-827.
- Rolón, R. E., Larrateguy, L. D., Di Persia, L. E., Spies, R. D. ve Rufiner, H. L., 2017, Discriminative Methods Based on Sparse Representations of Pulse Oximetry Signals for Sleep Apnea–Hypopnea Detection, *Biomedical Signal Processing and Control*, 33, 358-367.
- Samy, L., Macey, P. M., Alshurafa, N. ve Sarrafzadeh, M., 2015, An Automated Framework for Predicting Obstructive Sleep Apnea Using a Brief, Daytime, Non-Intrusive Test Procedure, *8th ACM International Conference on Pervasive Technologies Related to Assistive Environments*, New York, USA, 1-8.
- Schäfer, H., Ewig, S., Hasper, E. ve Lüderitz, B., 1998, Failure of CPAP Therapy in Obstructive Sleep Apnoea Syndrome: Predictive Factors and Treatment with Bilevel-Positive Airway Pressure, *Respiratory Medicine*, 92(2), 208-215.
- Semmlow, J. L., 2004, Biosignal and Biomedical Image Processing: MATLAB-Based Applications, *Marcel Dekker*, New York, USA.
- Senaratna, C. V., Perret, J. L., Lodge, C. J., Lowe, A. J., Campbell, B. E., Matheson, M. C., Hamilton, G. S. ve Dharmage, S. C., 2017, Prevalence of Obstructive Sleep Apnea in the General Population: A Systematic Review, *Sleep Medicine Reviews*, 34, 70-81.
- Sharma, M., Bapodara, S., Tiwari, J. ve Acharya, U. R., 2022, Automated Sleep Apnea Detection in Pregnant Women Using Wavelet-Based Features, *Informatics in Medicine Unlocked*, 32, 101026.
- Shin, J. J. W., Berry, R. B. ve Khoo, M. C. K., 1998, Fuzzy Assessment of Sleep-Disordered Breathing During Continuous Positive Airway Pressure Therapy, *Sleep*, 21(8), 817-828.
- Song, S., Jiang, F., Hao, L., Xu, L., Yi, X., Li, G. ve Lin, L., 2018, Use of Bi-Level Pulsed Frequency-Division Excitation for Improving Blood Oxygen Saturation Precision, *Measurement*, 129, 523-529.
- Strollo, P. J., Sanders, M. H. ve Atwood, C. W., 1998, Positive Pressure Therapy, *Clinics in Chest Medicine*, 19(1), 55-68.
- Subasi, A., 2019, Practical Guide for Biomedical Signals Analysis Using Machine Learning Techniques: A MATLAB Based Approach. *Elsevier-Academic Press*, USA.

- Tagluk, M. E., ve Sezgin, N., 2011, A New Approach for Estimation of Obstructive Sleep Apnea Syndrome, *Expert Systems with Applications*, 38(5), 5346-5351.
- Teschler, H., Berthon-Jones, M., Thompson, A. B., Henkel, A., Henry, J. ve Konietzko, N., 1996, Automated Continuous Positive Airway Pressure Titration for Obstructive Sleep Apnea Syndrome, *American Journal of Respiratory and Critical Care Medicine*, 154(3), 734-740.
- Tsouti, V., Kanaris, A. I., Tsoutis, K. ve Chatzandroulis, S., 2020, Development of an Automated System for Obstructive Sleep Apnea Treatment Based on Machine Learning and Breath Effort Monitoring, *Microelectronic Engineering*, 231, 111376.
- Türk Toraks Derneği, 2012, Türk Toraks Derneği Obstrüktif Uyku Apne Sendromu Tanı ve Tedavi Uzlaş Raporu-Pap Tedavisi, 13, Ankara, Türkiye, 41-43.
- Türkoğlu, İ., 2002, Durağan Olmayan İşaretler İçin Zaman-Frekans Entropilerine Dayalı Akıllı Örüntü Tanıma, Doktora Tezi, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Elazığ, Türkiye.
- Urbanowicz, R. J., Meeker, M. La Cava, W., Olson, R. S. ve Moore, J. H., 2018, Relief-Based Feature Selection: Introduction and Review, *Journal of Biomedical Informatics*, 85, 189-203.
- Ursavaş, A. ve Ege, E., 2004, Sleep Apnea Syndrome and Traffic Accidents, *Journal of Uludağ University Medical Faculty*, 30(1), 37-41
- Varon, C., Caicedo, A., Testelmans, D., Buyse, B. ve Van Huffel, S., 2015, A Novel Algorithm for the Automatic Detection of Sleep Apnea From Single-Lead ECG, *IEEE Transactions on Biomedical Engineering*, 62(9), 2269-2278.
- Vetterli, M. ve Kovačević, J., 1995, Wavelets and Subband Coding. *Prentice Hall*, New Jersey, ABD.
- Wang, Z., Peng, C., Li, B., Penzel, T., Liu, R., Zhang, Y. ve Yu, X., 2022, Single-Lead ECG Based Multiscale Neural Network for Obstructive Sleep Apnea Detection, *Internet of Things*, 20, 100613.
- Watson, N. F. ve Fernandez, C. R., 2021, Artificial Intelligence and Sleep: Advancing Sleep Medicine, *Sleep Medicine Reviews*, 59, 101512.
- Waxman, J. A., Graupe, D. ve Carley, D. W., 2010, Automated Prediction of Apnea and Hypopnea, Using a LAMSTAR Artificial Neural Network, *American Journal of Respiratory and Critical Care Medicine*, 181(7), 727-733.
- Xiang, C., Ding, S. ve Lee, T. H., 2005, Geometrical Interpretation and Architecture Selection of MLP, *IEEE Transactions on Neural Networks*, 16(1), 84-96.
- Xu, T., Li, T., Wei, D., Feng, Y., Xian, L., Wu, H. ve Xu, J., 2012, Effect of Automatic versus Fixed Continuous Positive Airway Pressure for the Treatment of Obstructive Sleep Apnea: An up-to-Date Meta-Analysis, *Sleep and Breathing*, 16(4), 1017-1026.

