



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**OSAS HASTALARI İÇİN CPAP
CİHAZLARINDAKİ OPTİMUM BASINCIN
YAPAY ZEKA İLE TAHMİNİ**

Fatma Zehra GÖĞÜŞ

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Kasım-2020
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Fatma Zehra GÖĞÜŞ tarafından hazırlanan “OSAS HASTALARI İÇİN CPAP CİHAZLARINDAKİ OPTİMUM BASINCIN YAPAY ZEKA İLE TAHMİNİ” adlı tez çalışması 12/11/2020 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Sabri KOÇER

.....

Danışman

Prof. Dr. Gülay TEZEL

.....

Üye

Prof. Dr. Seral ÖZŞEN

.....

Üye

Dr. Öğr. Üyesi Ömer Kaan BAYKAN

.....

Üye

Dr. Öğr. Üyesi Ayşe Merve ACILAR

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

Bu tez çalışması TUBITAK tarafından 119E127 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.



Fatma Zehra GÖĞÜŞ

Tarih:12.11.2020

ÖZET

DOKTORA TEZİ

OSAS HASTALARI İÇİN CPAP CİHAZLARINDAKİ OPTİMUM BASINÇIN YAPAY ZEKA İLE TAHMİNİ

Fatma Zehra GÖĞÜŞ

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Gülay TEZEL

2020, 144 Sayfa

Jüri

Prof. Dr. Gülay TEZEL

Prof. Dr. Sabri KOÇER

Prof. Dr. Seral ÖZŞEN

Dr. Öğr. Üyesi Ömer Kaan BAYKAN

Dr. Öğr. Üyesi Ayşe Merve ACILAR

Tıkayıcı uyku apne sendromu (Obstructive Sleep Apnea Syndrome: OSAS), uyku sırasında tekrarlayan üst solunum yolu daralmaları veya tıkanmaları nedeniyle soluk kesilmeleri şeklinde kendini gösteren bir uyku bozukluğudur. Uykuda oluşan soluk kesilmeleri kişilerin uyku devamlılığını bozmakta, derin ve dinlendirici bir uyku uyumasını engellemekte ve bu sayede günlük yaşamlarını olumsuz bir şekilde etkilemektedir. Ayrıca soluk kesilmeleri sıklıkla kanda oksijen doygunluğunu azaltarak başta kalp damar hastalıkları olmak üzere birçok ciddi hastalığın ortaya çıkmasına neden olmakta ve hatta ölüme bile sebebiyet verebilmektedir. Tüm bu olumsuz etkilerin ortadan kaldırılabilmesi için OSAS teşhisi konulmuş hastalara etkili bir tedavinin uygulanması gerekmektedir. Sürekli Pozitif Havayolu Basınç (Continuous Positive Airway Pressure: CPAP) terapisi OSAS için altın standart tedavi yöntemidir. CPAP cihazları ile gerçekleştirilen bu tedavide, belirlenen sabit basınç ile hastaların üst solunum yolunun açık kalması sağlanmaktadır. Hastalar için tedavi edici en etkin basınç (optimum CPAP seviyesi) uyku uzmanları tarafından uyku laboratuvarlarında manuel titrasyon süreci ile belirlenir. Fakat bu süreç hem maliyetli ve zaman alıcı hem de oldukça yorucudur. Bu nedenle, optimum CPAP seviyesinin belirlenebilmesi amacıyla, titrasyona alternatif çözümler geliştirme yönünde literatürde çok sayıda çalışma yürütülmüştür. Çalışmaların büyük kısmı hastaya uygulanacak optimum CPAP seviyesinin doğrudan tahmini üzerinde durmuş ve tahmin için çoğunlukla benzer özellikler üzerine kurulmuş regresyon tabanlı formülleri alternatif çözümler olarak üretmişlerdir. Ancak günümüze kadar klinikte tam manasıyla kabul gören, uygulanabilir ve yüksek doğrulukta bir alternatif çözüm halen geliştirilememiştir.

Gerçekleştirilen bu tez çalışmasında, OSAS şüphesi ile Necmettin Erbakan Üniversitesi, Meram Tıp Fakültesi, Göğüs Hastalıkları Anabilim Dalı, Uyku Kliniğine başvuran kişiler arasından CPAP terapisi ile tedavi edilmesi gerekli görülenlerin optimum CPAP seviyeleri tahmin edilmiştir. Tahmin işlemi gerçekleştirilmeden önce Doğrusal Olmayan Analiz ve Kural Tabanlı Algoritma yaklaşımları ile polisomnografi sinyallerinden olan nazal kanül hava akımı ve oksimetri sinyalleri kullanılarak, tez çalışmasına dahil edilen kişilerin OSAS hastası olup olmadığı ve CPAP terapisi gerektirip gerektirmediği belirlenmiştir. Doğrusal Olmayan Analiz Yaklaşımı ile OSAS hastaları sağlıklı bireylerden %93.10 doğruluk, %96.43 duyarlılık ve %81.82 özgüllük değerleri ile ayırt edilmiş ve CPAP terapisi gerektiren hastalar %96.25 duyarlılık ve %89.53 kesinlik ile tespit edilebilmiştir. Kural Tabanlı Algoritma yaklaşımı ise OSAS hastalarını sağlıklı bireylerden %98.62 doğruluk, %98.21 duyarlılık ve %100 özgüllük ile ayırırken, CPAP terapisi gerektiren hastaları %100 duyarlılık ve %100 kesinlik ile belirleyebilmiştir. OSAS terapisi ile tedavi gerektiren hastaların belirlenmesinin ardından, bu hastaların demografik ve

antropometrik bilgileri, nazal kanül hava akımı ve oksimetri sinyalleri, gece boyunca geçirmiş olduğu apneik atakları ve oksijen azalmaları göz önünde bulundurularak farklı özellik setleri oluşturulmuştur. Daha sonra farklı özellik setlerindeki özellikler arasından optimum CPAP seviyeleri üzerinde en etkili olanların seçimi gerçekleştirilmiş ve hem tüm özelliklerin hem de etkin olarak seçilen özelliklerin doğrusal regresyon analizleri ve çeşitli yapay zeka yöntemleri ile kullanılmasıyla hastalara ait optimum CPAP seviyeleri tahmin edilmiştir. Son olarak yüksek tahmin performansının sağlandığı özellikler ve yöntemlerle (adım adım çoklu doğrusal regresyon analizi, yapay sinir ağları, destek vektör makinesi, rastgele orman ve k en yakın komşuluk) 40 farklı CPAP tahmin modeli geliştirilmiştir. Bu 40 CPAP tahmin modelinin 36 tanesi farklı yapay zeka yöntemleri ile elde edilirken, yalnızca 4 tanesi doğrusal regresyon analizi ile elde edilmiştir. Sonuç olarak, polinom veya radyal tabanlı çekirdek fonksiyonlarına sahip Destek Vektör Makineleri, yapay zeka yöntemleri ile geliştirilen 36 modelden 24'ünü oluşturarak tahmin işleminde en başarılı yöntem olmuştur. Geliştirilen 40 modelin 25'i tez çalışmasında tahmin edilen CPAP seviyeleri ile uzmanların uyku laboratuvarlarında belirlediği optimum CPAP seviyeleri arasında yüksek ilişki ($0.6 \leq r < 0.8$; $0.36 \leq r^2 < 0.64$) ortaya koymuş, 10'u ise bu ilişkiyi çok yüksek ($r \geq 0.8$; $r^2 \geq 0.64$) olarak tanımlamıştır.

Tez çalışmasında elde edilen tüm sonuçlar genel olarak değerlendirildiğinde, hava akımı ve oksimetri sinyallerine, OSAS hastalarının geçirmiş oldukları apneik ataklara ve ataklara bağlı olarak oluşan oksijen seviyelerindeki azalmalara ait özelliklerin optimum basınçlar üzerinde büyük etkileri olduğu görülmüştür. Ayrıca, bu tez çalışması, tahmin için kullanılan özellikler arasındaki doğrusal ve doğrusal olmayan ilişkilerin yapay zeka yöntemleri ile daha iyi açıkladığını ve bu sayede optimum CPAP seviyelerinin tahmini için literatürde çoğunlukla tercih edilen doğrusal regresyon analizlerine göre birçok yapay zeka yönteminin genellikle daha başarılı sonuçlar ürettiğini ortaya koymuştur. Tez çalışması geliştirilen yeni CPAP tahmin modellerini ve modellerde tahmin parametreleri olarak kullanılan yeni özellikleri literatüre kazandırmıştır.

Anahtar Kelimeler: CPAP Tahmin Modelleri, CPAP Terapisi, Nazal Kanül Hava Akımı Sinyali, Oksimetri Sinyali, OSAS, Özellik Çıkarma, Sinyal İşleme, Yapay Zeka

ABSTRACT

PhD THESIS

PREDICTION OF OPTIMUM PRESSURE IN CPAP DEVICES FOR OSAS PATIENTS BY ARTIFICIAL INTELLIGENCE

Fatma Zehra GÖĞÜŞ

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Prof. Dr. Gülay TEZEL

2020, 144 Pages

Jury

Prof. Dr. Gülay TEZEL

Prof. Dr. Sabri KOÇER

Prof. Dr. Seral ÖZŞEN

Asst. Prof. Dr. Ömer Kaan BAYKAN

Asst. Prof. Dr. Ayşe Merve ACILAR

Obstructive Sleep Apnea Syndrome (OSAS) is a sleep disorder that manifests itself as breathing breaks due to recurrent upper airway constrictions or obstructions during sleep. The breathing breaks during sleep disrupt the continuity of individuals' sleep, prevent deep and restful sleep, and thus negatively affect their daily lives. In addition, breathing breaks often reduces oxygen saturation in the blood, causing many serious diseases, especially cardiovascular diseases, and may even lead to death. In order to eliminate all these negative effects, an effective treatment should be applied to patients diagnosed with OSAS. Continuous Positive Airway Pressure (CPAP) therapy is the gold standard treatment method for OSAS. In this treatment performed with CPAP devices, the upper airway of the patients is kept open with the determined constant pressure. The most effective therapeutic pressure (optimum CPAP level) for patients is determined by sleep specialists through a manual titration process in sleep laboratories. However, this process is both costly, time consuming and quite tiring. For this reason, many studies have been conducted in the literature to develop alternative solutions to titration in order to determine the optimum CPAP level. Most of the studies focused on the direct prediction of the optimum CPAP level to be applied to the patient, and they produced regression-based formulas based on similar features as alternative solutions. However, until today, an alternative solution that is fully accepted in the clinic, applicable and with high accuracy has not been developed yet.

In this thesis study, the optimum CPAP levels of those who applied to Necmettin Erbakan University, Meram Medical Faculty, Department of Chest Diseases, Sleep Clinic with the suspicion of OSAS were predicted. Before the prediction process was performed, it was determined whether the subjects included in the thesis study were OSAS patients or not and required CPAP therapy or not by using Nonlinear Analysis and Rule-Based Algorithm approaches and nasal cannula airflow and oximetry signals, which are among the polysomnography signals. With the Nonlinear Analysis Approach, OSAS patients were differentiated from healthy individuals with 93.10% accuracy, 96.43% sensitivity and 81.82% specificity, and patients requiring CPAP therapy could be identified with 96.25% sensitivity and 89.53% precision. The Rule-Based Algorithm approach distinguished OSAS patients from healthy individuals with 98.62% accuracy, 98.21% sensitivity and 100% specificity, while it was able to identify patients requiring CPAP therapy with 100% sensitivity and 100% precision. After the identification of patients requiring treatment with OSAS therapy, different feature sets were created by taking into account the demographic and anthropometric information of these patients, nasal cannula airflow and oximetry signals, apneic attacks and oxygen reductions during the night. Afterwards, the most effective ones were selected among the features in different feature sets on the optimum CPAP levels and the optimum CPAP

levels of the patients were predicted by using both all features and effectively selected features with linear regression analysis and various artificial intelligence methods. Finally, 40 different CPAP estimation models were developed with the features and methods (stepwise multiple linear regression analysis, artificial neural networks, support vector machine, random forest and k closest neighborhood) with high prediction performance. 36 of these 40 CPAP estimation models were obtained by different artificial intelligence methods, only 4 of them were obtained by linear regression analysis. As a result, Support Vector Machines with polynomial or radial basis kernel functions created 24 of 36 models developed with artificial intelligence methods and became the most successful method in prediction process. 25 model among the developed 40 models revealed a high correlation ($0.6 \leq r < 0.8$; $0.36 \leq r^2 < 0.64$) between the CPAP levels predicted in the thesis and the optimum CPAP levels determined by the specialists in sleep laboratories, and 10 model defined the this relationship as very high ($r \geq 0.8$; $r^2 \geq 0.64$).

When all the results obtained in the thesis were evaluated in general, it was seen that the characteristics of airflow and oximetry polysomnography signals, apneic attacks experienced by OSAS patients and the decreases in oxygen levels due to the attacks had great effects on optimum pressures. In addition, this thesis study revealed that the linear and nonlinear relationships between the features used for prediction can be explained better with artificial intelligence methods, and thus, many artificial intelligence methods generally produce more successful results compared to linear regression analyzes, which are mostly preferred in the literature for prediction of optimum CPAP levels. The thesis study has brought developed new CPAP prediction models and new features used as prediction parameters in models to the literature.

Keywords: Artificial Intelligence, CPAP Prediction Models, CPAP Therapy, Feature Extraction, Nasal Cannula Airflow Signal, OSAS, Oximetry Signal, Signal Processing

ÖNSÖZ

Bu tez çalışmamda değerli katkı ve fikirleri ile her daim beni destekleyip yönlendiren ve benim yetişmem için emeğini esirgemeyen danışman hocam Sayın Prof. Dr. Gülay TEZEL'e sonsuz teşekkürlerimi ve saygılarımı sunuyorum. Tezin gelişmesine yönlendirici görüş ve önerileriyle yardımcı olan ve manevi desteklerini esirgemeyen Sayın hocalarım Prof. Dr. Seral ÖZŞEN ve Dr. Öğr. Üyesi Ömer Kaan BAYKAN'a, çok değerli mesai arkadaşlarıma ve diğer bölüm hocalarıma can-ı gönülden teşekkürü bir borç bilirim.

Çalışmalarım sırasında ve hayatımın her anında yanımda olan, maddi ve manevi yönden beni destekleyen, üzerimde büyük hakları olan babam Durali GÖĞÜŞ, annem Fatmana GÖĞÜŞ ve kardeşlerim Hilal DEMİREL, Muhammed Fatih GÖĞÜŞ, Zeynep GÖĞÜŞ ve Ahmet Hamdi GÖĞÜŞ'e en içten teşekkürlerimi, saygılarımı ve minnettarlığımı sunarım. Ayrıca manevi katkılarını her zaman hissettiğim arkadaşlarım Havva ATEŞ, Betül UZBAŞ ve Müberra Nur KILIÇARSLAN'a sonsuz teşekkür ederim.

Fatma Zehra GÖĞÜŞ
KONYA-2020

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	vi
ÖNSÖZ	viii
İÇİNDEKİLER	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
1.1. Tezin Amacı ve Önemi	2
1.2. Tezin Literatüre Katkısı	4
1.3. Tezin Organizasyonu	7
2. KAYNAK ARAŞTIRMASI	8
3. TIKAYICI UYKU APNE SENDROMU (OSAS)	18
3.1. Polisomnografi ve OSAS Tanısı	19
3.2. Sürekli Pozitif Havayolu Basıncı (CPAP)	23
4. MATERYAL VE YÖNTEM	26
4.1. Polisomnografi Kayıtlarının Elde Edilmesi	28
4.2. Polisomnografi Kayıtları Üzerinde Gerçekleştirilen Ön İşlemler	29
4.3. Özellik Çıkarma Yöntemleri.....	31
4.3.1. Çokfraktallı eğimden arındırılmış dalgalanma analizi (MDFA)	31
4.3.2. Tekil değer ayrışımı (SVD)	34
4.3.3. Otoresif / Özbağlanım (AR)	34
4.3.4. Entropi ölçüleri	35
4.3.5. Merkezi eğilim ölçüsü (CTM)	36
4.3.6. Lempel ziv karmaşıklığı (LZK).....	37
4.4. Özellik Seçme Yöntemleri.....	38
4.4.1. Bilgi kazancı özellik değerlendirme yöntemi	38
4.4.2. Korelasyon özellik değerlendirme yöntemi	38
4.4.3. OneR özellik değerlendirme yöntemi	38
4.4.4. Korelasyon tabanlı alt küme değerlendirme yöntemi	39
4.4.5. Sarmal tabanlı alt küme değerlendirme yöntemi	39
4.5. Sınıflandırma ve Tahmin Yöntemleri	40
4.5.1. Rastgele orman algoritması (RF).....	40
4.5.2. Destek vektör makineleri (SVM).....	41
4.5.3. Yapay sinir ağları (ANN)	42
4.5.4. Naive Bayes (NB).....	43
4.5.5. K en yakın komşu algoritması (kNN).....	44
4.5.6. Doğrusal regresyon analizleri	44
4.6. Performans Değerlendirme Ölçütleri.....	45

5. OSAS TEŞHİSİ VE CPAP TEDAVİ GEREKLİLİĞİNİN BELİRLENMESİ ..	49
5.1. Doğrusal Olmayan Analiz Yaklaşımı	49
5.2. Kural Tabanlı Algoritma Yaklaşımı	56
6. CPAP TAHMİN MODELLERİNİN OLUŞTURULMASI	65
6.1. Özellik Setleri	65
6.1.1. Demografik ve antropometrik özellikler.....	65
6.1.2. Hava akımı ve oksimetri sinyal özellikleri	66
6.1.3. Hava akımı ve oksimetri sinyallerinin doğrusal olmayan özellikleri	68
6.1.4. Apneik atak ve desaturasyon özellikleri	71
6.2. Tahmin Modelleri	73
7. SONUÇLAR VE TARTIŞMA	77
7.1. OSAS Teşhisi ve CPAP Tedavi Gerekliliğini Belirleme Çalışmaları Sonuçları. 77	
7.1.1. Doğrusal olmayan analiz yaklaşımına ait sonuçlar.....	78
7.1.2. Kural tabanlı algoritma yaklaşımına ait sonuçlar	85
7.2. CPAP Seviyesi Tahmin Modelleri ve Sonuçları.....	90
8. SONUÇLAR VE ÖNERİLER	126
8.1. Sonuçlar	126
8.2. Öneriler	131
KAYNAKLAR	134
EKLER	142
ÖZGEÇMİŞ	143

SİMGELER VE KISALTMALAR

Simgeler

A	: SVD sinyalinin her bir örneği için Apneik etiketi
a(k)	: Hava akımı sinyallerinin her 1 sn'si için alan
apneik_esik	: Apneik atak tespitinde atakların tespiti için kullanılan eşik değeri
ar(k)	: AR yöntemi katsayıları (AR parametreleri)
Base[]	: Apneik atak tespitinde bazal değer hesaplanması için kullanılan sinyal örneklerini içeren dizi
Base_Val	: Apneik atak tespitindeki Bazal değer
cmH ₂ O	: OSAS tedavisinde kullanılan pozitif basınç birimi
e(n)	: Hata terimi
e _p	: Toplam en az karesel hata
esik_deger_1	: Apneik atak tespitinde aykırı değerlerin bulunması için kullanılan eşik değeri
F _{Norm} (k)	: Normalizasyon faktörü
f _s	: Örnekleme frekansı (1 sn'deki sinyal örnek sayısı)
F _α	: Tekillik spektrumu
h(q)	: Hava akımı sinyaline ait hurst üsteli
K	: Cohen'in Kappa katsayısı
N	: SVD sinyalinin her bir örneği için Normal etiketi
ÖrEn	: Örnek Entropi
p	: p değeri
PSD _{Burg}	: AR-Burg yöntemi ile hesaplanan güç spektrum yoğunluğu
r	: Korelasyon katsayısı
r ²	: Belirlilik katsayısı
s	: SVD sinyali
s _i	: SVD sinyalinin her bir örneği
\tilde{s}	: SVD sinyalinin medyanı
std(k)	: Hava akımı sinyallerinin her 1 sn'si için standart sapma
x(i)	: Hava akımı sinyali
$\overline{x^2(k)}$: 1 saniyedeki sinyal değerlerinin ortalaması
\overline{X}_{Norm}	: Adaptif olarak normalize edilmiş hava akımı sinyalinin ortalaması
X _{Norm} (k)	: Adaptif olarak normalize edilmiş hava akımı sinyali
YakEn	: Yaklaşık Entropi
α	: Tekillik üsteli
τ(q)	: Hava akımı sinyaline ait renyi (ölçeklendirme) üsteli

Kısaltmalar

AASM	: Amerikan Uyku Tıbbı Akademisi
AHI	: Apne Hipopne İndeksi
ANN	: Yapay Sinir Ağları
APAP	: Otomatik Pozitif Havayolu Basıncı
AR	: Otoregresif Yöntem

BMI	: Vücut Kitle İndeksi
BPAP	: İki Seviye Pozitif Havayolu Basıncı
CA	: Sınıflandırma Doğruluğu
CMS	: Medicare & Medicaid Hizmet Merkezleri
CPAP	: Sürekli Pozitif Havayolu Basıncı
CTM	: Merkezi Eğilim Ölçüsü
DFA	: Eğimden Arındırılmış Dalgalanma Analizi
DTAS	: Doğru olarak tespit edilen atak sayısı
EAS	: Eksik atak sayısı yani tespit edilemeyen atakların sayısı
EEG	: Beyin Dalgaları (Elektroensefalografi)
EES	: Epworth Uykululuk Puanı
EKG	: Kalp Fonksiyonları (Elektrokardiyografi)
EMG	: Kas Aktivitesi (Elektromiyografi)
EOG	: Göz Hareketleri (Elektrookülografi)
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
FTAS	: Fazladan tespit edilen atak sayısı yani gerçekte olmayıp kural tabanlı algoritma tarafından tespit edilen atakların sayısı
GAS	: Gerçek apneik atak sayısı
GRNN	: Genel Regresyon Sinir Ağları
ICC	: Sınıf içi korelasyon katsayısı
kNN	: k En Yakın Komşu Algoritması
LZK	: Lempel Ziv Karmaşıklığı
MDFA	: Çokfraktallı Eğimden Arındırılmış Dalgalanma Analizi
MLR	: Çoklu Doğrusal Regresyon
NB	: Naive Bayes
NC	: Boyun Çevresi
ODI	: Oksijen Desatürasyon İndeksi
OSAS	: Tıkayıcı Uyku Apne Sendromu
ÖS	: Özellik Seti
PAP	: Pozitif Havayolu Basıncı
PSG	: Polisomnografi
RDI	: Solunum Rahatsızlık İndeksi
RF	: Rastgele Orman Algoritması
SLR	: Basit Doğrusal Regresyon
S-MLR	: Adım Adım Çoklu Doğrusal Regresyon
SVD	: Tekil Değer Ayrışımı
SVM	: Destek Vektör Makineleri
TN	: Doğru Negatif
TP	: Doğru Pozitif

1. GİRİŞ

Tıkaçıcı Uyku Apne Sendromu (Obstructive Sleep Apnea Syndrome: OSAS), uyku sırasında üst solunum yolunda meydana gelen kısmi veya tam tıkanmalar ve bunlara eşlik eden kan oksijen değerinde azalma ile karakterize bir uyku sendromudur. OSAS'ta üst solunum yolundaki tam ya da kısmi tıkanıklıklara bağlı olarak oluşan, en az 10 saniye (sn) süren ve genellikle apneik atak olarak adlandırılan apne ve hipopne atakları, kişilerde soluk kesilmelerine yol açarak uykunun devamlılığını bozar. Bu durum da kişinin derin ve dinlendirici bir uyku uyumasını engelleyerek gündüz aşırı uykululuğa neden olur ve dolayısıyla trafik ve iş kazaları, konsantrasyon bozukluğu, depresyon gibi pek çok olumsuz durumun oluşmasına sebebiyet verir (Koley ve Dey, 2013). Ayrıca, soluk kesilmeleri sıklıkla kandaki oksijen doyunluğunu azaltarak başta kalp damar hastalıkları olmak üzere hipertansiyon, diyabet, nörobilişsel bozukluklar gibi ciddi rahatsızlıkların ortaya çıkma riskini artırır (Akhter ve ark., 2016). Hatta bu rahatsızlıklara bağlı olarak OSAS kişilerin ölümüne bile yol açabilir (Schiza ve ark., 2011). Bu nedenle OSAS'ın doğru teşhisi ve etkili bir şekilde tedavisi büyük bir önem arz etmektedir.

Polisomnografi (PSG) ve sürekli pozitif havayolu basınç (Continious Positive Airway Pressure: CPAP) terapisi, OSAS'ın teşhisi ve tedavisi için kullanılan altın standart tanı ve tedavi yöntemleridir. OSAS şüphesi ile ilgili kliniğe başvuran kişilerin teşhisi ve tedavisi için tüm gece veya yarı gece (split night) prosedürleri uygulanır. Uyku ile ilişkili solunum bozukluklarında rutin ve esas olarak önerilen tüm gece prosedüründe, kişinin uyku laboratuvarında iki gece geçirmesi istenir. İlk gece tanı gecesidir. Yaklaşık 6-8 saat süren PSG ile kişinin beyin dalgaları (Elektroensefalografi-EEG), göz hareketleri (Elektrookülografi-EOG), solunum faaliyetleri (nazal hava akımı), kanındaki oksijen seviyesi (oksimetri-SpO2), kas aktivitesi (Elektromiyografi-EMG), kalp fonksiyonları (Elektrokardiyografi-EKG) gibi fizyolojik sinyalleri gece boyunca belli bir periyotla eş zamanlı ve devamlı olarak kaydedilir. Kaydedilen sinyaller ve bu sinyallerde uyku süresi boyunca meydana gelen değişiklikler teşhis amacıyla uyku uzmanları tarafından analiz edilir (Xie ve Minn, 2012) ve Amerikan Uyku Tıbbi Akademisi (American Academy of Sleep Medicine: AASM) tarafından yayınlanan kılavuza dayanarak apne ve hipopne atakları tanımlanır. Tanımlanan apne ve hipopnelerin saat başına sayıları yani Apne Hipopne İndeksi (Apnea Hyoponea Index: AHI) hesaplanarak OSAS tanısı için nihai karar verilir (AASM, 2012). İkinci gece,

CPAP terapisi ile tedavide gerekli olan, hastayı tedavi edebilecek ve yan etkilere yol açmayacak en etkin yani optimum basıncın belirlendiği titrasyon gecesidir. OSAS tanısı konulan kişiler CPAP cihazına bağlanır ve klasik manuel titrasyon ile kişilerin tedavi edici basınç seviyeleri belirlenir (Choi ve ark., 2010; Schiza ve ark., 2011). Manuel titrasyona minimum (4 cmH₂O) basınç seviyesi ile başlanır. Daha sonra hastaya verilen basınç uyku uzmanı tarafından aşamalı olarak artırılır (El Solh ve ark., 2007). Basınç artırma işlemi tüm uyku evrelerinde ve tüm uyku pozisyonlarında solunum problemleri (apne, hipopne, horlama vs.) ortadan kaldırılıncaya kadar devam eder (El Solh ve ark., 2007). Tüm solunum problemlerinin yok edildiği ve yan etkilere yol açmayan en düşük basınç değeri tedavi edici optimum basınç olarak kabul edilir (Schiza ve ark., 2011).

Kliniklerdeki uyku laboratuvarlarında uzmanlar eşliğinde gerçekleştirilen manuel titrasyonun OSAS tedavisindeki yeri tartışmasızdır. Ancak, manuel titrasyon ile etkili basıncın belirlenmesi süreci çoklu basınç değişikliklerini beraberinde getirmektedir. Ayrıca, manuel titrasyon yoğun emek gerektiren, pahalı, zaman alıcı ve oldukça yorucu bir süreçtir (El Solh ve ark., 2007; Schiza ve ark., 2011). Tüm bunlara ek olarak, hastaların klinik ortamlara uyum sağlayamamaları uyku uyumayı güçleştirebilir ve titrasyon süresinin yetersiz olmasına yol açarak etkili tedavi edici basıncın doğru bir şekilde belirlenmesini engelleyebilir (Basoglu ve Tasbakan, 2012). Dünyada ve ülkemizde uyku bozuklukları ile ilgili yeterli düzeyde çalışma yapabilecek laboratuvar sayısı da oldukça sınırlıdır. Bu nedenle, kişilerin hem OSAS teşhisi hem de tedavi edici CPAP titrasyonu için 2 gecesini laboratuvarında geçirmesi uzun bekleme listelerine yol açar. Bu durum da OSAS sendromundan etkilenen diğer hastaların tanı ve tedavisini geciktirir. Tüm bu olumsuzluklar, OSAS tedavisindeki optimum CPAP seviyesinin belirlenmesi amacıyla kullanılan manuel titrasyonunun yerini alacak veya bu titrasyon sürecini hızlandıracak ve basitleştirecek etkili alternatiflerin geliştirilmesi gerekliliğini ortaya çıkarmaktadır.

1.1. Tezin Amacı ve Önemi

CPAP terapisi ile tedavide en önemli husus hastaların üst solunum yollarının açık kalmasını sağlayacak basınç seviyesinin belirlenmesidir (Choi ve ark., 2010). Yüksek seviyede basınç uyku sırasında üst hava yolu tıkanıklığını ortadan kaldırırsa da, hastada ağız ve burun kuruluğu gibi rahatsızlıklara neden olabilir ve bireyler tedaviyi yarıda bırakabilir (Akashiba ve ark., 2001; Choi ve ark., 2010). Belirlenen basınç

seviyesinin gerekenden düşük olması ise, yetersiz tedavi ve istenmeyen maske kaçaklarına neden olabilir (Akashiba ve ark., 2001; Choi ve ark., 2010). Bu nedenlerden dolayı, CPAP terapisi ile gerçekleştirilen tedavideki basınç, apneik ataklar (apne, hipopne), horlama ve uyanayazma gibi tüm uyku düzensizliklerini ortadan kaldırmak için optimum düzeyde olmalıdır.

Bu tez çalışmasının temel amacı, OSAS için altın standart tedavi yöntemi olarak kabul edilen CPAP terapisindeki optimum basınç seviyesinin hastaların en az %90'ını için ± 3 cmH₂O güven aralığında olacak şekilde tahmin edilmesidir. Bu amaç doğrultusunda, OSAS tanısı konulmuş hastaların demografik ve antropometrik (fiziksel) bilgilerinin yanı sıra hastaların polisomnografi sinyal kayıtlarının, gece boyunca uyku sırasında geçirmiş oldukları apneik atakların ve ataklara bağlı olarak oluşan oksijen seviyesindeki düşüşlerin (desaturasyon) de göz önünde bulundurulmasıyla doğrusal regresyon analiz ve farklı yapay zeka yöntemleri ile CPAP tahmin modellerinin geliştirilmesi ve bu sayede kliniklerdeki uyku laboratuvarlarında uygulanan titrasyona alternatif bir çözümün önerilmesi hedeflenmiştir.

Tez çalışmasında geliştirilen CPAP tahmin modelleri ile gerçekleştirilecek optimum CPAP seviye tahminiyle, aslında klinik anlamda ulaşılmak istenen başarımlar aşağıda verildiği gibi ifade edilebilir:

- ✓ Laboratuvardaki manuel titrasyonun başarı oranı iyileştirilebilecektir. Uyku uzmanları öngörülen (tahmin edilen) basınç seviyeleri ile titrasyonu başlatarak hastalar için gerekli olan optimum CPAP seviyelerine daha kısa sürede ulaşabileceklerdir.
- ✓ Hastaların tedavileri doğrudan başlatılabilecektir. Uyku laboratuvarında manuel titrasyonun mümkün olmadığı (örneğin hareketsizlik, güvenlik ve kritik hastalık gibi) durumlarda manuel titrasyon yerine tahmin edilen basınç seviyesi kullanılarak kişinin tedavisinin başlatılması ya da yüksek başarı oranlarında yapılan optimum basınç tahmini ile hastanın tedavi için tekrar hastaneye yatmasına ve manuel titrasyona gerek kalmadan öngörülen basınç ile tedavinin başlatılması mümkün olacaktır.

Böylece, tez çalışmasındaki amaca ulaşılmasıyla, laboratuvar ortamındaki manuel titrasyonun neden olduğu çoklu basınç değişiklikleri ortadan kaldırılabilir, optimum etkili basıncın belirlenmesi için yetersiz zaman riski en aza indirilebilir ve klinikte harcanan zaman ve tedavi maliyeti azaltılabilecektir. Sonuç olarak, OSAS tedavisine hem klinik hem de hasta açısından çok yönlü katkı sağlanmış olacaktır.

1.2. Tezin Literatüre Katkısı

Literatürde, manuel titrasyonun dezavantajlarından dolayı OSAS'ın tedavisinde kullanılan CPAP titrasyonunun hızlandırılması ve basitleştirilmesi amacıyla farklı alternatifler önerilmiştir. Otomatik CPAP titrasyonu bu alternatiflerden biridir. Bir diğeri ise özellikle son yıllarda sıklıkla tercih edilen demografik (cinsiyet, yaş vb.), antropometrik (vücut kitle indeksi, boyun çevresi vb.) ve polisomnografik (AHI, ortalama oksimetri değeri vb.) parametrelerden (değişkenlerden) türetilen CPAP tahmin formülleridir (Lee ve ark., 2013). Otomatik CPAP kullanımı, manuel CPAP titrasyonu ile ilgili pratik sorunu büyük ölçüde çözmüştür. Otomatik CPAP cihazları ile hastaların solunum paternleri izlenir ve ardından anormal solunum düzensizliklerine bağlı olarak önceden belirlenmiş alt ve üst limitler arasında otomatik basınç seviyeleri ayarlanır. Gece boyunca titre edilen basıncın 90. veya 95. yüzdeleri genellikle optimum tedavi edici basınca eşdeğer kabul edilir. Ancak farklı üreticiler tarafından üretilen otomatik CPAP cihazları titrasyon işlemini farklı algoritmalar kullanarak gerçekleştirebilir ve tedavi edici basınç olarak farklı basınç seviyeleri üretebilir (Luo ve ark., 2013). Ayrıca kalp yetmezliği, önemli akciğer hastalığı veya obezite hipoventilasyon sendromu gibi rahatsızlıkları olan bazı hastalarda bu cihazlardan kaçınılması gerektiği klinisyenler tarafından belirtilmiştir (Lee ve ark., 2013). Bazı durumlarda ise hastaların solunum düzensizlikleri otomatik CPAP titrasyonu ile belirlenen basınç ile azaltılabilir de, oksijen desatürasyonları hala devam edebilmektedir. Böyle bir durumda, otomatik titrasyon işlemi de tıpkı manuel titrasyon gibi uyku uzmanının müdahalesini gerektirir. Yine manuel titrasyona benzer bir şekilde, otomatik CPAP titrasyonu sırasında da üst ve alt limitler arasında çoklu basınç değişiklikleri meydana gelebilir ve uzun süreli takip gerektirir. Tüm bunlara ek olarak otomatik CPAP cihazları hastalarda daha önce gözlemlenmeyen santral apnelerin ortaya çıkmasını da tetikleyebilir. Bu nedenle, CPAP tahmin formüllerinden faydalanmak, klinik uygulamada, özellikle diğer spesifik rahatsızlıkları olan popülasyonlarda yararlı olmaya devam etmektedir (Lee ve ark., 2013).

CPAP tahmin formülleri ile optimum CPAP seviyesinin tespit edilebilmesi veya uyku laboratuvarlarında gerçekleştirilen titrasyon işlemleri için başlangıç basınç seviyesinin belirlenebilmesi amaçlanmaktadır. Günümüze kadar birçok araştırmacı tarafından, bir çok farklı ırk için, çeşitli tahmin formülleri geliştirilmiştir (Miljeteig ve Hoffstein, 1993; Series ve Marc, 1997; Akashiba ve ark., 2001; Lin ve ark., 2003;

Stradling ve ark., 2004; Rowley ve ark., 2005; El Solh ve ark., 2007; Loreda ve ark., 2007; El Solh ve ark., 2009; Choi ve ark., 2010; Schiza ve ark., 2011; Basoglu ve Tasbakan, 2012; Lee ve ark., 2013; Lai ve ark., 2015; Ebben ve ark., 2017; Wahab ve Ahmed, 2017; Kim ve Yang, 2018; Yong ve ark., 2018; Chong ve ark., 2019 ; Chong ve ark., 2020; Cunha ve ark., 2020). Bu formüllerin test edilmesi ve doğrulanması amacıyla da birçok çalışma yapılmıştır. Ancak gerçekleştirilen çalışmalar incelediğinde, çok az sayıda formülün, klinik ortamlarda tedaviye yönelik amaçlarla geliştirilmiş olduğu görülmüştür (Miljeteig ve Hoffstein, 1993; Series ve Marc, 1997; Lin ve ark., 2003; Stradling ve ark., 2004; Loreda ve ark., 2007). Ayrıca, yapılan çalışmalarda genellikle aynı parametrelerin tercih edildiği, araştırmacılar tarafından aynı veya farklı ırklar için sıklıkla benzer parametrelerin kullanıldığı, farklı parametrelerin değerlendirmeye alınmadığı gözlemlenmiştir. Bu çalışmalardaki tahmin formüllerinde kullanılan parametreler sık kullanılanlardan daha az kullanılanlara göre aşağıdaki listede görüldüğü gibi olmuştur.

1. Vücut Kitle İndeksi (Body Mass Index: BMI)
2. Apne Hipopne İndeksi (AHI)
3. Boyun Çevresi (Neck Circumference: NC)
4. Oksijen Desatürasyon İndeksi (Oxygen Desaturation Index: ODI)
5. Solunum Rahatsızlık İndeksi (Respiratory Desaturation Index: RDI)
6. Ortalama oksijen saturasyon indeksi
7. En düşük oksijen saturasyon indeksi (Minimum oksimetri)
8. Sefalometrik değişkenler
9. Yaş ve Irk
10. Diğer parametreler (dil pozisyonu bilgisi, epworth uykululuk puanı vs)

Geliştirilen birçok formülün (Akashiba ve ark., 2001; Cunha ve ark., 2020) ise içerdiği parametreler (üst hava yolları mekanizmaları, solunum fonksiyonları ve sefalometrik değişkenler) bakımından klinik ortamlarda kullanılmaya uygun olmadığı belirlenmiştir (Loreda ve ark., 2007). Bu parametrelerin ölçümü özel test ekipmanları gerektirmektedir ve gün - gün değerlendirmelerde, rutin olarak bu ölçümlerin yapılması pratik olarak mümkün değildir (Loreda ve ark., 2007).

Günümüze kadar yapılan çalışmalarda, araştırmacılar çalışmalarına dahil ettikleri parametreler üzerine genellikle doğrusal regresyon analizlerini uygulamışlar ve

regresyon analizi sonucunda optimum CPAP seviyesini tahmin eden formüller elde etmişlerdir. Doğrusal regresyon analizi ile elde edilen tahmin formülleri; optimum CPAP seviyesini tespit etmede, CPAP titrasyonu için başlangıç değerini belirlemede ve CPAP titrasyonundaki başarı oranını geliştirmede mütevazı bir performans sergilemiştir (El Solh ve ark., 2009). Doğrusal olmayan özellikler ile davranışsal süreçler arasındaki karmaşık ilişkinin tam olarak açıklanamaması, formüller ile yapılan tahminlerde en büyük eksiklik olarak görülmüştür. El Solh ve ark. (2007), El Solh ve ark. (2009) ve Kim ve Yang (2018) yaptıkları çalışmalarda, doğrusal regresyon yöntemlerinin dezavantajlarından bahsetmişler ve optimum CPAP seviyesinin tahmini için sinir ağları ve rastgele orman tekniklerini kullanmışlardır. Bu araştırmacılar tarafından yapılan üç çalışma dışında, günümüze kadar yapılan çalışmalarda doğrusal regresyon analizleri tercih edilmiş ve farklı yapay zeka teknikleri CPAP seviyesinin tahmini için kullanılmamıştır.