- Yu, H., Liu, D., Zhao, J., Chen, Z., Gou, C., Huang, X., Sun, J. ve Zhao, X., 2022, A Sleep Apnea-Hypopnea Syndrome Automatic Detection and Subtype Classification Method Based on LSTM-CNN, *Biomedical Signal Processing and Control*, 71, 103240.
- Yurtoğlu, H., 2005, Yapay Sinir Ağları Metodolojisi Ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği, Uzmanlık Tezi, *Devlet Planlama Teşkilatı Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü*, Ankara, Türkiye.
- Zhuang, Z., Wang, F., Yang, X., Zhang, L., Fu, C. H., Xu, J., Li, C. ve Hong, H., 2022, Accurate Contactless Sleep Apnea Detection Framework with Signal Processing and Machine Learning Methods, *Methods*, 205, 167-178.
- Zoroğlu, C., 2015, Bulanık Uzman Sistem Kullanarak Tıkalıcı Uyku Apne Hipopne Sendromunun Ciddiyet Seviyesinin Tahmini, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, Türkiye.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Mehmet Balcı
Uyruğu : Türkiye Cumhuriyeti

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Alanya İmam Hatip Lisesi	1999
Üniversite	: Selçuk Üniversitesi Teknik Eğitim Fakültesi Bilgisayar Sistemleri Öğretmenliği	2006
Yüksek Lisans	: Selçuk Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Bilgisayar Sistemleri Eğitimi	2010
Doktora	: Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği	2022

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2006-2009	Seydişehir Anadolu Ticaret Meslek Lisesi	Teknik Öğretmen
2009-2013	Karamanoğlu Mehmetbey Üniversitesi	Öğretim Görevlisi
2013-2018	Selçuk Üniversitesi	Öğretim Görevlisi
2018-	Konya Teknik Üniversitesi	Öğretim Görevlisi

UZMANLIK ALANI

Yapay Zekâ
 Makine Öğrenmesi
 Biyomedikal Sinyal İşleme
 Tıpta Yapay Zekâ Uygulamaları

YABANCI DİLLER

İngilizce

YAYINLAR

Uluslararası hakemli dergilerde yayımlanan makaleler:

- Balcı Mehmet, Taşdemir Şakir, Gölcük Adem (2022). Real-Time Learning and Adaptive System Design For The Prevention of Apneas, Computer Methods in Biomechanics and Biomedical Engineering. (Revizon yapıldı, makale hakem değerlendirmesinde)

2 Balcı Mehmet, Taşdemir Şakir, Gölcük Adem (2022). Determining the Most Appropriate Parameters to Predict the Attacks of Obstructive Sleep Apnea by PAP Devices Through Signal Processing and Machine Learning Algorithms, Medical & Biological Engineering & Computing. (Makale hakem değerlendirmesinde)

3 Balcı Mehmet, Taşdemir Şakir, Özmen Güzin, Gölcük Adem (2022). Machine Learning-Based Detection of Sleep-Disordered Breathing Type Using Time and Time-Frequency Features. Biomedical Signal Processing and Control, 73, 1-10., Doi: 10.1016/j.bspc.2021.103402 (Yayın No: 7309750)

4 Balcı Mehmet, Gölcük Adem, Küçüktürk Serkan, Taşdemir Şakir, Vatansev Hüsamettin, Vatansev Hülya (2021). Wavelet Dalgacık Dönüşümü ile Tıkayıcı Uyku Apnesi Tahmini ve Epok Sürelerinin Etkisi. European Journal of Science and Technology(26), 276-283., Doi: 10.31590/ejosat.954003 (Yayın No: 7309701)

5 Gölcük Adem, Balcı Mehmet, Taşdemir Şakir, Küçüktürk Serkan, Vatansev Hüsamettin, Vatansev Hülya (2022). Designing a System that Records the Sleeping Position Data of Sleep Apnea Patients. Gazi Journal of Engineering Sciences, 8, 130-134., Doi: 10.30855/gmbd.2022.01.12 (Kontrol No: 7698269)

Uluslararası bilimsel toplantılarda sunulan ve bildiri kitaplarında (proceedings) basılan bildiriler:

1 Gölcük Adem, Balcı Mehmet, Taşdemir Şakir, Küçüktürk Serkan, Vatansev Hüsamettin, Vatansev Hülya (2021). Designing a system that records the sleeping position data of sleep apnea patients. ICENTE'21 5th International Conference on Engineering Technologies, 1, 12-12. (Özet Bildiri/Sözlü Sunum) (Yayın No:7309810)

2 Balcı Mehmet, Gölcük Adem, Küçüktürk Serkan, Taşdemir Şakir, Vatansev Hüsamettin, Vatansev Hülya (2021). Wavelet Dalgacık Dönüşümü ile Tıkayıcı Uyku Apnesi Tahmini ve Epok Sürelerinin Etkisi. HORA 2021 3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications, 1(1), 1-1. (Özet Bildiri/Sözlü Sunum) (Yayın No:7309785)