CPAP seviyesi tahmini gerçekleştiren literatür çalışmalarında, kişilerin teşhis gecesinde PSG tetkiki ile ölçülen hava akımı (solunum) polisomnografi sinyal kaydına ve kişilerin geçirmiş oldukları apneik ataklara ait özellikler göz önünde bulundurulmamıştır. Oksijen seviyesini belirten oksimetri sinyaline ve ataklara eşlik eden oksijen desaturasyonlarına ait ise sınırlı sayıda ve genellikle aynı özellikler incelemeye alınmıştır. Oysaki, hava akımı ve oksimetri sinyalleri başta olmak üzere polisomnografi sinyalleri, bu sinyallerde uyku sırasında meydana gelen değişimler, gece boyunca geçirilen apneik atak ve desaturasyonlar OSAS teşhisi ve tedavisi ile doğrudan ilişkilidir. Kliniğe başvuran kişilerin OSAS hastası olup olmadıkları, OSAS hastası iseler hastalık dereceleri ve tedavileri için CPAP seviyesini belirleme süreci uyku uzmanları tarafından sinyallerdeki değişiklikler, apneik ataklar ve oksijen desaturasyonları izlenerek belirlenir. Bu durum literatür çalışmalarının eksikliği olarak değerlendirilmiş ve gerçekleştirilen tez çalışmasında göz önünde bulundurulmuştur. Bu tez çalışması kapsamında kişilerin polisomnografi sinyal kayıtlarından, geçirmiş oldukları apneik ataklardan ve oksijen desaturasyonlarından uzmanların danışmanlığında elde edilen farklı özellikler tahmin parametresi olarak değerlendirilmiştir. Böylelikle, farklı değişkenlerin optimum CPAP seviyesi üzerindeki etkisi incelenmiştir. Ayrıca, bu tez çalışmasında, tahmin parametreleri, literatürde sıklıkla tercih edilen doğrusal regresyon analizinin yanı sıra farklı yapay zeka yöntemleri tarafından da kullanılmış, bu sayede parametreler arasındaki doğrusal ve doğrusal olmayan ilişkiler incelenmiş, optimum CPAP seviyeleri tahmin edilmiş ve

CPAP tahmin modelleri geliştirilmiştir. Gerçekleştirilen tez çalışması sayesinde kliniklerdeki olağan teşhis ve tedavi prosedürlerini destekleyici yeni parametreler, yeni yöntemler ve yeni tahmin modelleri CPAP seviyelerinin tahmini için literatüre kazandırılmıştır. Farklı parametre ve yöntemlerin tahmin etkinliği değerlendirilerek literatüre farklı bir yönde de yenilik sağlanmıştır.

1.3. Tezin Organizasyonu

Bu tez çalışması 8 bölüme ayrılmıştır.

Giriş bölümünde gerçekleştirilen tez çalışmasının amacı, önemi, literatüre katkısı ve tezin organizasyonundan bahsedilmiştir.

İkinci bölümde literatürde optimum CPAP seviyesinin tahmini üzerine gerçekleştirilen çalışmalar incelenmiş ve bu çalışmalara ait kısa bilgiler sunulmuştur.

Üçüncü bölümde, OSAS ve bu sendromun teşhis ve tedavi süreci ile ilgili genel bilgiler verilmiştir.

Dördüncü bölümde materyal ve yöntem başlığı altında tez çalışmasına dahil edilen kişilere ve o kişilere ait polisomnografi kayıtlarının alınmasına dair bilgilere, kayıtlar üzerinde gerçekleştirilen ön işlemlere, tez çalışmasında kullanılan yöntemlere ve matematiksel tanımlamalara yer verilmiştir.

Beşinci bölümde, çalışmaya dahil edilen kişilerin OSAS teşhisi ve CPAP terapisi ile tedaviye ihtiyaç duyup duymadıklarının belirlenmesi üzerinde durulmuştur.

Altıncı bölümde, optimum CPAP seviyelerinin tahmininde parametre olarak kullanılacak farklı özellikleri içeren özellik setlerinin oluşturulması, tahmin üzerinde etkisi en fazla olan özelliklerin belirlenmesi ve doğrusal regresyon analizleri ve çeşitli yapay zeka yöntemleri ile CPAP tahmin modellerinin oluşturulmasına dair açıklamalarda bulunulmuştur.

Yedinci bölümde, OSAS teşhisinin, CPAP terapisi ile tedavi gereksiniminin ve CPAP tahmin modellerinin analizleri yapılmış ve elde edilen sonuçlar ayrıntılı bir şekilde, grafik ve tablolar halinde sunulmuştur. Bu bölümde ayrıca elde edilen sonuçların yorumlanması ve tartışılması da gerçekleştirilmiştir.

Sekizinci bölümde ise, elde edilen araştırma sonuçları genel olarak özetlenmiş, önerilen CPAP tahmin modellerinin avantaj ve dezavantajlarından bahsedilmiş ve önerilerde bulunulmuştur.

2. KAYNAK ARAŞTIRMASI

Literatürde OSAS hastalarının tedavisinde kullanılan CPAP terapisi için CPAP cihazları ile sağlanan tedavi edici optimum basınç seviyesini belirleme yönünde birçok çalışma yapılmıştır. Bu çalışmalar genellikle optimum CPAP seviyesinin doğrudan tahmini üzerinde durmuş ve tahmin için çoğunlukla benzer özellikler üzerine kurulmuş regresyon tabanlı matematiksel formülleri alternatif çözümler olarak üretmişlerdir (Camacho ve ark., 2015).

Optimum CPAP seviyesini belirleme üzerine yapılan ilk çalışma Miljeteig ve Hoffstein (1993)'in Kafkas popülasyonu üzerinde yaptığı çalışma olmuştur. Araştırmacıların çoklu doğrusal regresyon analizi ile geliştirdikleri Denklem 2.1'de görülen tahmin formülü BMI, NC ve AHI parametrelerini içermektedir. Bu formül hastaların optimum CPAP seviyelerindeki varyasyonu %76 oranında karşılamıştır. Araştırmacılar, denklemin CPAP titrasyonlarının başarı oranlarını arttırmak için kullanılabileceğini de öne sürmüşlerdir; çünkü başlangıç basıncı optimum basınca daha yakın olacak ve böylece çoklu basınç değişikliklerine olan ihtiyaç ortadan kaldırılacaktır. Böylelikle de optimum basıncın belirlenmesinde yetersiz zaman riski en aza indirgenecektir. Hoffstein formülü olarak bilinen bu formül klinik çalışmalarda en sık kullanılan iki formülden biri olmuştur.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = -512 + (0.13 \times \text{BMI}) + (0.16 \times \text{NC}) + (0.04 \times \text{AHI}) \quad (2.1)$$

Series ve Marc (1997), Hoffstein formülünün gerekli olan basınç ihtiyacını karşılayamadığını ifade etmişlerdir. Bu nedenle aynı parametrelerden oluşan yeni formülü yine Kafkas popülasyonu üzerinde geliştirmişlerdir (Denklem 2.2). Geliştirilen formül hastaların %95'inde optimum basınç değerini belirleyici olmuştur. Series formülü de klinik ortamlarda kullanılan diğer tahmin formülü olarak tanımlanmıştır.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = -0.611 + (0.193 \times \text{BMI}) + (0.077 \times \text{NC}) + (0.02 \times \text{AHI}) \quad (2.2)$$

Akashiba ve ark. (2001) OSAS tanısı konulmuş 27 Japon erkek birey ve 20 sağlıklı birey üzerinde çalışma yapmışlardır. Araştırmacılar sağlıklı ve hasta bireylerdeki sefalometrik (kafa kemikleri ve yumuşak dokular ile ilgili) ölçümlerdeki farklılıkları belirleyerek bu ölçümleri ortalama oksimetri değeri ile birlikte optimum CPAP seviyelerini tahmin formülünde kullanmışlardır. Tahmin amacıyla çoklu doğrusal

regresyon analizinden faydalanmışlardır. Çalışmada, Denklem 2.3'deki formül ile hesaplanan optimum CPAP seviyesinin klinikte uzmanlar tarafından titrasyon ile belirlenen optimum CPAP seviyesine benzer olduğu belirtilmiştir. Denklem 2.3'deki NSBa kafa kaidesi açısını belirtmektedir.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 42.036 - (0.209 \times \text{ortalama oksimetri}) - (0.099 \times \text{NSBa}) \quad (2.3)$$

Lin ve ark. (2003) OSAS'lı Tayvan popülasyonu için çoklu doğrusal regresyon analizi ile Denklem 2.4'te görülen farklı bir optimum CPAP tahmin formülü belirlemişlerdir. Bu formüle sadece BMI ve AHI parametrelerini dâhil etmişlerdir. Çalışmada, NC gibi diğer parametrelerin optimum basınç tahminini önemli derecede etkilemediği fikri savunulmuştur. Araştırmacılar ayrıca etnik farklılıkların önemli bir rolü olduğunu ve kendilerinin geliştirdiği formülün Hoffstein formülüne göre Asya popülasyonu için optimum CPAP seviyesini belirlemede daha etkili olacağını belirtmişlerdir. Hastaların %86'sında optimum basınç seviyesi tahmini ± 2 cmH₂O sapma değeri ile başarılı bir şekilde yapılmıştır.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 0.52 + (0.174 \times \text{BMI}) + (0.042 \times \text{AHI}) \quad (2.4)$$

Fitzpatrick ve ark. (2003) yaptıkları çalışmada OSAS'ın tedavisi için laboratuvar da gerçekleştirilen manuel titrasyon ve evde kendi kendine titrasyon arasındaki sonuçları karşılaştırmıştır. Hastanın kendi kendine yaptığı CPAP titrasyonu, Denklem 2.1'de belirtilen Miljeteig ve Hoffstein (1993) tarafından geliştirilen Hoffstein prediktif formülü ile elde edilen optimum CPAP seviyesine dayalı olarak gerçekleştirilmiştir. Yazarlar, bir prediktif formül kullanarak CPAP'ın evde kendi kendine titrasyonunun, laboratuvar da manuel titrasyon kadar etkili olduğunu göstermiştir.

Denklem 2.1'deki Hoffstein formülü dışında, farklı parametrelerden oluşan başka denklemler de Kafkas halkı için geliştirilmiştir. Stradling ve ark. (2004) optimum CPAP seviyesini tahmin edebilmek amacıyla, NC ve oksimetri sinyal parametrelerinden yararlanılmış ve çoklu doğrusal regresyon analizini kullanarak tahmin formülü geliştirmişlerdir (Denklem 2.5). Araştırmacılar formüle dayalı CPAP tahmininin tüm gece manuel titrasyon kadar etkili olabileceğini belirtmişlerdir.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 2.1 + (0.048 \times \%4 \text{ oksimetri dips / h}) + (0.128 \times \text{NC}) \quad (2.5)$$

Denklem 2.6'da görülen ve BMI, NC ve AHI parametrelerini kullanılan bir diğer formül de Rowley ve ark. (2005) tarafından geliştirilmiştir. Çalışmaya Amerika Birleşik Devletleri'nde bulunan kişiler dahil edilmiştir. Çoklu lojistik regresyon analizi kullanılarak Denklem 2.6'da görülen formül üretilmiştir. Araştırmacılar tahmin formülü kullanımının CPAP titrasyon sürecini iyileştirip iyileştirmeyeceği hususu üzerinde durmuşlardır. Araştırmacılar hastaların yalnızca %30'unda tahmin edilen basıncın uzmanların belirlediği optimum seviyelerin ± 3 aralığında bulunduğunu belirtmiş ve CPAP tahmin formülünün titrasyon sürecini iyileştirmede mütevazı bir başarı sağladığını vurgulamışlardır.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = -5.12 + (0.16 \times \text{BMI}) + (0.13 \times \text{NC}) + (0.04 \times \text{AHI}) \quad (2.6)$$

Loredo ve ark. (2007) yaptıkları çalışmada en iyi CPAP tahmin modelinin yalnızca 3 değişken içerdiğini gözlemlemişlerdir. Bu değişkenlerin uyku periyodu sırasındaki solunum rahatsızlık indeksi (RDI), nadir oksihemoglobin saturasyonu (NSAT) ve ortalama oksihemoglobin saturasyonu (MSAT) olduğu belirtilmiştir. Alt küme regresyon analizi kullanılarak elde edilen formül (Denklem 2.7) ile optimum CPAP varyansının %67'si tahmin edilebilmiştir.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 30.8 + (0.03 \times \text{RDI}) - (0.05 \times \text{NSAT}) - (0.2 \times \text{MSAT}) \quad (2.7)$$

El Solh ve ark. (2007), 2007 yılına kadar yapılan çalışmaların genelinde çoklu doğrusal regresyon analizinin tahmin formülü üretmek amacıyla kullanıldığından bahsetmişlerdir. Ancak araştırmacılar, bu analiz ile elde edilen tahmin formüllerinin eksikliklerinin olduğunu da çalışmalarında vurgulamışlardır. Araştırmacılara göre, değişkenler arasında karmaşık ilişkilerin bulunduğu çalışmalarda, doğrusal regresyon ve istatistiksel araçların yerine yapay zeka yöntemlerinden biri olan sinir ağlarının kullanılması daha uygundur. Bu araştırmacılar, sinir ağları içeren bilgisayar analizi ile optimum CPAP seviyesinin daha doğru bir şekilde tahmin edilebileceği hipotezini ileri sürmüşlerdir. Bu hipotezi desteklemek amacıyla yaş, cinsiyet, BMI, NC ve AHI parametrelerinin girdi olarak kabul edildiği 3 katmanlı Genel Regresyon Sinir Ağları (General Regression Neural Networks: GRNN) yapısını tasarlamışlardır. Sinir ağları ile yapılan regresyon sonucunda, hastaların %92'si için tahmin edilen basınç değeri, manuel titrasyon ile belirlenen optimum basıncın ± 3 cmH₂O aralıklarında olmuştur. GRNN, hastaların optimum CPAP seviyelerindeki varyasyonu %85 oranında

karşılamaştır. Çalışmada GRNN yapay zeka yöntemi ile yapılan basınç seviyesi tahmininin regresyon formülleri ile yapılan basınç seviyesi tahmininden daha başarılı olduğu sonucuna varılmıştır.

Yapay zeka yöntemlerinden olan GRNN ile optimum CPAP seviyesinin tahmini ile ilgili El Solh ve ark. (2009) başka bir çalışma daha yapmışlardır. Çalışmaya dâhil edilen 115 OSAS hastası rastgele olacak şekilde 2 gruba dağıtılmıştır. 58 kişilik ilk grup manuel CPAP titrasyonuna tabi tutulurken, 57 kişilik ikinci grup GRNN ile başlangıç basınç seviyesinin tahmin edildiği CPAP titrasyonundan geçirilmiştir. Her iki grup; optimum CPAP seviyesine ulaşma için geçen süre, titrasyon başarısızlığı (tedaviden geri çekilme, artık AHI değerinin >5 olması ve oksimetri sinyal değerinin < %89 olması) ve CPAP terapisi ile gerçekleştirilen tedaviye uyum kriterleri bakımından karşılaştırılmıştır. Karşılaştırma sonucunda; ikinci grupta optimum CPAP seviyesine daha kısa sürede ulaşıldığı ve daha düşük titrasyon başarısızlığı olduğu (%16'ya karşı %36), ayrıca ilk ve ikinci grup hastalarının benzer ölçüde tedaviye uyum sağladığı sonuçlarına ulaşılmıştır.

Choi ve ark. (2010) çalışmalarını farklı bir popülasyon olan Kore halkı üzerinde gerçekleştirmişlerdir. 202 OSAS hastasının optimum CPAP seviyeleri için en etkili parametrelerin BMI ve AHI olduğunu belirtmişler ve adım adım çoklu doğrusal regresyon analizini kullanarak tahmin formülünü üretmişlerdir (Denklem 2.8). Optimum CPAP seviyesindeki varyasyonun %42'si bu formülle açıklanmıştır. Lin ve ark. (2003)'ün Tayvan halkı için üretmiş oldukları tahmin formülü (Denklem 2.4) ile bu çalışmada Kore halkı için üretilen tahmin formülü (Denklem 2.8) büyük ölçüde uyumlu çıkmıştır.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 0.681 + (0.205 \times \text{BMI}) + (0.040 \times \text{AHI}) \quad (2.8)$$

Schiza ve ark. (2011), orta dereceli ve ağır OSAS'a sahip Yunan popülasyonu için, optimum CPAP seviyesini tahmin eden Denklem 2.9'da ve Denklem 2.10'da görülen iki formülü geliştirmişlerdir. Çalışma kapsamında, cinsiyetler arasında CPAP seviyesi bakımından önemli farklılıkların olup olmadığı, etnik kökenin ve sigara içme geçmişinin optimum seviyeyi etkileyip etkilemediği gibi konular üzerinde durulmuştur. Sonuç olarak, optimum CPAP seviyesinin tahmini için BMI, AHI, sigara içme geçmişi (paket / yıl) ve cinsiyet parametrelerini içeren gelişmiş formüller bay ve bayanlar için çoklu doğrusal regresyon analizi aracılığı ile ayrı ayrı oluşturulmuştur. Formüllerden

elde edilen tahmini basınç seviyesinin, hastaların klinikte uzmanlar tarafından titrasyon ile belirlenen optimum basınç seviyesinden yalnızca ± 2 cmH₂O sapma gösterebileceği gözlemlenmiştir. Araştırmacılar geliştirdikleri formül ve Hoffstein formülü (Denklem 2.1) ile elde edilen ortalama optimum basınç seviyelerini karşılaştırmışlardır. Karşılaştırma sonucunda, yeni geliştirilen formüllerin daha doğru tahmin yapabildiği sonucuna varılmıştır.

Erkekler için:

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 5.16 + (0.003 \times \text{sigara içme geçmişi (paket / yıl)}) + (0.054 \times \text{BMI}) + (0.016 \times \text{AHI}) - 0.403 \quad (2.9)$$

Kadınlar için:

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 5.16 + (0.003 \times \text{sigara içme geçmişi (paket / yıl)}) + (0.054 \times \text{BMI}) + (0.016 \times \text{AHI}) - 0.806 \quad (2.10)$$

Basoglu ve Tasbakan (2012), Denklem 2.1'deki Hoffstein formülünün biraz karmaşık olduğunu vurgulamışlardır. Araştırmacılar Türkiye'nin farklı etnik kökenlerden oluştuğunu ifade etmişler ve bu nedenle Türk popülasyonu üzerinde çalışmışlardır. Çalışmada optimum CPAP seviyesini tahmin edebilecek yeni bir formül çoklu doğrusal regresyon analizi kullanılarak geliştirilmiştir. Denklem 2.11'de görülen formülün değişkenleri olarak NC ve ODI değerleri belirlenmiştir. Daha önce yapılan çalışmaların birçoğunda BMI parametresinin kullanıldığı belirtilmiştir. Ancak çalışma kapsamında değinilen önemli bir nokta da şu olmuştur; tüm desaturasyon parametreleri optimum basınç seviyeleri ile BMI'ya göre pozitif yönde daha yüksek bir korelasyona sahiptir. Bu nedenle araştırmacılar çalışmalarında BMI yerine ODI parametresini kullanmışlardır. Çalışmada ayrıca geliştirilen formülün daha önce geliştirilen formüllere göre daha basit yapıda olduğu da ifade edilmiştir. Çalışma sonucunda formül ile tahmin edilen CPAP seviyeleri ve titrasyon ile elde edilenler arasında korelasyon katsayısı (r) 0.65 olan bir ilişki bulunmuştur. Hastaların %96.2'sinde tahmin edilen basınç seviyeleri, optimum basınç seviyelerinin ± 3 cmH₂O aralığında ve %80'inde ± 2 cmH₂O aralığında olmuştur.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = (0.148 \times \text{NC}) + (0.038 \times \text{ODI}) \quad (2.11)$$

Kore popülasyonu için optimum basınç seviyelerinin tahmin edildiği bir başka çalışmada Lee ve ark. (2013) tarafından yapılmıştır. Araştırmacılar Choi ve ark. (2010) tarafından üretilen formülden farklı yeni bir formül türetmişlerdir (Denklem 2.12). Çalışmalarına dâhil ettikleri 356 hastayı, her grupta 178'er kişi olacak şekilde 2 gruba rastgele ayırmışlardır. İlk grupta bulunan hastalar için gerekli basınç seviyeleri; BMI, minimum oksimetri değeri, RDI, epworth uyku puanı (Epworth Sleepiness Score: ESS) parametrelerinden oluşan ve çoklu doğrusal regresyon analizi ile elde edilen Denklem 2.12'deki yeni formül ile tahmin edilmiştir. İkinci grupta bulunan hastalar için gerekli basınç seviyeleri ise Denklem 2.1'deki Hoffstein formülü kullanılarak hesaplanmıştır. Çalışma sonucunda iki formülün tahmin performansı kıyaslanmıştır. Yeni geliştirilen formülün Asya halkına mensup hastalar için optimum basınç seviyelerini tahmin etmede daha iyi olduğu sonucuna ulaşılsa da formülün optimum CPAP seviyelerini tam olarak tahmin edemediği görülmüştür. Bu nedenle tahmin formüllerini kullanmanın klinik ortamlarda kısıtlı fayda sağlayabileceği çalışma sonucunda ifade edilmiştir.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 6.656 \times (0.156 \times \text{BMI}) - (0.071 \times \text{minimum oksimetri}\%) + (0.041 \times \text{RDI}) + (0.094 \times \text{ESS}) \quad (2.12)$$

Lai ve ark. (2015) üst solunum yolları fiziksel yapısının basınç seviye tahmini için etkili olabileceğini savunmuşlardır. Araştırmacılar çalışmalarında yaptıkları korelasyon testi sonucunda, Friedman'ın güncellenmiş dil pozisyonu (uFTP), hiyoid (dil kemiği)-mental mesafesi (HMD) ve AHI parametreleri ile optimum CPAP seviyeleri arasında pozitif yönde önemli bir ilişkinin olduğunu gözlemlemişlerdir. Yaptıkları çalışmada, bu ilişkiye dayalı olarak uFTP, HMD ve AHI parametrelerini içeren bir tahmin formülünü adım adım çoklu doğrusal regresyon analizi ile geliştirilmişlerdir (Denklem 2.13). Çalışma sonucunda, üst solunum yolu yapısı ve hastalık derecesinden oluşan formül ile etkili CPAP seviye tahminin yapılabilmesi vurgulanmıştır.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = (1.01 \times \text{uFTP}) + (0.74 \times \text{HMD}) + (0.059 \times \text{AHI}) - 1.603 \quad (2.13)$$

Wahab ve Ahmed (2017) yaptıkları çalışmada manuel titrasyon sonunda elde edilen optimum CPAP seviyeleri ile yüksek korelasyona sahip parametreleri belirlemişlerdir. Araştırmacılar ESS, NC, boyun çevresi / boy oranı (N/H) ve AHI'nin iyileştirici optimum CPAP seviyesi ile yüksek pozitif korelasyona, minimum ve

ortalama oksimetri sinyal değerlerinin ise aynı CPAP seviyeleri ile negatif yüksek korelasyona sahip olduğunu belirtmişlerdir. Çalışmada kullanılan çoklu doğrusal regresyon analizi sonucunda; N/H ve minimum oksimetri değer parametreleri optimum CPAP seviyelerini en iyi tahmin ediciler olarak belirlenmiş ve tahmin formülünü oluşturmuştur (Denklem 2.14). Çalışmada herhangi bir istatistiksel analiz yapılmamış, tahmin için geliştirilen formüllerin manuel titrasyona veya otomatik CPAP'a alternatif olabileceği belirtilmiştir.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 4.740 + (68.575 \times N / H) - (0.153 \times \text{minimum oksimetri}) \quad (2.14)$$

Ebben ve ark. (2017), CPAP terapisi ile tedavideki maske stilinin optimum CPAP seviyesini etkilediğini belirtmişlerdir. 200 kişi yalnızca burnu kapatan nazal maske, 132 kişi ise hem ağızı hem de burunu kapatan oro-nazal maske kullanarak CPAP titrasyon sürecini geçirmiştir. Bu hastaların maske stillerindeki farklılıklar göz önünde bulundurularak iki grup için de doğrusal regresyon analizi yardımıyla farklı formüller geliştirilmiştir. Nazal maske grubu için AHI, minimum oksimetri değeri ve NC parametreleri tahmin formülünde kullanılırken (Denklem 2.15), oro-nazal maske kullanan grup için tahmin edici parametreler AHI ve minimum oksimetri değeri olarak belirlenmiş ve bu parametrelerden oluşan formül (Denklem 2.16) geliştirilmiştir.

Nazal Maske kullanan grup için;

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = (0.017 \times \text{AHI}) - (0.092 \times \text{minimum oksimetri}) + (0.225 \times \text{NC}) - 5.534 \quad (2.15)$$

Oro-Nazal Maske kullanan grup için;

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = (0.03 \times \text{AHI}) - (0.130 \times \text{minimum oksimetri}) + 19.732 \quad (2.16)$$

Sadeghniaat-Haghighi (2018), İranlı 90 OSAS hastası üzerinde daha önce geliştirilmiş olan Denklem 2.1 'deki Hoffstein formülünü, Denklem 2.7'deki formülü ve Denklem 2.4'deki formülü uygulamışlardır. Araştırmacılar formüller ile üretilen CPAP seviyelerini, klinikte titrasyon ile elde edilen optimum seviyeleri ile karşılaştırmışlardır. Araştırmacılar titrasyon ile elde edilen ortalama CPAP seviyelerinin formüller ile elde edilenden daha yüksek olduğunu belirtmişlerdir. CPAP seviyeleri arasındaki en yüksek

ilişki Denklem 2.4'teki Loredó ve ark. (2007) tarafından geliştirilen formüllerin ürettiği ile titrasyonla elde edilenler arasında korelasyon katsayısı 0.30 olacak şekilde olmuştur.

Yong ve ark. (2018), Malezya ırkına ait 92 OSAS hastasının optimum CPAP seviyesini bulmak için çoklu doğrusal regresyon analizini kullanmış ve Denklem 2.17'de görülen tahmin formülünü üretmişlerdir. Araştırmacılar cinsiyet faktörünün, epworth uyku luluk puanı ve oksimetri değerlerinin hastalar için gerekli olan optimum basınç seviyeleri üzerinde etkisi olduğunu belirtmişlerdir. Çalışma sonucunda, tahmin edilen CPAP seviyeleri ile titrasyon sonucu uzmanların belirlediği optimum CPAP seviyeleri arasındaki ilişki korelasyon katsayısı (r) 0.51 olacak şekilde bulunmuştur. Araştırmacılar ayrıca basınç ihtiyacı 6'nın altında ve 18'in üzerinde olan hastalar için tahmin formülünün zayıf sonuçlar ürettiğinden bahsetmişlerdir.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 13.666 + 2.361(\text{erkek}) + (0.154 \times \text{ESS}) - (0.059 \times \text{Nadir oksimetri (\%)}) \quad (2.17)$$

Kim ve Yang (2018) 162 obezite (BMI>25) OSAS hastası için optimum CPAP tahmin formülü geliştirmişlerdir. Optimum seviyelerin tahmini için hem doğrusal regresyon analizini hem de yapay zeka yöntemlerinden biri olan Rastgele Orman algoritmasını kullanmışlardır. Çalışmada tahmin parametreleri olarak BMI, AHI, ODI ve ortalama oksijen seviyesi değişkenleri kullanılmıştır. Rastgele Orman ile geliştirilen tahmin modelinden elde edilen CPAP seviyeleri ve titrasyon sonucu uzmanların belirlediği optimum CPAP seviyeleri arasında korelasyon katsayısı (r) 0.78 olacak şekilde ilişkili bulunmuştur. Araştırmacılar regresyon analizi ile de Denklem 2.18'de görülen formülü üretmişlerdir. Çalışma sonucunda regresyon ile geliştirilen formülün de Denklem 2.1'de görülen Hoffstein formülüne göre iyileştirilmiş sonuçlar ürettiği belirtilmiştir.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 26.213 + (0.084 \times \text{BMI}) + (0.004 \times \text{AHI}) + (0.004 \times \text{ODI}) - (0.215 \times \text{ortalama oksimetri}) \quad (2.18)$$

Chong ve ark. (2019) çocuk OSAS hastaları üzerinde tedavi amacıyla kullanılabilen CPAP tahmin formülünü çoklu doğrusal regresyon analizi ile geliştirmişlerdir (Denklem 2.19). Üretilen formül çalışmaya dahil edilen çocuk hastaların optimum CPAP seviyelerindeki varyasyonu %30.7 oranında karşılamıştır. Araştırmacılar tahmin formülünün optimum CPAP seviyelerini belirlemede yardımcı

olabileceğini belirtmişlerdir. Bu araştırmacılar 2020 yılında aynı çocuk hastalar için bir çalışma daha gerçekleştirmişler ve Denklem 2.20’de görülen formülü önermişlerdir (Chong ve ark., 2020). Bu formül ile hastaların optimum CPAP seviyelerindeki varyasyon %31.4 oranında karşılanmıştır. Denklem 2.19’daki ve 2.20’deki adenotonsillektomi, bademcik ve geniz eti alınmasını ifade etmektedir.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 4.538 + (0.250 \times \text{yaş}) - (0.549(\text{kız})) - (0.752[\text{adenotonsillektomi yapılmadıysa}]) + (2.125[\text{Down sendromlu ise}]) + (0.040 \times \text{AHI}) + (0.337 \times \text{BMI_zskore}) \quad (2.19)$$

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 6.486 + (0.273 \times \text{yaş}) - (0.664 \times \text{adenotonsillektomi [hayır} = 1, \text{evet} = 0]) + (2.120 \times \text{Down sendromlu[hayır} = 0, \text{evet} = 1]) + (0.280 \times \text{BMI_zskore}) \quad (2.20)$$

Cunha ve ark. (2020) OSAS tedavisinde optimum hava yolu basınç seviyelerini tahmin etmek için kraniyofasiyal (baş ve yüz ölçümleri) özellikleri kullanılmışlar ve Denklem 2.21’de görünen formülü geliştirmişlerdir. Araştırmacılar, uzmanların titrasyonla oluşturduğu optimum CPAP seviyelerinin ortalamasının 8.6 cmH₂O, önerilen denklemi kullanarak bulunan CPAP seviyelerinin ortalamasının 8.9 cmH₂O olduğunu belirtmişlerdir. Çalışma sonucunda, bu değerlerin çok yakın olduğu vurgulanmıştır.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 17.244 - (0.133 \times \text{mandibular length}) + (0.969 \times \text{modified Mallampati score}) - (0.926 \times \text{atlas – jaw distance}) \quad (2.21)$$

Kaynak araştırması sonucunda görülmüştür ki, literatürde gerçekleştirilen çalışmalar genellikle BMI, AHI, NC gibi benzer parametreleri tercih etmişler ve bu parametreleri bazen aynı bazen de farklı popülasyonlar için optimum CPAP seviyelerinin tahmininde değerlendirmişlerdir. Tahmin işlemi için çok az sayıda çalışma birkaç oksimetri sinyal değerini de (minimum ve ortalama oksimetri değeri ve ODI) göz önünde bulundurmıştır (Akashiba ve ark., 2001; Stradling ve ark., 2004; Basoglu ve Tasbakan, 2012; Lee ve ark., 2013; Ebben ve ark., 2017; Wahab ve Ahmed, 2017; Kim ve Yang, 2018; Yong ve ark., 2018). Ancak belli başlı oksimetri sinyal ve indeks değerlerinin dışında oksimetri sinyallerinin farklı özellikleri incelemeye alınmamıştır. Ayrıca kaynak araştırması neticesinde gözlemlenmiştir ki, klinikte OSAS teşhis ve tedavi sürecinde önemli bir role sahip hava akımı sinyal değerlerine, hastaların gece

uyku sırasında geirmiş oldukları apneik ataklara ve ataklara eşlik eden desaturasyonlara ait özellikler hiçbir alıřma da deęerlendirmeye tabi tutulmamıştır. Tüm bunlara ek olarak kaynak araştırması sonucu göstermektedir ki, günümüze kadar gerçekleştirilen alıřmalarda yalnızca El Solh ve ark. (2007), El Solh ve ark. (2009) ve Kim ve Yang (2018) farklı yapay zeka yöntemlerinden (Sinir Ağları ve Rastgele Orman) faydalanmışlar, bu alıřmalar dışındaki tüm alıřmalar optimum CPAP seviyelerinin tahmini için doğrusal regresyon analizlerini kullanmışlardır.



3. TIKAYICI UYKU APNE SENDROMU (OSAS)

Solunumun durması manasına gelen apne, ağız ve burun seviyesinde hava akımının en az 10 sn süre ile durmasıdır (Akdoğan, 2010). AASM (2012) kurallarına göre ise apne, en az 10 sn süre ile hava akımı (solunum) tepe sinyalinde bazala göre %90 veya daha fazla azalma olmasıdır. Hipopne ise 10 sn veya daha fazla süreyle nazal hava akımı sinyalinde bazala göre en az %30'luk azalma ile birlikte kandaki oksijen seviyesinde de en az %3'lük düşme veya arousal gelişimidir (AASM, 2012).

Apne hava akımı ve/veya hastanın solunum çabasının olup olmamasına göre tıkayıcı, santral ve mikst olmak üzere farklı isimlerle adlandırılmaktadır. Tıkayıcı apne, uyku sırasında solunum çabasının devam etmesine rağmen (abdominal ve torasik solunumun sürmesi), ağız ve burunda hava akımının olmamasıdır (Özercan, 2018). Santral Apne, uyku sırasında hem solunum çabasının hem de hava akımının olmaması durumudur (Akdoğan, 2010). Mikst apne ise başlangıçta santral tipte olan apnenin solunum çabasının başlamasına rağmen hava akımı olmaması durumunun devam etmesidir (Akdoğan, 2010). Yani apne başlangıcında solunum çabası yokken devamında solunum çabasının yeniden ortaya çıkmasıdır. Apne tipleri ve hipopne Şekil 3.1'de gösterilmektedir (Külahlı, 2012).

Tıkayıcı Uyku Apne Sendromu (Obstructive Sleep Apnea Syndrome: OSAS) teşhis ve tedavisinde kullanılan temel kavramlar aşağıda kısaca verilmiştir:

Apne İndeksi: Uyku süresi boyunca saatteki ortalama apne sayısıdır.

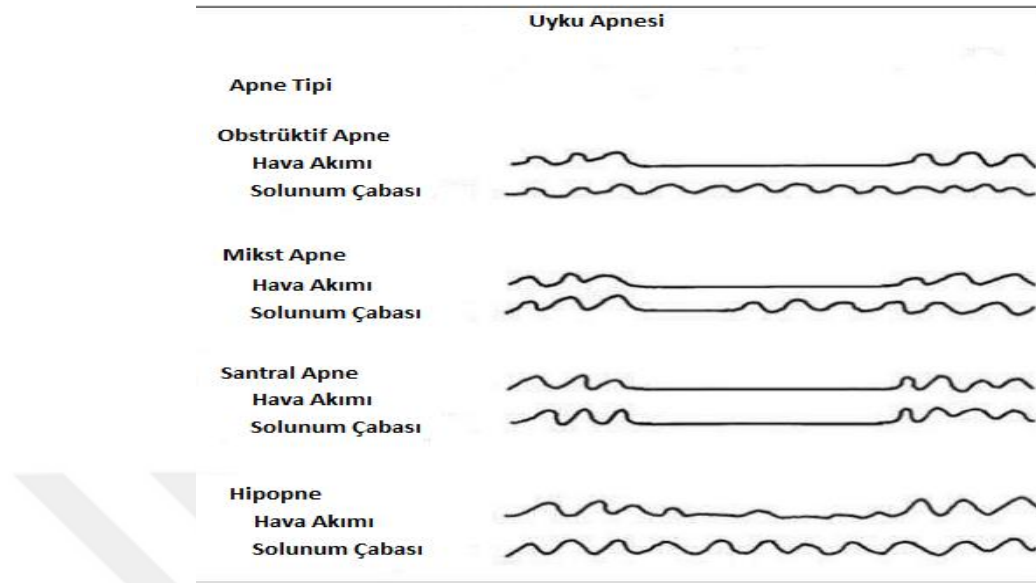
Arousal (Uyanayazma): Anormal solunum paterninin sona ermesini sağlayan, daha hafif daha yüzeysel uyku evresine veya uyanıklık durumuna ani geçişlerdir (Akdoğan, 2010).

Hipopne İndeksi: Uyku süresi boyunca saatteki ortalama hipopne sayısıdır.

Apne-Hipopne İndeksi (AHI): Uyku süresi boyunca oluşan apnelerin ve hipopnelerin saatlik ortalamasıdır. Uykuda görülen toplam apneik atak (apne ve hipopne) sayısının saat olarak uyku süresine bölünmesi ile elde edilmektedir (AASM, 2012).

Oksijen Desaturasyonu: Kandaki oksijen seviyesinin %90'nın altına düşmesidir (AASM, 2012).

Toplam uyku süresi (TST -Total sleep time): Hastanın gece boyunca aralıklı olarak uyandığı zamanlarda çıkarılmak üzere yalnızca uykuda geçirdiği toplam süredir.




Şekil 3.1. Apne tipleri ve hipopne (Külahlı, 2012)

3.1. Polisomnografi ve OSAS Tanısı

Uyku bozukluğu rahatsızlığına sahip olan ve genellikle aşırı gürültülü horlama, uykudan boğulma hissi ile uyanma, yeterince uyunduğu düşünülmesine rağmen sabah yorgun bir şekilde uyanma ve gündüz aşırı uykululuk hali, unutkanlık, dikkat dağınıklığı ve sinirlilik gibi farklı şikayetlerle ilgili kliniğe başvuran kişilerin öncelikle hastalık geçmişi (öyküsü) değerlendirilir. Daha sonra hastalığın gelişimine katkıda bulunan faktörlerin tespiti ve tedavi önerilerinin saptanabilmesi amacıyla kişiler fiziki muayeneden geçirilirler (Özercan, 2018). Üst solunum yolu görüntülenmesi ile OSAS patofizyolojisinin anlaşılması kolaylaşacağı için kişilerin radyolojik incelemesi de gerçekleştirilir (Özercan, 2018). En nihayetinde, kesin tanı için PSG tetkikine ihtiyaç duyulan kişilerin uyku laboratuvarlarında bir gece geçirmesi istenir. Kişiler, vücutlarına kayıt için çeşitli elektrotlar ve sensörler takılarak polisomnografi kaydına hazırlanır ve klinikte uyumaları amacıyla laboratuvarlardaki onların tüm ihtiyaçlarını karşılayacak konforda olan odalara yatırılırlar. Şekil 3.2’de örnek bir PSG kaydı gösterilmektedir (Malalur, 2018).

Uykuda meydana gelen solunum bozukluklarının ve diğer uyku bozukluklarının tespit edilmesinde altın standart tanı yöntemi olarak kullanılan PSG tetkiki, hastaların vücutlarına takılan çeşitli elektrot ve sensörler ile uyku sırasındaki fizyolojik ölçümlerin

(polisomnografi sinyalleri) genellikle gece boyunca, eş zamanlı ve devamlı olarak kaydedilmesi şeklinde tanımlanır (Andrew ve ark., 1997; Akdoğan, 2010). Polisomnografi kaydı için AASM (2012) raporunda bildirilmiş ve ülkemizde de yaygın olarak kabul edilmiş asgari gereksinimlerin temel alınması gerekmektedir. Standart bir PSG ile kayıt altına alınan ölçümler Çizelge 3.1’de verilmektedir (Köktürk, 1999).

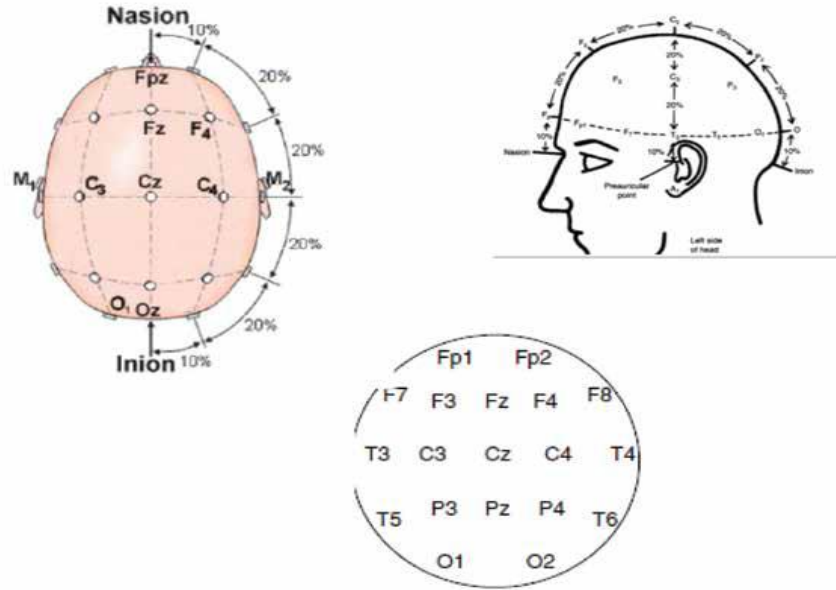


Şekil 3.2. PSG kaydı (Malalur, 2018)

Çizelge 3.1. Standart PSG kaydı ölçümleri

Polisomnografi Sinyalleri
Elektroensefalografi (EEG)
Elektrookülografi (EOG)
Elektromyografi (EMG – submentalis (çene))
Oronazal hava akımı
Abdominal (karın) ve torasik (göğüs) hareketleri
Kandaki oksijen seviyesi (Oksimetri-Oksijen satürasyonu)
Elektrokardiyografi (EKG)
Elektromyografi (EMG – tibialis (bacak kası))
Vücut pozisyonu
Horlama

EEG kaydı için elektrotlarının yerleştirileceği noktalar uluslararası 10–20 prosedürüne göre belirlenir. EEG için temel olarak 3 derivasyon önerilir: F4-M1, C4-M1, O2-M1 (AASM, 2012). Olası bir problem için F3-M2, C3-M2, O1-M2 derivasyonları da yedek olarak bağlanmalıdır (AASM, 2012). Bu derivasyonlar, gecenin herhangi bir zamanında hastanın uyku evresini belirlemek için kullanılmaktadır. Şekil 3.3, 10-20 prosedürüne göre elektrotların yerlerini göstermektedir (Demir ve ark., 2012).



Şekil 3.3. 10-20 sistemine göre EEG elektrotlarının yerleri (Demir ve ark., 2012)

EOG kaydı için E1 elektrodu aşağıya ve sol gözün dışına ve E2 elektrodu yukarıya ve sağ gözün dışına yerleştirilir (Demir ve ark., 2012; Yücelbaş, 2017a). Bu elektrotlar uyku sırasında göz hareketlerini kaydeder ve uyku evrelerini belirlemeye yardımcı olurlar.

EMG kaydı yapılmak üzere üç elektrot çeneye ve iki elektrotta her bir baldırın 2-4 cm dışına yerleştirilir (Yücelbaş, 2017a). Bu elektrotlar sayesinde uyku sırasındaki kas hareketleri elde edilir ve kas tonusuna bakılarak kişilerin gece boyunca uyku ve uyanıklık kararı verilir.

EKG kaydı için elektrotlar kalp ritmini kaydetmek üzere sağ ve sol kollara yakın göğsün üstüne yerleştirilir (Yücelbaş, 2017b).

Solunumun izlenebilmesi için solunum çabası (abdominal ve torasik hareketler), hava akımı ölçerler ve pulse oksimetre kullanılır (Özercan, 2018). Hava akımı sinyalini ölçmek amacıyla oronazal termistör ve nazal kanül tercih edilir. Termistör hava akımındaki ısı değişikliklerini kaydeder. Nefes alınan (inspire edilen) hava soğuk, nefes verilen (ekspire edilen) hava sıcaktır. Termistörün ısınıp soğuması rezistansta artma ve azalmaya neden olarak hava akımının sinyal şekline dönüşmesine yol açar, böylece hava akım kaydı elde edilir (Kanbay, 2013). Ancak termistör ortam sıcaklığından etkilendiği için kayıt sırasında sorunla karşılaşılabilir. Nazal kanül, burun içi basıncı ölçerek hava akımı sinyalini oluşturur. Burun deliklerine yerleştirilir ve ucunda basınç ölçer bulunur. Nazal kanül, termistörden daha hassastır. Harekete duyarlı sensör taşıyan kemer, toraks için göğüs kemiği ortasından, abdomen için ise göbeğin hemen üstünden

bağlanarak solunum çabası sinyallerini oluşturur (Özercan, 2018). Horlama kaydı ise trakea üstüne mikrofon konularak gerçekleştirilir (Demir ve ark., 2012). Kişilerin yatış pozisyonlarının belirlenmesi amacıyla sensör toraks veya abdomen kemerine monte edilir veya bazı cihazlarda kişilerin üstüne takılan bağlantı kutusu üzerine yerleştirilir. Kaydı alınan kişinin sırt üstü mü, yan pozisyonda mı olduğu belirlenerek kaydedilir. Oksimetri sinyalinin ölçümü için parmak ya da kulak memesi sensörü kullanılmaktadır. Tüm gerekli elektrotlar kişiye bağlandıktan sonra elektrot kabloları bağlantı kutusuna takılır. Ardından kişilerin tüm gece PSG tetkiki ile polisomnografi kayıtları gerçekleştirilir. Bir gecelik PSG tetkiki sonunda aşağıda belirtilen AASM (AASM, 2012) kurallarına uygun olarak, uyku uzmanları tarafından kişilerin uyku sırasında geçirmiş oldukları apneik ataklar (apne ve hipopne) tespit edilir.

AASM (2012) skorlama kılavuzuna göre aşağıdaki kriterlerin varlığı apne skorlamak için yeterlidir.

- I. Hava akımı tepe sinyalinde en az %90'lık azalma olmalı
- II. Bu azalma en az 10 sn sürmeli

AASM (2012)'nin skorlama kılavuzuna göre aşağıdaki kriterlerin varlığı hipopne skorlamak için yeterlidir.

- I. Hava akımı tepe sinyalinde en az %30 azalma olmalı
- II. Bu azalma en az 10 sn sürmeli
- III. Solunumsal olay öncesine göre en az %3 oksijen desaturasyonu veya arousal olmalı

Son olarak tespit edilen apneik atakların (apnelerin ve hipopnelerin) toplam sayısının toplam uyku süresine bölünmesi ile AHI değerleri hesaplanır ve bu değerlere göre AASM (2012) kriterlerince kişilerin OSAS hastası olup olmadığı, hasta iseler hastalığın ağırlık derecesinin ne olduğu ve CPAP terapisi ile tedaviye ihtiyaç duyup duymadıkları belirlenir. AASM (2012)'ye göre OSAS hastalarının ağırlık derecelerinin sınıflandırılması Çizelge 3.2'de gösterildiği şekilde yapılmaktadır.

Çizelge 3.2. AHI'ye göre OSAS sınıflaması

AHI Değer Aralıkları (AHI Alt Grupları)	Ağırlık Derecesi
AHI < 5	Sağlıklı Birey
$5 \leq \text{AHI} < 15$	Hafif OSAS
$15 \leq \text{AHI} < 30$	Orta OSAS
$30 \leq \text{AHI}$	Ağır OSAS

3.2. Sürekli Pozitif Havayolu Basıncı (CPAP)

OSAS'tan muzdarip kişilerin tedavisi için ilk olarak genel önlemlerin (yatış pozisyonu ayarlama, kilo verme, alkolden sakınma, sedatiflerden uzak durma, eşlik eden diğer hastalıkların tedavisi vb.) alınması beklenir (Demir ve ark., 2012). Tedavi de ikinci adım olarak ise Kulak Burun Boğaz (KBB) konsültasyonu istenir ve üst solunum yolunda tıkanmaya neden olan patolojilerin ve varsa cerrahi tedavi endikasyonunun belirlenmesi sağlanır. Ancak, solunum ve solunum olayları ile ilgili araştırma ve çalışmalar yapan önemli kuruluşlardan biri olan Avrupa Solunum Derneği tarafından OSAS cerrahisinde bugüne kadar uygulanan cerrahi müdahalelerin çoğunun yetersiz kaldığı ve bazı özel durumlar dışında cerrahi tedavinin yerinin “düzeltici cerrahi” ile sınırlı kaldığı bildirilmiştir (Demir ve ark., 2012). Bu nedenle OSAS rahatsızlığının tedavisinde çoğunlukla üst solunum yolunun uykuda açık kalmasını sağlayacak özel terapiler uygulanmaktadır.


Pozitif Havayolu Basıncı (Positive Airway Pressure: PAP) terapileri, OSAS için altın standart tedavi yöntemleridir. Esas olarak orta ve ağır dereceli OSAS'lı olgularda ($AHI \geq 15$) standart olarak önerilmekle beraber, hafif dereceli bile olsa ($AHI:5-15$), semptomları belirgin ve/veya kardiyovasküler, serebrovasküler risk faktörleri olan olgularda da PAP terapileri ile tedavi önerilmektedir (CMS, 2005; Demir ve ark., 2012).

Uyku sırasındaki solunum bozukluklarının tedavisinde kullanılan tüm PAP terapilerinde amaç; üst solunum yolunun uykuda açık kalmasını sağlamak, solunumu ve uyku kalitesini düzenlemektir. PAP terapileri ile tedavi, basınçlı hava üreten bir pompa, hastanın burnuna yerleştirilen ya da burun ve ağızı tamamen içine alan yumuşak silikon bir maske ve hortumdan oluşan cihazlarla gerçekleştirilir. Cihazların üst solunum yolu kasları üzerine herhangi bir etkisi olmamaktadır. PAP cihazları sadece kullanıldığı sürece “iyileştirici cihaz” etkisi göstermektedir. Bu nedenle PAP terapileri ile gerçekleştirilen tedavilerinin hastalığı tamamen tedavi edici etkisi olmamaktadır (Strohl ve Redline, 1986). Hastalar cihazı kullandığı süre boyunca tedaviden fayda görmektedirler. Bu konuda genel kabul gören prensip hastanın tüm kullanım süresinin %70'den fazla olması ve kullandığı gecede en az 4 saat kullanılmasıdır (Engleman ve Wild, 2003; Demir ve ark., 2012). Özellikle, hastaların cihazları ilk 1-3 ay içinde kullanımı ile cihaza daha adapte oldukları bildirilmiştir (Demir ve ark., 2012).

Sürekli pozitif havayolu basınç (Continuous Positive Airway Pressure: CPAP), otomatik CPAP (auto CPAP / APAP) ve iki seviye pozitif havayolu basınç (Bi Level

Positive Airway Pressure: BPAP) olmak üzere 3 farklı PAP terapi tekniği bulunmaktadır. CPAP ile tedavide, hastaların üst solunum yoluna sabit pozitif bir basınç iletilir ve bu basınç ile hastaların üst solunum yolunun açık kalması sağlanır. APAP ile tedavide; hava akımı amplitüd değişikliklerine, hava akım limitasyonlarına, horlama varlığına ve/veya havayolu impedansındaki değişikliklere göre basınç artışı ve azalması gerçekleştirilir (Berry ve ark., 2002). BPAP terapisi ile tedavide de CPAP'ta olduğu gibi hastalara sabit pozitif bir basınç verilir. Ancak BPAP'ın en önemli farkı; solunum döngüsü boyunca inspirasyon ve ekspirasyonda farklı sabit basınçta hava verilmesidir.

Üç PAP terapisi arasında ilk tercih edilen ve standart olan tedavi yöntemi CPAP'tır. CPAP terapisi ile sağlanan yüksek basınçları tolere edemeyen, tedaviye uyum sorunu olan veya basınç gereksinimi değişken (REM veya pozisyon ilişkili OSAS gibi) olan hastalarda sıklıkla APAP terapisine başvurulur. Ayas ve ark. (2004), APAP kullanımında ortalama etkin basıncın daha düşük olduğunu, ancak tedavide uyumluluk ve uykululuk halinin devamında sabit basınçlı CPAP terapilerine göre bir fark olmadığını bildirmişlerdir. Bununla birlikte, Lee ve ark. (2013)'na göre de klinisyenler kalp yetmezliği, önemli akciğer hastalığı veya obezite hipoventilasyon sendromu gibi rahatsızlıkları olan bazı hastalarda APAP terapisinden kaçınılması gerektiğini söylemişlerdir. BPAP terapisi de OSAS tedavisinde ilk seçenek değildir, ancak CPAP terapisi ile gerçekleştirilen tedaviyi tolere edemeyen, yüksek basınca karşı nefes vermekte zorlanan, ek olarak alveoler hipoventilasyona neden olan bir hastalığı olanlar için seçenek olarak düşünülmektedir (Demir ve ark., 2012). Şekil 3.4 üç farklı PAP terapisine ait gece boyunca geçerli olan basınç seviyelerini göstermektedir (d'Ortho ve ark., 2016).



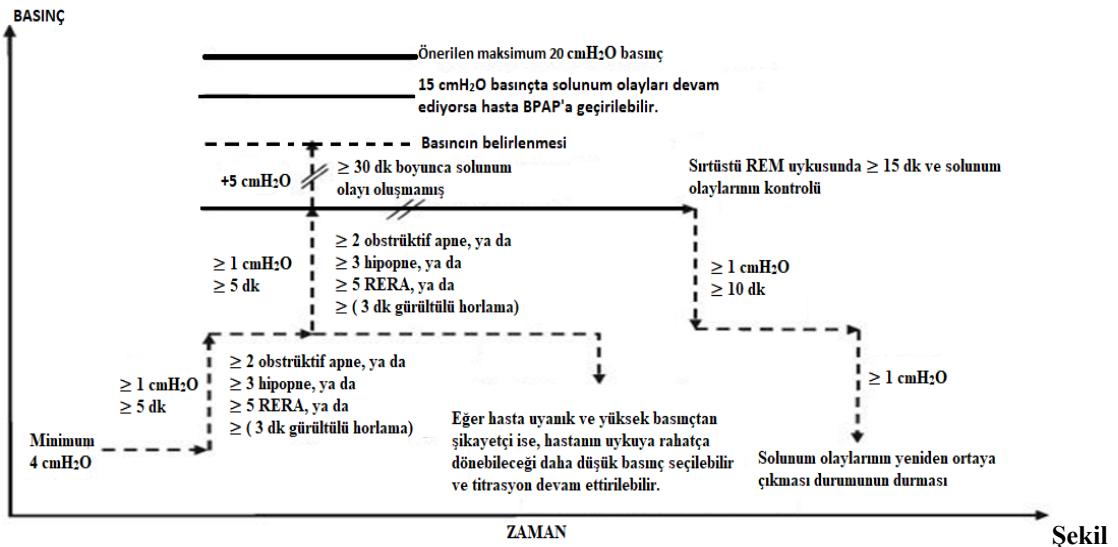
Şekil 3.4. PAP terapileri basınç seviyeleri (d'Ortho ve ark., 2016)

CPAP cihazları ile gerçekleştirilen CPAP terapisinde, oda havası sıkıştırılarak belirlenen basınçta bir hava oluşturulur. Cihazların oluşturduğu pozitif sabit basınç, düşük dirençli bir hortum ve hastanın burnuna veya hem ağız hem de burnuna bağlanan bir maske aracılığı ile hastaya iletilir ve bu sayede hastanın üst hava yolunun açık kalmasını sağlar. Şekil 3.5, OSAS için CPAP terapisi ile gerçekleştirilen tedaviyi göstermektedir.



Şekil 3.5. CPAP terapisi ile tedavi

OSAS tanısı konulan ve CPAP terapisi ile tedavi edileceği belirlenen hastalara ya tanı gecesinin diğer yarısında (yarı gece - split night) ya da bir başka gece (tüm gece) tedavi için genellikle klasik manuel CPAP titrasyonu uygulanır. Basınç titrasyonuna 4 cmH₂O ile başlanır ve Şekil 3.6'da görülen algoritmaya göre maksimum 20 cmH₂O ya kadar basınç artırımı gerçekleştirilir (Kushida ve ark., 2008). Titrasyon işlemi sonucunda, hastaların tüm solunum problemlerini ortadan kaldıracak şekilde AHI değerini saatte 5'in altına düşüren, oksijen saturasyonunu %90'ın üzerine çıkaran ve horlamayı ortadan kaldıran minimum basınç seviyesi optimum basınç olarak belirlenir ve OSAS hastalarının kullanması için belirlenen seviyede ki CPAP cihazı raporlanır.



Şekil

3.6. CPAP titrasyon algoritması (Kushida ve ark., 2008)

4. MATERYAL VE YÖNTEM


OSAS şüphesi ile Konya Necmettin Erbakan Üniversitesi, Meram Tıp Fakültesi, Göğüs Hastalıkları Anabilim Dalı, Uyku Kliniğine başvuran kişiler bu tez çalışmasına dahil edilmiştir. Kişilerin OSAS teşhisi için kliniğin uyku laboratuvarına yatırılması ile PSG tetkikleri uzmanlar tarafından gerçekleştirilmiş ve tüm gece polisomnografi sinyal kayıtları elde edilmiştir. Bu kayıtlardan olan nazal kanül hava akımı ve oksimetri sinyalleri, kişilerin demografik ve antropometrik bilgileri ve kişilerin gece boyunca geçirmiş olduğu apneik atakları ve desaturasyonları göz önünde bulundurularak oluşturulan farklı özellik setlerinin kullanılması ile hastaların tedavisi için gerekli olan optimum CPAP seviyelerinin tahmini gerçekleştirilmiş ve CPAP tahmin modelleri geliştirilmiştir. Şekil 4.1 çalışmada gerçekleştirilen işlemlerin genel blok şemasını göstermektedir.

Tez çalışmasının ilk adımında, çalışmaya dahil edilen kişilerin uyku laboratuvarına yatırımları ile tüm gece PSG tetkikleri gerçekleştirilmiş ve polisomnografi sinyalleri kaydedilmiştir. Ardından kişilerin polisomnografi kayıtları, OSAS teşhisi ve tedavisi ile ilgili bilgileri içeren raporlar uyku uzmanı tarafından hazırlanmıştır.

İkinci adımda, elde edilen polisomnografi sinyalleri arasından çalışmanın amacına uygun olarak yalnızca nazal kanül hava akımı ve oksimetri sinyalleri değerlendirmeye alınmış, bu sinyaller gereksiz bileşenlerden ve gürültülerden arındırılmak üzere filtreleme ve normalizasyon ön işlemlerinden geçirilmiştir.

Üçüncü adımda, ön işlemlerden geçirilmiş hava akımı sinyallerinin çokfraktallı eğimden arındırılmış dalgalanma analizi ile doğrusal olmayan özellikleri çıkarılarak, çalışmaya dahil edilen kişilerin OSAS hastası olup olmadığının belirlenmesi ve tedavi için CPAP terapisine ihtiyaç duyup duymadıklarının tespit edilmesi sağlanmıştır. Ayrıca bu adımda, farklı bir yaklaşımla da, uyku uzmanlarının kliniklerde klasik olarak yaptığı gibi, kişilerin gece boyunca geçirdikleri apneik atak sayısına göre AHI hesabına dayanan OSAS teşhisleri gerçekleştirilmiş ve CPAP terapisine ile tedavi gereklilikleri belirlenmiştir. Çalışmaya dahil edilen kişilere ait ön işlemlerden geçirilen hava akımı ve oksimetri sinyallerinin kullanılmasıyla belirli kurallara dayalı olarak geliştirilen algoritma ile hastaların gece boyunca geçirmiş oldukları apneik ataklar otomatik olarak tespit edilmiştir. Ayrıca geliştirilen algoritmada ataklara eşlik eden oksijen desaturasyonlarının varlığı araştırılmış ve oluşan desaturasyonlar da ortaya çıkarılmıştır.

Tespit edilen ataklara göre AHI deęerleri hesaplanmıř ve bu deęerlere gre kiřilerin OSAS teřhisi gerekleřtirilerek CPAP terapisi ile tedavi edilmeye ihtiya duyup duymadıkları belirlenmiřtir.



řekil 4.1. Tez alıřması genel blok řeması

alıřmanın drdnc adımımda, CPAP terapisine ihtiya duyan hastalar iin CPAP cihazları tarafından saęlanacak olan optimum CPAP seviyeleri tahmin edilmiř ve CPAP tahmin modelleri geliřtirilmiřtir. Bu amala ncelikle farklı yntemlerle 4 zellik seti oluřturulmuřtur. Ardından, farklı zellik setlerindeki zellikler arasından optimum

CPAP seviyeleri üzerinde etkisi en fazla olanların seçimi gerçekleştirilmiştir. Son olarak hem tüm özelliklerin hem de etkin olarak seçilen özelliklerin doğrusal regresyon analizleri ve farklı yapay zeka yöntemleri ile kullanılmasıyla hastalara ait optimum CPAP seviyeleri tahmin edilmiş ve yüksek tahmin performansı sağlayan özelliklerin ve yöntemlerin oluşturduğu CPAP tahmin modelleri geliştirilmiştir.

4.1. Polisomnografi Kayıtlarının Elde Edilmesi

OSAS şüpesi ile Necmettin Erbakan Üniversitesi, Meram Tıp Fakültesi, Göğüs Hastalıkları Anabilim Dalı, Uyku Kliniğine başvuran Türk popülasyonuna ait kişilerin hastalık geçmişi ve şikayetleri dinlendikten sonra uyku uzmanları tarafından gerekli görülen 145'i, Selçuk Üniversitesi Tıp Fakültesinden 11.10.2017 tarihli Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Toplantısı ile alınan 2017/287 sayılı etik kurul onayı ile tez çalışmasına dahil edilmiştir (Etik kurul onayı EK-1'de sunulmuştur). Kişilerin yaş, cinsiyet ve BMI bilgileri öğrenilerek her kişiye ait bir rapor hazırlanmıştır. Daha sonra bu kişiler uzmanlar tarafından uygun görülen tarihte klinikteki uyku laboratuvarında bir gece geçirmişlerdir. Uyku uzmanları eşliğinde kişilerin tüm gece PSG tetkikleri gerçekleştirilmiş ve polisomnografi kayıtları .edf uzantılı dosyalar formatında daha sonra kullanılmak üzere kaydedilmiştir. Kayıtları alınan kişilere ait ayrıntılı bilgiler Çizelge 4.1'de verilmiştir.

Çizelge 4.1. Polisomnografi kaydı alınan hastalara ait bilgiler

AHI Aralığı (OSAS Derecesi)	Kişi Sayısı	Yaş	BMI	AHI	Kayıt Süresi (saat)
AHI < 5	33	48.3 ± 12.1	31.3 ± 5.95	1.78 ± 1.24	4.5 ± 1.3
5 ≤ AHI < 15	33	51.6 ± 11.8	33.4 ± 6.4	9.0 ± 3.3	5.06 ± 1.5
15 ≤ AHI	79	50.4 ± 14.1	33.6 ± 7.3	57.1 ± 32.8	4.19 ± 1.7

Tüm gece boyunca kaydedilen polisomnografi kayıtları ertesi gün uyku uzmanları tarafından değerlendirilmiş ve uzmanlar AASM (2012) kriterlerine göre uykuyu ve uyku ile ilişkili olayları skorlamışlardır. Buna göre; çalışmaya dahil edilen kişilerin gece boyunca her 30 sn'de bir hangi uyku evresinde oldukları (Uyanık, N1, N2, N3, REM), toplam uyku süreleri, gece boyunca geçirmiş oldukları tüm apneik atakları (apne, hipopne), arousalları ve oksijen desaturasyonları uyku uzmanları tarafından skorlanarak hazırlanan rapora eklenmiştir. Daha sonra apneik atak ve

toplam uyku süreleri kullanılarak hesaplanan AHI değerlerine göre bu kişilerin 112'sine OSAS teşhisi konulmuş, 33'ü ise sağlıklı bulunmuştur. Ayrıca 112 hastanın 80'i için de uzmanlar tarafından CPAP terapisi ile tedavi gereklidir kararı verilmiştir. Uyku uzmanları tarafından klinikte hesaplanan AHI değerleri tez çalışmasında referans AHI değerleri olarak değerlendirilmiştir.

Uzmanların OSAS teşhisi koyduğu ve CPAP terapisi gerekiyor olarak tanımladığı 80 hasta, manuel CPAP titrasyonlarının gerçekleştirilmesi için başka bir gecelerini daha kliniğin uyku laboratuvarında geçirmiştir. Laboratuvar ortamında uyku uzmanları tarafından gerçekleştirilen titrasyon işlemiyle hastaların tedavisi için gerekli olan ve CPAP cihazları tarafından hastaların üst solunum yollarına iletilecek optimum CPAP seviyeleri belirlenmiştir. Uzmanlar tarafından belirlenen bu CPAP seviyeleri, gerçekleştirilen tez çalışması kapsamında referans optimum CPAP seviyeleri olarak kabul edilmiştir.

4.2. Polisomnografi Kayıtları Üzerinde Gerçekleştirilen Ön İşlemler

Tez çalışması kapsamında gerçekleştirilecek çalışmalardan önce, PSG cihazı ile kaydedilen polisomnografi kayıtları üzerinde çalışılabilmek üzere aşağıdaki gibi hazırlanmıştır.

Gerçekleştirilen çalışmanın amacına uygun olarak, 145 kişiden alınmış polisomnografi kayıtları arasından tüm solunum olaylarını hassas bir şekilde yansıtan 100 Hz örnekleme frekanslı nazal kanül hava akımı ve 1 Hz örnekleme frekanslı oksimetri sinyalleri değerlendirmeye alınmıştır. EDFtoASCII çevirici (convertor) adlı arayüz programı ile her bir kişinin ayrı ayrı hava akımı ve oksimetri sinyalleri .ascii uzantısına dönüştürülerek kaydedilmiştir. Daha sonra MATLAB R2019b yazılımının hazırlanan sinyalleri okuyabilmesi için .ascii uzantılı her bir sinyal dosyasının uzantısı .data olarak değiştirilmiştir. Böylelikle PSG cihazından alınan kayıtlar, üzerinde çalışılabilecek formata dönüştürülmüştür.

Çalışılacak formata getirilmiş hava akımı sinyallerindeki gürültülerin yok edilebilmesi amacıyla hava akımı sinyalleri 0.01–0.7 Hz frekans aralığında 3. dereceden Butterworth bant geçiren filtre ile filtrelenmiştir. Oksimetri sinyallerinde ise 50 oksijen değerinin altında bulunan oksimetri değerleri gürültü olarak kabul edilmiş ve bu değerler elimine edilmiştir.

Uzun süreli hava akımı sinyalleri sensörlerden, hastaların vücut pozisyonlarından, hastaların gece boyunca hareketlerinden etkilenebilir ve bundan dolayı hava akımı sinyallerinin değerleri ve genlikleri gece boyunca sürekli değişebilir. Bu nedenle çalışmaya dahil edilen kişilerin filtrelenmiş hava akımı sinyalleri, Tian ve Liu (2005) ve Choi ve ark. (2018) tarafından önerilen adaptif normalizasyon yöntemi ile normalize edilmiştir. Adaptif normalizasyonda, filtrelenen hava akımı sinyallerinin her 1 sn'si için alan ($a(k)$) ve standart sapma ($std(k)$) bilgileri sırasıyla Denklem 4.1 ve 4.2 ile hesaplanmıştır (Choi ve ark., 2018). Daha sonra, normalizasyon faktörü ($F_{Norm}(k)$) Denklem 4.3 kullanılarak belirlenmiş ve Denklem 4.4'teki gibi sinyallerin normalizasyon faktörüne bölünmesiyle normalleştirilmiş sinyaller elde edilmiştir (Choi ve ark., 2018). Adaptif normalizasyon faktörü, Denklem 4.3'de görüldüğü gibi, yeni 1 sn'lik hava akımı sinyal parametrelerinin %5'i ve önceki faktör değerinin %95'i kullanılarak hesaplanmıştır. Adaptif normalizasyon faktörünün ilk değerinin hesaplanmasında ise önceki faktör değeri mevcut olamayacağı için o değer 0 olarak kabul edilmiş ve yalnızca 1 sn'lik hava akımı sinyal parametrelerinin %5'lerinin minimumu alınarak ilk faktör değeri belirlenmiştir. Denklemlerdeki x ; hava akımı sinyalini, f_s ; 1 saniyedeki örnek sayısını, $x'(k)$; 1 saniyedeki sinyal değerlerinin ortalamasını belirtmektedir.

$$a(k) = \frac{1}{f_s} \sum_{i=k*f_s}^{(k+1)*f_s-1} abs(x(i)) \quad (4.1)$$

$$std(k) = \sqrt{\frac{1}{f_s - 1} \sum_{i=k*f_s}^{(k+1)*f_s-1} (x(i) - x'(k))^2} \quad (4.2)$$

$$F_{Norm}(k) = \min\{0.95F_{Norm}(k-1) + 0.05a(k), 0.95F_{Norm}(k-1) + 0.05std(k)\} \quad (4.3)$$

$$X_{Norm}(k) = \frac{x(k)}{F_{Norm}} \quad (4.4)$$

Ön işlemler adımı oksimetri sinyal değerleri üzerinde herhangi bir normalizasyon işlemi gerçekleştirilmemiştir.

4.3. Özellik Çıkarma Yöntemleri

Bu tez çalışması kapsamında hava akımı sinyallerine ve oksimetri sinyallerine ait etkin özelliklerin belirlenmesi amacıyla farklı özellik çıkarma yöntemleri kullanılmıştır.

4.3.1. Çokfraktallı eğimden arındırılmış dalgalanma analizi (MDFA)

Peng ve ark. (1995), DNA dizilerindeki benzerlik ve korelasyonu analiz etmek için Eğimden Arındırılmış Dalgalanma Analizi (Detrended Fluctuation Analysis: DFA) yöntemini önermiştir. O zamandan bu yana, bu yöntem finansal piyasa analizi (Di Matteo ve ark., 2003), biyomedikal zaman serilerinin analizi ve anormal durumların tespiti (Barbi ve ark., 1998; Vaquerizo-Villar ve ark., 2018), doğal ve sosyal olaylar (Chattopadhyay ve Chattopadhyay, 2014) gibi birçok alanda durağan olmayan zaman serilerindeki mono-fraktal ölçekleme özelliklerini belirlemek için sıklıkla kullanılmaktadır. Ancak biyomedikal sinyallerin de içinde bulunduğu birçok zaman serisi mono-fraktal bir yapı sergileyebilir (Kantelhardt ve ark., 2002). Özellikle biyomedikal sinyaller geçici varyasyonlar ve düzensiz dalgalanmalar sergileyebilir. Bu varyasyon ve dalgalanmalar DFA yönteminin sağladığı tek bir ölçekle açıklanamaz ve çoklu fraktal bir yapıya uygundur. Bu nedenle, Kantelhardt ve ark. (2002), DFA yönteminin gelişmiş versiyonu olan Çokfraktallı Eğimden Arındırılmış Dalgalanma Analizi (Multifractal Detrended Fluctuation Analysis: MDFA) yöntemini ortaya çıkararak DFA'nın kısıtlarını ortadan kaldırmıştır.

MDFA aşağıdaki adımlar takip edilerek uygulanır (Márton ve ark., 2014; Erdoğan, 2017; Bose ve ark., 2019) .

- ✓ Denklem 4.5'te görüldüğü gibi zaman serisinin ortalaması alınır.

$$\overline{X_{Norm}} = \frac{1}{N} \sum_{i=1}^N X_{Norm}(i) \quad (4.5)$$

Denklemdaki zaman serisi (X_{NORM}), adaptif normalleştirilmiş sinyali belirtmektedir.

- ✓ Serideki her bir değerden ortalama değer çıkarılır ve elde edilen farkların toplanması ile birleştirilmiş zaman serisi hesaplanır (Denklem 4.6).

$$Y_i = \sum_{i=1}^N X_{Norm(i)} - \overline{X_{Norm(i)}} \quad (4.6)$$

- ✓ Birleştirilmiş zaman serisi (Y_i) eşit uzunlukta alt aralıklara bölünür. Serinin uzunluğuna bağlı olarak L>0 olmak üzere her bir aralık N_L=tamdeğer (N/L) değerden oluşur. N'nin büyüklüğü genelde ele alınan L ölçeğinin bir katı olmadığından aynı bölme yöntemi serinin bazı kısımlarını dikkate almak için karşı kısmından başlayarak tekrar eder. Böylece tamamen 2N_L parça elde edilmiş olur.
- ✓ Her bir alt aralıkta en küçük kareler yöntemine göre yerel regresyon yapılır. Yerel eğilimin ortadan kaldırılarak varyansın belirlenmesi Denklem 4.7 ve Denklem 4.8'deki gibi gerçekleştirilir.

$$f^2(L,v) = \frac{1}{L} \sum_{i=1}^L \{Y[(v-1)L+i] - p_v(i)\}^2 \text{ for } v = 1, \dots, N_L \quad (4.7)$$

ve

$$f^2(L,v) = \frac{1}{L} \sum_{i=1}^L \{Y[N-(v-N_L)L+i] - p_v(i)\}^2 \text{ for } v = N_L + 1, \dots, 2N_L \quad (4.8)$$

Denklem 4.7'deki p_v(i) değeri v bölümü içindeki m. mertebeden bir polinom fonksiyonudur.

- ✓ Her bir aralıkta q. merteben dalgalanma fonksiyonu elde edilir (Denklem 4.9 ve Denklem 4.10).

$$f_q(L) = \left\{ \frac{1}{2N_L} \sum_{v=1}^{2N_L} [f^2(L,v)]^{0.5q} \right\}^{1/q} \quad q \neq 0 \quad (4.9)$$

$$f_0(L) = \exp \left\{ \frac{1}{4N_L} \sum_{v=1}^{2N_L} \ln [f^2(L,v)] \right\} \quad q = 0 \quad (4.10)$$

- ✓ Her q değeri için L 'ye karşılık $f_q(L)$ 'nin log-log grafiği analiz edilerek dalgalanma fonksiyonlarının ölçekleme davranışı belirlenir. $f_q(L)$ ise $L^{h(q)}$ orantılıdır. Bu ilişki Denklem 4.11'deki gibi ifade edilebilir.

$$f_q(L) \propto KL^{h(q)} (*) \quad (4.11)$$

Burada $h(q)$ genelleştirilmiş Hurst üstelini belirtir. Denklem 4.11, her iki tarafının logaritmaları aldıktan sonra Deklem 4.12'de görüldüğü biçimde yazılabilir.

$$\log F_q(L) = \log K + h(q) \log L \quad (4.12)$$

- ✓ Tek bir üstel tarafından ifade edilen mono fraktal zaman serileri için $h(q)$ değeri q değerinden bağımsızdır. Çoklu fraktal zaman serilerinde ise Hurst üsteli $h(q)$, q değerine bağlı olarak değişim gösterir. Küçük ve büyük dalgalanmaların farklı biçimde ölçeklenmesi sonucunda q değerine göre $h(q)$ 'da anlamlı bir bağımlılık elde edilir. Bu nedenle q 'nun pozitif değerleri için ölçekleme üsteli $h(q)$ büyük dalgalanmalar, q 'nun negatif değerleri için ise küçük dalgalanmaları tanımlar.
- ✓ Zaman serilerindeki çoklu fraktallığın doğrulanmasının diğer bir yolu ise elde edilen genelleştirilmiş Hurst üsteli $h(q)$ ve Renyi üsteli $\tau(q)$ arasındaki ilişkiye dayalı olan çokfraktallı spektrum analizinin uygulanmasıdır. $\tau(q)$ ile $h(q)$ arasındaki ilişki Denklem 4.13'deki gibidir.

$$\tau(q) = q h(q) - 1 \quad (4.13)$$

- ✓ Mono fraktal zaman serileri tek bir Hurst üsteli ile karakterize edilebilirken, çok fraktallı zaman serileri genellikle birden fazla Hurst üsteli ile karakterize edilir ve $\tau(q)$ doğrusal olarak q 'ya bağlıdır. Legendre dönüşümü kullanarak, tekilli üsteli ve tekillik spektrumu sırasıyla Denklem 4.14 ve Denklem 4.15 aracılığıyla $\tau(q)$ ile ilişkilendirilir.

$$\alpha = \frac{d\tau}{dq} \quad (4.14)$$

$$F\alpha = q\alpha - t(q) \quad (4.15)$$

Denklemlerdeki α tekillik üsteli, $F\alpha$ ise tekillik spektrumudur.

- ✓ Denklem 4.16 ve Denklem 4.17 kullanılarak α ve $F\alpha$, $h(q)$ türünden ifade edilir.

$$\alpha = h(q) + q h'(q) \quad (4.16)$$

$$F\alpha = q[\alpha - h(q)] + 1 \quad (4.17)$$

- ✓ $F\alpha$ değerlerinin α değerlerine göre grafiği ise çokfraktallı spektrumu verir ve bu spektrum zaman serilerinin uzun aralıktaki korelasyon karakteristiğini yansıtır.

4.3.2. Tekil değer ayrışımı (SVD)

Tekil değer ayrışımı (Singular Value Decomposition: SVD) boyut azaltma, sinyal işleme uygulamaları, istatistiksel analiz ve veri sıkıştırma gibi bir çok alanda kullanılan faydalı bir araçtır (Lee ve Hayes, 2004). Bu yöntem bir matrisin çarpanlarına ayrılması esasına dayanır. SVD $m \times n$ boyutlu A matrisini Denklem 4.18'te görüldüğü gibi U , Λ ve V olmak üzere 3 matrise ayırır (Golub ve Reinsch, 1970; Xia ve ark., 2015; Yucelbas ve ark., 2018a; Yucelbas ve ark., 2018b).

$$A = U \Lambda V^T \quad (4.18)$$

Denklem 4.4'te, Λ köşegen(diyagonal) bileşenleri yani $A_{m \times n}$ matrisinin tekil değerleri olan $m \times n$ boyutunda köşegen bir matrisi ifade etmektedir (Yücelbaş, 2017a). Ortogonal yani dikey $U_{m \times m}$ ve $V_{n \times n}$ matrislerinin sütunları A matrisinin sol ve sağ tekil değerleridir (Yücelbaş, 2017b).

4.3.3. Otoregresif / Özbağlanım (AR)

Otoregresif (Autoregressive: AR) yöntem, bir serinin herhangi bir andaki değerini, serinin geçmiş zamandaki belirli sayıda gözlem değerine ve hata terimine bağlı olarak açıklayan bir yöntemdir. Bu yöntem, geçmiş zamandaki içerdiği gözlem değeri sayısına göre isimlendirilir. Örneğin, AR (5) geçmiş zamana ait 5 gözlem değerini içerir ve 5. dereceden otoregresif olarak belirtilir. Bu yöntem denklem 4.19'da

görüldüğü gibi temsil edilir (Acharya ve ark., 2008; Göğüş, 2015). Denklemdaki, x ; zaman serisini, $ar(k)$; AR yöntemi katsayılarını (parametreler), $e(n)$; hata terimini temsil etmektedir (Acharya ve ark., 2008).

$$x(n) = \sum_{k=1}^p ar(k)x(n-k) + e(n) \quad (4.19)$$

Ar parametrelerinin tahmini için farklı tekniklerden faydalanılmaktadır. Burg tekniği en sık kullanılan ve en etkili sonuçların elde edilmesini sağlayan AR tekniklerinden biridir (Übeyli ve Güler, 2004). Bu teknik temel olarak ileri ve geri tahmin hatalarının minimuma indirilmesi esasına dayanır. AR-Burg tekniği ile güç spektrum yoğunluğu Denklem 4.20'deki gibi hesaplanır (Acharya ve ark., 2008). Denklem 4.20'deki e_p toplam en az karesel hatayı gösterir ve ileri ve geri tahmin hatalarının toplamıdır (Acharya ve ark., 2008).

$$PSD_{Burg} = \frac{e_p}{\left| 1 + \sum_{k=1}^p ar(k)e^{-j2\pi f k} \right|^2} \quad (4.20)$$

4.3.4. Entropi ölçüleri

Yaklaşık entropi (YakEn) ve örnek entropi (ÖrEn), bir zaman serisindeki tekrarlanabilirliği, öngörülebilirliği ve karmaşıklığı ölçmek için geliştirilmiş matematiksel algoritmalarıdır (Yentes ve ark., 2013). Sinyaller hem yaklaşık hem de örnek entropi değerleri bakımından değerlendirilirse, düzensiz, kestirilemez ve rastgele sinyaller daha yüksek entropi değerlerine sahipken daha düzenli ve öngörülebilir olan sinyaller daha düşük entropi değerlerine sahip olurlar.

N boyutlu bir x_n serisi için yaklaşık entropi değeri aşağıda anlatıldığı gibi hesaplanır.

İlk olarak seri m boyutlu $v_m(i)$ vektör kümesine bölünür. Birbirlerine Öklid mesafesine göre yakın bulunan vektörlerin sayısı $n_i^m(\hat{r})$, \hat{r} toleransına bağlı olarak $d[v_m(i), v_m(j)] \leq \hat{r}$ şeklinde gösterilir. Bu sayı kullanılarak Denklem 4.21'deki olasılık hesaplanır (Topçu ve ark., 2015).

$$C_i^m(\dot{r}) = \frac{n_i^n}{(\dot{N} - m + 1)}, \quad n_i^n; \quad d[v_m(i), v_m(j)] \leq \dot{r} \text{ olanların sayısı} \quad (4.21)$$

Yaklaşık entropi değeri de Denklem 4.22’de görüldüğü gibi elde edilir.

$$\text{YakEn}(\dot{r}) = \lim_{\dot{N} \rightarrow \infty} [\Phi^m(\dot{r}) - \Phi^{m+1}(\dot{r})] \quad (4.22)$$

Bu denklemdeki $\Phi^m(\dot{r})$ Denklem 4.23’de gösterildiği gibidir.

$$\Phi^m(\dot{r}) = \frac{1}{(\dot{N} - m + 1)} \sum_{i=1}^{\dot{N} - m + 1} \ln C^m(\dot{r}) \quad (4.23)$$

Örnek entropi, yaklaşık entropinin geliştirilmiş bir versiyonudur. Yaklaşık entropinin özeşleme problemini ortadan kaldırmaktadır. Örnek entropi yaklaşık entropiye göre ayrıca iki avantaja sahiptir, bu avantajlar; 1) Veri uzunluğundan bağımsızdır, 2) Uygulaması nispeten daha kolaydır. Örnek entropi Denklem 4.24’te görülen eşitsizlik ile hesaplanır (Topçu ve ark., 2015).

$$\text{ÖrEn} = \lim_{\dot{N} \rightarrow \infty} - \ln \frac{C^{m+1}(\dot{r})}{C^m(\dot{r})} \quad (4.24)$$

Denklem 4.24’teki $C^{m+1}(\dot{r})$, Denklem 4.21’deki gibi hesaplanan $d[v_{m+1}(i), v_{m+1}(j)] \leq \dot{r}$ $i \neq j$ vektörlerinin olasılıklarını, $C^m(\dot{r})$ ise yine Denklem 4.21’de görülen eşitsizlik ile hesaplanan $d[v_m(i), v_m(j)] \leq \dot{r}$ $i \neq j$ olasılıklarını belirtmektedir (Chen ve ark., 2005).

4.3.5. Merkezi eğilim ölçüsü (CTM)

Bir sinyalin değişkenlik ölçüsü olan merkezi eğilim ölçüsü (Central Tendency Measure: CTM), Denklem 4.25’de görüldüğü gibi elde edilen bir fark grafiğine dayanır (Alvarez ve ark., 2006; Jiménez-García ve ark., 2020).

$$[x(n+2) - x(n+1)] \text{ vs. } [x(n+1) - x(n)] \quad (4.25)$$

CTM, oluşturulan fark grafiği üzerinde orjin etrafında olacak şekilde r yarıçaplı dairesel bir bölgenin seçilmesi, bu bölge içinde kalan örneklerin sayılması ve toplam örnek sayısına bölünmesi ile hesaplanır (Alvarez ve ark., 2006). Bir zaman serisinin N örnekten oluştuğu varsayılırsa, Denklem 4.25’deki gibi çizilen bir grafikte toplam $N-2$

örnek olmaktadır. Bu durumda CTM Deklem 4.26’da görüldüğü gibi hesaplanır (Alvarez ve ark., 2006).

$$\text{CTM} = \frac{\sum_{i=1}^{N-2} \delta(i)}{N-2} \quad (4.26)$$

Denklem 4.26’daki $\delta(i)$, Denklem 27’deki gibidir (Alvarez ve ark., 2006).

$$\delta(i) = \begin{cases} 1 & \text{if } [(x(i+2)-x(i+1))^2 + (x(i+1)-x(i))^2]^{1/2} < r \\ 0 & \text{aksi takdirde} \end{cases} \quad (4.27)$$

4.3.6. Lempel ziv karmaşıklığı (LZK)

Son yıllarda biyomedikal sinyallerin analizinde sıklıkla kullanılan doğrusal olmayan ölçütlerden biri karmaşıklık ölçüsüdür. Lempel Ziv Karmaşıklığı (LZK), sonlu serilerin rastgeleliğini ölçmek için kullanılan bir karmaşıklık ölçütüdür (Alvarez ve ark., 2006; Akar ve ark., 2015). Bu karmaşıklığı hesaplamak için, sinyaller öncelikli olarak sembolik bir diziye dönüştürülür (Artan ve Yazgan, 2008; Akar ve ark., 2015). Bunun için sıklıkla işaretin genliğinin bir eşik değeri ile kıyaslanması ve böylelikle 0-1 sembolik dizisine dönüştürülmesi işlemi tercih edilir (Artan ve Yazgan, 2008; Akar ve ark., 2015). Eğer sinyalin genlik değeri eşik değerinden büyükse, genlik değeri 1’e, aksi takdirde 0’a çevrilir. Eşik değeri olarak ise genellikle sinyalin ortanca değerinin (medyanının) kullanılması iyi bir seçim olarak görülür (Artan ve Yazgan, 2008).

Sinyaller 0-1 dizilerine dönüştürüldükten sonra sembolik dizi farklı sözcükler oluşturmak üzere ayrıştırılarak kodlanmaktadır. $L(N)$, bu sözcüklerin kodlanmış dizisinin uzunluğunu göstermek üzere, LZK değeri Denklem 4.28’de görüldüğü şekilde tanımlanır (Artan ve Yazgan, 2008).

$$\text{LZK} = \frac{L(N)}{N} \quad (4.28)$$

Denklemdaki N dizinin uzunluğudur. Kodlanan dizinin toplam uzunluğu Denklem 4.29’daki eşitsizlik ile elde edilir. Eşitsizlikteki $c(N)$ sözcük sayısıdır. Böylelikle LZK denklem 4.30 kullanılarak hesaplanır (Artan ve Yazgan, 2008).

$$L(N) = c(N)[\log_2 c(N) + 1] \quad (4.29)$$

$$LZK = c(N) \frac{[\log_2 c(N) + 1]}{N} \quad (4.30)$$

4.4. Özellik Seçme Yöntemleri

Bu tez çalışmasında bilgi kazancı özellik değerlendirme, korelasyon özellik değerlendirme, OneR özellik değerlendirme, korelasyon tabanlı alt küme değerlendirme ve sarmal tabanlı alt küme değerlendirme özellik seçim yöntemleri çeşitli amaçlarla değerlendirilecek etkin özellikleri belirlemek için kullanılmıştır.

4.4.1. Bilgi kazancı özellik değerlendirme yöntemi

Bilgi kazancı özellik değerlendirme (Information Gain Attribute Eval) yöntemi, her bir özelliğin önemini hedef sınıfa göre bilgi kazancı değeri ile ölçerek özellik seçimini gerçekleştirir (Göğüş ve ark., 2020). Bilgi kazancı Denklem 4.31’de görüldüğü gibi hesaplanır (Gnanambal ve ark., 2018).

$$\text{Bilgi Kazancı}(\text{Sınıf}, \text{Özellik}) = H(\text{Sınıf}) - H(\text{Sınıf} | \text{Özellik}) \quad (4.31)$$

Deklem 4.31’deki H entropiyi ifade eder. Yöntemin icrası sonucunda özellikler bilgi kazancı değerine göre sıralanır ve en yüksek bilgi kazancına sahip özellikler etkin özellikler olarak seçilir.

4.4.2. Korelasyon özellik değerlendirme yöntemi

Korelasyon özellik değerlendirme (Correlation Attribute Evaluation) yöntemi, her bir özelliğin değerini, onunla hedef sınıf/değer arasındaki Pearson korelasyonu ölçerek değerlendirir (Yıldırım, 2015; Göğüş ve ark., 2020). Özellikler hedef ile olan korelasyonlarına göre sıralanır ve yüksek korelasyona sahip özellikler etkin özellikler olarak seçilir.

4.4.3. OneR özellik değerlendirme yöntemi

One-R, Holte tarafından önerilen basit bir sınıflandırma algoritmasıdır (Holte, 1993). Bu yöntem her bir özelliğin etkinliğini hata oranını dikkate alarak One-R algoritmasına göre belirler. Yöntem, algoritmaya göre en düşük hata oranını dikkate alarak özellik seçimini gerçekleştirir (Holte, 1993; Gogus ve Tezel, 2019).

4.4.4. Korelasyon tabanlı alt küme değerlendirme yöntemi

Korelasyon tabanlı alt küme değerlendirme (Correlation Based Subset Evaluation) yöntemi özellik alt kümelerinin etkinliğini ölçmektedir. Yöntemin amacı, sınıfla veya nümerik bir değerle yüksek derecede ilişkili ve birbiriyle ilişkisiz özellikler içeren alt kümeleri bulmaktır (Hall, 1999; Yıldırım, 2015). Yöntemin özellik alt kümesi değerlendirme işlevi Denklem 4.32'deki gibi gerçekleştirilir (Hall, 1999; Yıldırım, 2015).

$$\text{Merit}_S = \frac{kr_{cf}}{\sqrt{k+(k+1)r_{ff}}} \quad (4.32)$$

Denklemdaki Merit_S , k özellikten oluşan S altkümesinin etkinlik ölçütüdür. r_{cf} özellik-sınıf veya değer arasındaki ortalama korelasyon ve r_{ff} özellik-özellik arasındaki ortalama iç korelasyondur.

4.4.5. Sarmal tabanlı alt küme değerlendirme yöntemi

Sarmal tabanlı alt küme değerlendirme (Wrapper Subset Evaluation) yöntemi seçilen sınıflayıcı için doğru sınıflandırma oranına göre en düşük hatayı veren özellik alt kümesini bulabilmek amacıyla var olan özellikler listesinde bir arama yapar (Kohavi ve John, 1997; Yücelbaş, 2017b). Özellik alt kümesinin seçiminde, herhangi bir öğrenme algoritması, önemli özellikleri bir alt küme haline getirir ve geri kalanı görmezden gelir. Özellik alt kümesi seçim algoritması, induksiyon algoritması etrafında sarmal olarak bulunur. İndüksiyon algoritması, "kara kutu" olarak ifade edilir yani bu algoritmanın ne olduğuna dair bilgilere gerek yoktur. Bu algoritma sadece basit bir arayüzdür ve görevi bir sonraki aşamadaki verilerin sınıflandırılmasında veya değer tahmininde kullanılmasında yararlı olacak bir öğrenme algoritmasını tetikleyerek çalıştırmaktır (Kohavi ve John, 1997; Yücelbaş, 2017b). Özellik alt küme seçme algoritması, induksiyon algoritmasını kullanarak iyi bir alt küme için arama yapar ve kendisini de özellik alt kümelerini değerlendiren işlevin bir parçası olarak kullanır. Kısacası buradaki hedef en yüksek değerlendirme sonucunun yani en düşük hatanın elde edildiği özellik alt kümesinin belirlenmesidir. Sarmal yöntemlerde n özellikli veri seti için 2^n adet aday alt küme bulunmaktadır (Budak, 2018). Bu arama uzayı sayısı, n sayısı arttıkça arama işlemini engelleyebilecek seviyeye ulaşmaktadır (Budak, 2018).

Bu nedenle farklı özellik alt kümeleri oluşturulurken kullanılan farklı arama algoritmaları mevcuttur. İleri yönde seçim, geri yönde seçim, iki yönlü (ileri ve geri) seçim, en iyi arama (best-first search) ve açgözlü adım adım seçim (greedy stepwise) bu arama algoritmalarındandır. Sarmal yöntemler, en iyi alt özellik kümesinin tespit edilmesinde diğer yöntemlere oranla daha başarılı sonuçlar üretmelerine karşın, her bir özellik alt kümesi için tahmin yaptığından dolayı yüksek bir hesaplama maliyetine sahiptirler (Budak, 2018).

4.5. Sınıflandırma ve Tahmin Yöntemleri

Bu tez çalışmasında OSAS teşhisi ve CPAP terapisi ile sağlanan tedavi gerekliliğinin belirlenmesi amacıyla sınıflandırma işlemleri, CPAP terapisi gerekli görülen hastalara ait tedavi edici optimum CPAP seviyelerinin tahmin edilebilmesi amacıyla da tahmin işlemleri gerçekleştirilmiştir. Bu işlemler için birçok farklı yöntem kullanılmış ve yöntemlerin etkinlikleri karşılaştırılarak tez çalışmasının amacına ulaştıracak en başarılı yöntemlere karar verilmiştir.

4.5.1. Rastgele orman algoritması (RF)

Breiman (2001) tarafından geliştirilen Rastgele Orman (Random Forest:RF) algoritması, ağaç türü sınıflayıcılar topluluğu (ormanı) olarak ifade edilebilir (Breiman, 2001). Bu algortmada tek bir ağaç yerine çok sayıda ve çok değişkenli karar ağaçlarının farklı eğitim kümeleriyle eğitilmesi sonucunda üretilen kararların birleştirilerek tek bir karar olarak elde edilmesi fikri söz konusudur (Breiman, 2001; Yücelbaş, 2017b). Yani, bu sınıflandırıcıda tek sınıflandırıcı kullanmanın yerini birden fazla sınıflandırıcının üretilip bu sınıflandırıcıların tahminleri üzerine son sınıflandırmayı gerçekleştirme işlemi almıştır (Yücelbaş, 2017b). Bu algortima yalnızca 2 adet parametreye sahiptir. Bu parametreler her bir düğüm için kullanılacak değişken sayısı ve ormanda oluşturulacak ağaç sayısıdır (Akkoc ve ark., 2017). Ağaç sayısının artması sonucun daha kararlı olmasını sağlar, ancak bunun yanında hesaplama süresinin uzamasına sebebiyet verir. Diğer belirlenmesi gereken parametre ise ağaç oluşturmak için değişkenlerden kaç adetinin seçilmesi gerektiğidir. Bu sayı rassal olarak elde edilir. Değişkenlerden bilgi kazancı en yüksek olana göre en iyi bölünme (split) hesaplanmaktadır. RF algoritması hem sınıflama hem de nümerik değerleri tahmin işlemlerinde kullanılmaktadır. Sınıflandırma işlemleri için en çok oyu alan sınıf nihai

sınıf olarak belirlenirken, nümerik değer tahmini için yapılan oylamanın ortalaması alınarak nihai tahmin yapılır (Uzbaş, 2017).

RF algoritması için genelleme hatası ormandaki ağaç sayısı arttıkça yakınsar, bu nedenle algoritma için aşırı öğrenme bir problem değildir (Uzbaş, 2017). Aynı zamanda RF algoritmasında belirlenmesi gereken az sayıda parametre mevcuttur ve algoritma oldukça hızlıdır. Bu nedenlerden dolayı birçok farklı alanda kullanılmak üzere araştırmacılar tarafından sıklıkla tercih edilmektedir.

4.5.2. Destek vektör makineleri (SVM)

Destek Vektör Makineleri (Support Vector Machines: SVM), Vapnik (1999) tarafından geliştirilen istatistiki öğrenme teoremine dayanan bir yöntemdir. SVM'nin ana fikri, ayrılacak veri örnekleri arasındaki aralığı en üst düzeye çıkaran optimal hiper düzlemi bulmaktır (Vapnik, 1999; Huang ve ark., 2018).

SVM ile doğrusal olarak ayrılabilen verilerde maksimum sınır ve hiper düzlem kolaylıkla bulunabilirken, doğrusal olarak ayrılamayan verilerde maksimum sınırın bulunabilmesi için verilerin doğrusal olarak ayrılabilmesi için bir uzaya aktarılması gereklidir. SVM çekirdek fonksiyonlarını kullanarak doğrusal olmayan verileri yüksek boyutlu uzaya taşır (Huang ve ark., 2018). Bu sayede doğrusal olmayan veriler, doğrusal olarak ayrılabilir hale getirilmiş olur. Çizelge 4.2 en çok kullanılan çekirdek fonksiyonlarını göstermektedir.


Çizelge 4.2. Çekirdek fonksiyonları

Fonksiyon Formülü	Fonksiyon İsmi
$K(x_i, x_j) = (x_i \cdot x_j + 1)^d$	d dereceli polinom (Polynomial Kernel-PolyKernel) x _i ve x _j girdi uzayındaki vektör noktalarıdır.
$K(x_i, x_j) = e^{-\ x_i - x_j\ ^2 / 2\sigma^2}$	Radyal tabanlı fonksiyon (RBFKernel) x _i ve x _j girdi uzayındaki vektör noktalarıdır. σ, RBF çekirdeğinin bir parametresidir ve çekirdeğin 'yayılması' ve dolayısıyla karar bölgesi olarak düşünülebilir

SVM aynı ilkelere bağlı olarak hem sınıflandırma hem de değer tahmini işlemleri için kullanılmaktadır. Doğrusal olmayan ve karmaşık veriler üzerindeki başarısından dolayı araştırmacılar tarafından sıklıkla tercih edilmektedir.

4.5.3. Yapay sinir ağları (ANN)

Yapay Sinir Ağları (Artificial Neural Network:ANN) insan beynindeki biyolojik nöronların yapısından ve çalışma mantığından esinlenerek geliştirilmiş bir yöntemdir. ANN, sinir sistemindeki biyolojik nöronları temsil eden ve her biri kendi hafızasına sahip nöron, yapay sinir hücresi yada düğüm olarak adlandırılan birçok işlem elemanından oluşur. Bu sinir hücreleri ağırlıklı bağlantılar vasıtasıyla birbirleriyle haberleşirler. Her bir sinir hücresi kendine bilgi getiren birden çok girişe sahip olabilir. Aynı şekilde bir sinirin tek bir çıkışı olabileceği gibi birden fazla çıkışı da olabilir. Şekil 4.2 bir sinir hücresini göstermektedir (Demirhan ve ark., 2009).




Şekil 4.2. Yapay sinir hücre yapısı (Demirhan ve ark., 2009)

Şekil 4.2'de görüldüğü üzere yapay sinir hücresinin girdileri x_1, x_2, \dots, x_n girişleri çevreden veya kendinden önceki sinirlerden aldığı bilgiyi w_n bağlantı ağırlık katsayısı yani önemlilik derecesi ile diğer sinirlere getirir. Sinirler tüm girdi işaretlerinin ağırlıklı toplamlarını elde eder ve daha sonra bu toplamı, çıkış değerini istenilen değerler arasında tutmayı sağlayan bir transfer fonksiyonundan geçirir. Yaygın olarak kullanılan transfer fonksiyonları doğrusal, basamak, sigmoid ve hiperbolik tanjant fonksiyonlarıdır. Bir sinirin çıkışı transfer fonksiyonu sonucunun dış ortama veya diğer sinirlere gönderildiği yerdir. Elde edilen çıkış değeri ile beklenen çıkış değeri arasındaki fark belli bir değer üzerinde ise hata geriye doğru bir önceki katmana yayılarak ağ hatasının karesini minimize etmek için ağırlıkların değerlerini günceller. Hata değeri belli bir değer altına düşüncüye kadar iterasyon işlemine devam edilir ve böylece ağırlık öğrenme aşaması tamamlanmış olur (Demirhan ve ark., 2009; Göğüş, 2015).

ANN giriş katmanı, bir veya daha fazla ara katman ve çıktı katmanı olmak üzere 3 katmandan meydana gelmektedir. İlk katman olan giriş katmanı, girişlerin ANN'e sunulduğu ve söz konusu değişkenlerin ara katmana aktarıldığı katmandır. Ara katman

girdi katmanından sağlanan bilgilerin işlenerek çıktı katmanına gönderildiği katmandır. Çıktı katmanı ise ağıın üretmiş olduğu çıktı değerini dış dünyaya iletilmekle görevli olan katmandır (Akkoç ve Elitaş, 2010). Şekil 4.3 bir gizli katmana sahip ANN yapısını göstermektedir (Akkoç ve Elitaş, 2010; Göğüş, 2015).



Şekil 4.3. 1 gizli katmanlı yapay sinir ağı (Akkoç ve Elitaş, 2010; Göğüş, 2015)

ANN, birçok araştırmacı tarafından örüntü tanıma, kestirim, optimizasyon gibi farklı alanlarda sıklıkla tercih edilen bir yöntemdir. Yöntem biyomedikal alanda da modelleme, veri analizi ve tanı için sınıflandırma ve tahmin amacıyla sıklıkla kullanılmaktadır.

4.5.4. Naive Bayes (NB)

Naive Bayes (NB), Thomas Bayes tarafından önerilen ve Bayes karar teorisine dayanan basit bir olasılıksal sınıflandırıcıdır (Sezgin ve Çelik, 2013).

NB algoritmasının uygulanmasında niteliklerin birbirinden bağımsız olduğu ve niteliklerin hepsinin aynı derecede önemli olduğu gibi bir takım kabuller yapılır (Göğüş, 2015; Uzbaş, 2017). Bu algoritma ile gerçekleştirilen sınıflama işlemi hangi sınıflara ait oldukları bilinen belirli bir oranda eğitim verisi ile başlar. Bu veriler üzerinde yapılan olasılık hesapları ile sisteme sunulan yeni test verileri, daha önce elde edilmiş olasılık değerlerine göre değerlendirilir ve verilen test verilerinin hangi sınıflara ne kadar olasılıkla ait olduğu tespit edilmeye çalışılır (Göğüş, 2015).

NB sınıflandırıcısı için, G giriş örneği n adet özellikten oluşmakta ve $G = (g_1, g_2, \dots, g_n)$ olarak ifade edilmektedir. M sınıf olduğu düşünüldüğünde C_1, C_2, \dots, C_M sınıf

değerlerini göstermektedir. Sınıfı belirlenecek olan örneğe ilişkin olarak son olasılık Denklem 4.33'de gösterildiği şekilde hesaplanır.

$$P(C_i | G) = \frac{P(G | C_i) \times P(C_i)}{P(G)} \quad (4.33)$$

$P(G)$ değeri tüm sınıflar için sabit olduğu için Denklem 4.33 yalnızca denklemin payı olan $P(G | C_i) \times P(C_i)$ ile ifade edilir ve bu ifadenin maksimumu aranır (Uzbaş, 2017). Yeni gelen G örneğinin sınıfı, Maksimum $P(G | C_i) \times P(C_i)$ değerine sahip sınıf olarak belirlenir.

4.5.5. K en yakın komşu algoritması (kNN)

k En Yakın Komşu (k Nearest Neighbor: kNN) algoritması sınıflandırma ve tahmin işlemlerinde sıklıkla kullanılan en basit ve en az maliyetli makine öğrenmesi yöntemidir (Göğüş, 2015). kNN, sınıfı veya değeri bilinmeyen yeni gözlem değerinin, örnek kümedeki gözlemlerin her birine olan uzaklığının hesaplanması ve en küçük uzaklığa sahip k sayıdaki gözleme göre sınıfının veya değerinin belirlenmesi esasına dayanır (Altman, 1991; Demircan, 2020). Örnekler arasındaki uzaklığı hesaplamak için kullanılan en yaygın ölçüt Öklid (Euclidean) uzaklığıdır (Yücelbaş, 2017b).

kNN algoritmasının adımları şu şekildedir (Göğüş, 2015; Uzbaş, 2017):

- k değeri belirlenir.
- Yeni gelen gözlem değerinin, bilinen örnek kümesi içindeki gözlemlerin her biri ile uzaklığı hesaplanır.
- En yakın k adet gözlem belirlenir.
- Sınıflama işleminde k adet gözlemden en çok örneğin bulunduğu sınıf değerlerine bakılarak yeni gelen gözlemin sınıfı belirlenir. Eğer gerçekleştirilen işlem bir değer tahmini ise yeni gözlemin değeri, en yakın k adet gözlem değerlerinin ortalamasıdır.

4.5.6. Doğrusal regresyon analizleri

Doğrusal regresyon analizi bağımlı sayısal bir değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi modelleme aracıdır (Kilic, 2013). Bağımlı değişken, değeri tahmin edilmesi gereken değişkendir. Bağımsız değişkenler ise daha erken saptanabilen, bağımlı değişkenin değerini tahmin etmek için kullanılan değişkenlerdir.

Oluşturulan regresyon modelindeki bağımsız değişken sayısı bir ise model Basit Doğrusal Regresyon (Simple Linear Regression: SLR), bağımsız değişken sayısı birden fazla ise Çoklu Doğrusal Regresyon (Multiple Linear Regression: MLR) olarak isimlendirilir (Kilic, 2013). Denklem 4.34 tek değişkenli basit bir SLR modelini göstermektedir (Karabulut ve Şeker, 2018). Denklemdaki y bağımlı değişkeni, x bağımsız değişkeni, β_0 regresyon doğrusunun kesim değerini (Sabit değer), β_1 regresyon katsayısını (eğimini), ε hata terimini göstermektedir (Karabulut ve Şeker, 2018).

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (4.34)$$

Denklem 4.35, MLR analiz modelini göstermektedir (Kilic, 2013; Karabulut ve Şeker, 2018).

$$y = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \dots + \beta_p x_{ip} + \varepsilon \quad (4.35)$$

MLR analizinde bağımsız değişken sayısı oldukça fazla olduğunda çeşitli yöntemler kullanılarak modele katkısı en fazla olan daha az sayıdaki değişken veya değişkenler belirlenebilir (Kilic, 2013). Bu yöntemlerden en sık tercih edileni Adım-Adım Çoklu Doğrusal Regresyon (Stepwise Multiple Linear Regression:S-MLR) yöntemidir. S-MLR yönteminde öncelikle bağımlı değişkenle yüksek korelasyonlu özellikler ileriye doğru adım adım seçilerek regresyon modeline eklenir. Ardından, modele daha önce eklenen bağımsız değişkenler geriye doğru yeniden değerlendirilir ve böylelikle önceden eklenen bir bağımsız değişken daha sonraki adımlarda modelden çıkarılabilir (Kayaalp ve ark., 2015). Bu süreç sonunda regresyon modelinde kalan özellikler en etkin özellikler olarak değerlendirilir ve bu özellikler ile doğrusal regresyon analizi gerçekleştirilir.

4.6. Performans Değerlendirme Ölçütleri

Bu tez çalışmasında kullanılan yöntemlerin performanslarının değerlendirilmesi amacıyla Sınıflandırma Doğruluğu (Classification Accuracy: CA), duyarlılık, özgüllük, kesinlik/hassasiyet, F-Skor, Cohen'in Kappa katsayısı (K), Pearson korelasyon (r) ve belirlilik (r^2) katsayıları, p değeri ölçütleri kullanılmıştır.

CA, duyarlılık, özgüllük ve kesinlik/hassasiyet ölçütleri gerçekleştirilen işlem sonucunda oluşan ve Çizelge 4.3'te görülen konfüzyon matrisindeki değerlerden hesaplanmaktadır.

Çizelge 4.3. Konfüzyon matrisi

		Tahmin Edilen	
		Pozitif	Negatif
Gerçek	Pozitif	Doğru Pozitif (True Positive: TP)	Yanlış Negatif (False Negative: FN)
	Negatif	Yanlış Pozitif (False Positive: FP)	Doğru Negatif (True Negative: TN)

Çizelge 4.3'te bulunan değerlerin anlamları aşağıda verildiği şekilde açıklanabilir:

Doğru Pozitif (True Positive: TP): Gerçekte pozitif olan durumlar arasından tahmin edildiğinde de pozitif olarak bulunanların sayısını ifade eder. Örneğin gerçekte hasta olan kişiler arasından tahmin sonucunda da hasta olarak bulunanların sayısıdır.

Yanlış Negatif (False Negative: FN): Gerçekte pozitif olan durumlar arasından tahmin edildiğinde negatif olarak bulunanların sayısını ifade eder. Örneğin gerçekte hasta kişiler arasından tahmin sonucunda sağlıklı olarak bulunanların sayısıdır.

Yanlış Pozitif (False Positive: FP): Gerçekte negatif olan durumlar arasından tahmin edildiğinde pozitif olarak bulunanların sayısını ifade eder. Örneğin gerçekte sağlıklı kişiler arasından tahmin sonucunda hasta olarak bulunanların sayısıdır.

Doğru Negatif (True Negative: TN): Gerçekte negatif olan durumlar arasından tahmin edildiğinde de negatif olarak bulunanların sayısını ifade eder. Örneğin gerçekte hasta olmayan sağlıklı kişiler arasından tahmin sonucunda da sağlıklı olarak bulunanların sayısıdır.

Konfüzyon matrisinden elde edilen ölçütler Denklem 4.36, 4.37, 4.38, 4.39'da gösterildikleri gibi hesaplanırlar.

$$CA = \frac{TP+TN}{TP+TN+FP+FN} \quad (4.36)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (4.37)$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (4.38)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (4.39)$$

CA, doğru sonuçların yani hem doğru pozitifler hem de doğru negatiflerin tüm popülasyona oranıdır. Duyarlılık doğru pozitiflerin doğru tahmin edilme oranının

ölçüsüdür ve özgüllük doğru negatiflerin doğru tanımlanma oranının ölçüsüdür (Uzbaş, 2017). Kesinlik, gerçekteki doğru pozitiflerin tüm pozitif sonuçlara (hem gerçek pozitif hem tahmin edilen pozitifler) oranı olarak tanımlanır (Yücelbaş, 2017b). F-Skor, duyarlılık ve kesinlik ölçütlerinin birlikte değerlendirilmesini sağlar ve Denklem 4.40'de görüldüğü gibi kesinlik ve duyarlılığın harmonik ortalaması alınarak hesaplanır.

$$F\text{-Skor} = 2 \times \frac{(Kesinlik \times Duyarlılık)}{(Kesinlik + Duyarlılık)} \quad (4.40)$$

Cohen'in Kappa katsayısı (K) iki veya daha fazla kararın arasındaki uyumu ölçen bir istatistiktir (Cohen, 1960). K, -1 ile +1 arasında değerler alabilir. 0.8 ve +1 arası değer uyumun mükemmel olduğunun göstergesidir (Yücelbaş, 2017b). K değeri Denklem 4.41'deki eşitsizlik ile elde edilir (Cohen, 1960; Yücelbaş, 2017b; Göğüş ve ark., 2020). Denklem 4.41'deki P_o kararların uyumudur yani konfüzyon matrisinden hesaplanan CA ile aynıdır. Denklem 4.41'deki P_e ise uyuma etki eden şans olasılığıdır (Yücelbaş, 2017b; Göğüş ve ark., 2020). P_e Denklem 4.42'de görüldüğü gibi konfüzyon matrisinden hesaplanır (Bağ ve ark., 2010).

$$K = \frac{P_o - P_e}{1 - P_e} \quad (4.41)$$

$$P_e = \frac{[(TP + FP) \times (TP + FN)] + [(FN + TN) \times (FP + TN)]}{(TP + TN + FP + FN)^2} \quad (4.42)$$

Korelasyon, iki değişken arasında doğrusal bir ilişki olup olmadığını, ilişki var ise bu ilişkinin yönünü ve şiddetini gösteren istatistiksel bir ölçüttür (Şentürk ve Aşan, 2007). İlişki şiddeti korelasyon katsayısı (r) ile gösterilir. Pearson korelasyon en yaygın kullanılan korelasyon analizidir ve n örnekten oluşan X ve Y değişkenleri arasındaki Pearson korelasyon katsayısı Denklem 4.43'de görüldüğü gibi hesaplanır.

$$r = \frac{\sum XY - \frac{(\sum X)(\sum Y)}{n}}{\sqrt{\left(\sum X^2 - \frac{(\sum X)^2}{n}\right)\left(\sum Y^2 - \frac{(\sum Y)^2}{n}\right)}} \quad (4.43)$$

r'nin yorumu ařağıdaki gibi yapılır.

- $r < 0.2$ ise deęişkenler arasında çok zayıf iliřki vardır veya korelasyon yoktur.
- r 0.2 ile 0.4 arasında ise deęişkenler arasında zayıf korelasyon vardır.
- r 0.4 ile 0.6 arasında ise deęişkenler arasında orta řiddette korelasyon vardır.
- r 0.6 ile 0.8 arasında ise deęişkenler arasında yüksek korelasyon vardır.
- $r \geq 0.8$ ise deęişkenler arasında çok yüksek korelasyon vardır.

Bu deęerler negatif ise deęerler arasında ters yönde bir iliřki olduęu anlamına gelir. Belirlilik katsayısı ise r deęerinin karesi alınarak elde edilir. Bu katsayı, bir deęişkenin içindeki varyasyonun ne kadarının dięer deęişken tarafından açıklandığını belirtir (Göğüş ve ark., 2020). Örneğin X deęişkeni ile Y deęişkeni arasındaki korelasyonun 0.50 olduęu bulunmuşsa r^2 deęeri 0.25 olarak hesaplanır. Bu katsayı řu şekilde yorumlanabilir: Y deęişkeni içerisindeki deęişimin/varyansın %25'i X deęişkeni ile açıklanabilir.

p deęeri bir karşılařtırmada "istatistiksel anlamlı fark vardır" kararı verileceęi zaman, olası hata miktarını göstermek için kullanılır. r ile birlikte p deęeri de istatistiksel anlamlılıęı ifade eder. Arařtırmacıların isteęine göre p deęerinin genellikle 0.05, 0.01 veya 0.001'den küçük olması "istatistiksel olarak anlamlıdır" olarak kabul edilir.

5. OSAS TEŞHİSİ VE CPAP TEDAVİ GEREKLİLİĞİNİN BELİRLENMESİ

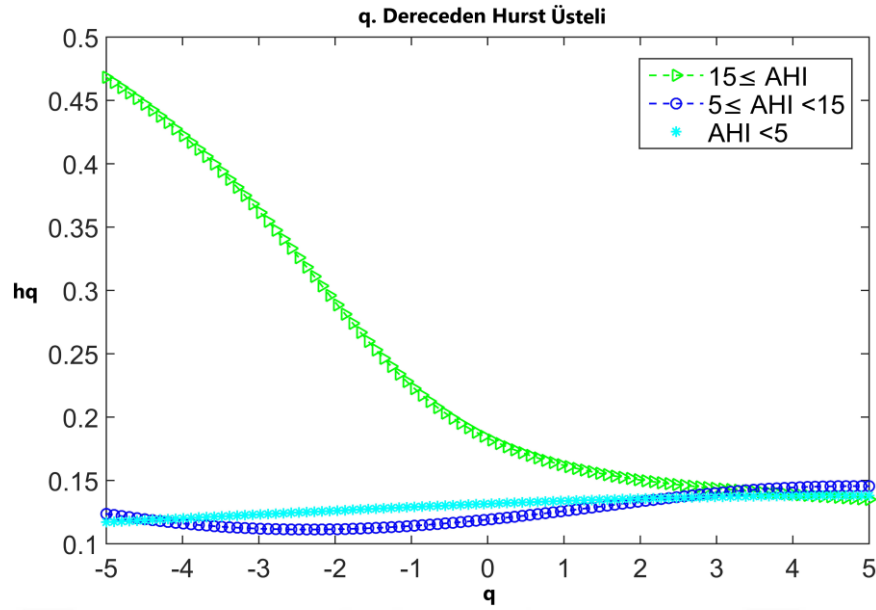
Bu tez çalışmasında, çalışmaya dahil edilen kişilerin OSAS hastası olup olmadığının ve CPAP terapisi ile gerçekleştirilen tedaviye ihtiyaç duyup duymadıklarının belirlenmesi amacıyla 2 farklı yaklaşım sunulmuştur. Bu yaklaşımlardan ilki Doğrusal Olmayan Analiz ikincisi ise Kural Tabanlı Algoritma yaklaşımıdır.

5.1. Doğrusal Olmayan Analiz Yaklaşımı

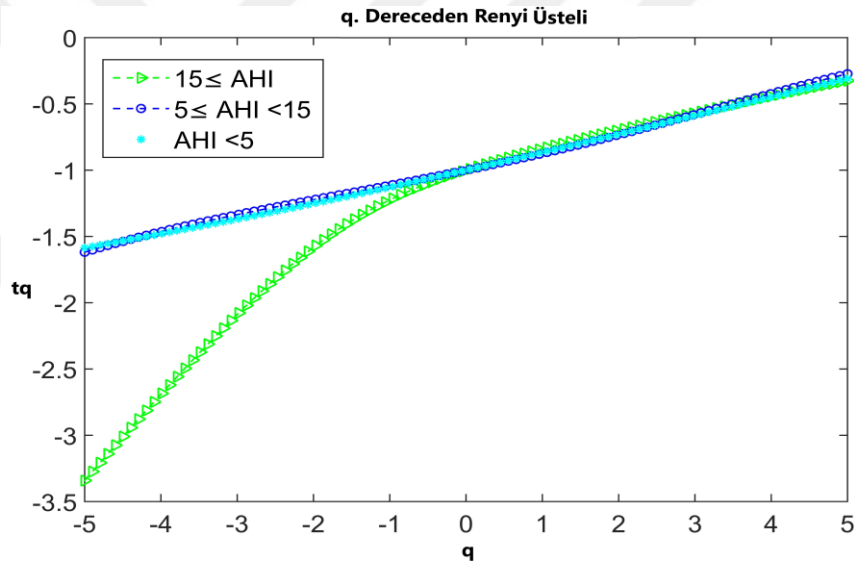
Uygunun kendisi, sıcaklık, solunum, kan basıncı ve kalp atış hızı gibi otonom sinir sistemi işlevlerini düzenleyen aktif bir süreçtir (Kaimakamis ve ark., 2009). Araştırmacılar tarafından bu otonomik aktivitenin düzenlenmesinin doğrusal olmayan bir davranış olduğu tespit edilmiştir (Kaimakamis ve ark., 2009). Ayrıca uykudaki solunum bozuklukları, üst hava yolu anatomik yatkınlığı ve nöral aktivasyon mekanizmalarındaki değişikliklerin bir kombinasyonu sonucu ortaya çıktığı için (Salisbury ve Sun, 2007), gece boyunca kaydedilen vücut sinyalleri de doğrusal olmayan dinamikler sergiler ve varyasyonlara sahiptir. Bu nedenle, hava akımı ve diğer polisomnografi sinyallerinin yapısal özellikleri her zaman önceki çalışmalarda kullanılan ortalama genlik, Fourier Dönüşümü tabanlı özellikler, istatistiksel özellikler gibi klasik ölçümlerle temsil edilemeyebilir (Nakano ve ark., 2007; Jayasri ve Hemalatha, 2013). Birçok araştırmacı bu durumu göz önünde bulundurarak, polisomnografide bulunan EEG, EKG, oksimetri, kalp atış gibi sinyallerin doğrusal olmayan dinamiklerini ortaya çıkaracak entropi ölçüleri, DFA, CTM, LZK gibi yöntemlerle OSAS teşhisi veya OSAS'lı hastalarla ilgili çalışmalar yapmışlardır (Deng ve ark., 2006; da Silva ve ark., 2015; Ma ve ark., 2018; Vaquerizo-Villar ve ark., 2018). Ancak, OSAS'lı hastaların patolojik hava akımı (solunum) sinyallerinde doğrusal olmayan dinamikleri keşfetmek ve bunları hastalığın varlığına yönelik olarak kullanmak için çok az sayıda çalışma yapılmıştır (Kaimakamis ve ark., 2009). Yapılan çalışmalarda ise genellikle hava akımı sinyalleri tek başına kullanılmamış, göğüs hareketi ve oksimetri sinyalleri ile birlikte sıklıkla entropi ölçüleri, DFA gibi aynı yöntemler kullanılarak değerlendirilmiş (Kaimakamis ve ark., 2009; Gutierrez-Tobal ve ark., 2013; Kaimakamis ve ark., 2016; Jiménez-García ve ark., 2020), diğer patolojik durumların tespitinde (EEG'den epilepsi tespiti, kalp seslerinden kalp rahatsızlığı tespiti

vb.) sıklıkla faydalanan MDFA yöntemi tercih edilmemiştir. Oysaki uyku bozuklukları ile ilişkili hava akımı sinyallerinde meydana gelen farklı örüntüler sinyalin alt aralıklarında tekrarlayabilmekte ve gece boyunca meydana gelen apne ve hipopne atakları hava akımının da dahil olduğu polisomnografi sinyallerinde rastgele ani yükselmeler ve/veya düzensiz dalgalanmalar üretmektedir (Vaquerizo-Villar ve ark., 2018). Bu varyasyonlar ve dalgalanmalar çok fraktallı yapı ile uyumludur ve bu sinyallerin karakteristiklerinin keşfedilmesinde MDFA gibi doğrusal olmayan bir yöntemin kullanılması yararlıdır. Bu nedenle, gerçekleştirilen tez çalışmasında, filtrelenmiş ve normalize edilmiş hava akımı sinyallerini karakterize eden çeşitli doğrusal olmayan özellikler MDFA yöntemi kullanılarak elde edilmiştir.

Çalışmaya dahil edilen 145 kişinin hava akımı sinyallerine MDFA yöntemi uygulanarak her bir kişinin hava akımı sinyaline ait çokfraktallı spektrum elde edilmiştir. Birçok biyomedikal fizyolojik sinyal için q değerinin seçimi -5 ve 5 arasında olacak şekilde uygun görülmüştür (Lashermes ve ark., 2011; Ihlen, 2012). Ayrıca literatürde L (ölçek) değerinin genellikle 16 ile 1024 arasında olduğu da görülmüştür. Bu nedenle, tez çalışmasında kullanılan MDFA tekniği için q , 0.1'lik adımlarla -5 ve 5 arasında değişecek şekilde seçilmiştir. L (ölçek) değerinin sınır değerlerinin de literatürdeki gibi 16 ve 1024 olmasına karar verilmiştir. Buna göre, ölçek aralığı 16 ila 1024 arasında logaritmik aralıklı toplam 19 eşit aralığa sahip olmuştur. Bu parametrelere göre, her bir kişinin hava akımı sinyalinin çok fraktallı analizi gerçekleştirilmiştir. Çok fraktallı analizde öncelikle MDFA yöntemi tarafından hava akımı sinyallerine ait Hurst üstelleri üretilmiştir. Ardından Hurst üstelleri, yöntem tarafından Renyi üstellerine dönüştürülmüştür. Şekil 5.1 ve Şekil 5.2 sırasıyla üç farklı AHI alt grubuna ($AHI < 5$, $5 \leq AHI < 15$, $15 \leq AHI$) dahil kişilerin hava akımı sinyallerine ait MDFA yöntemi ile elde edilen q . dereceden Hurst ve Renyi üstellerini göstermektedir. Şekil 5.1'den görüldüğü üzere, eğri şekilli Hurst üstel grafikleri, tüm AHI alt grupları için q değerleri ile doğrusal olmayan bir ilişki içerisindedir. Şekil 5.2'de, q 'ya bağlı Renyi üstelinin, özellikle $15 \leq AHI$ grubu için eğri bir şekil gösterdiği görülebilir. Bu, AHI değerinin artmasıyla, hava akımı sinyallerinin daha doğrusal olmayan çok fraktallı bir yapı ve büyük dalgalanmalar gösterdiği anlamına gelir.



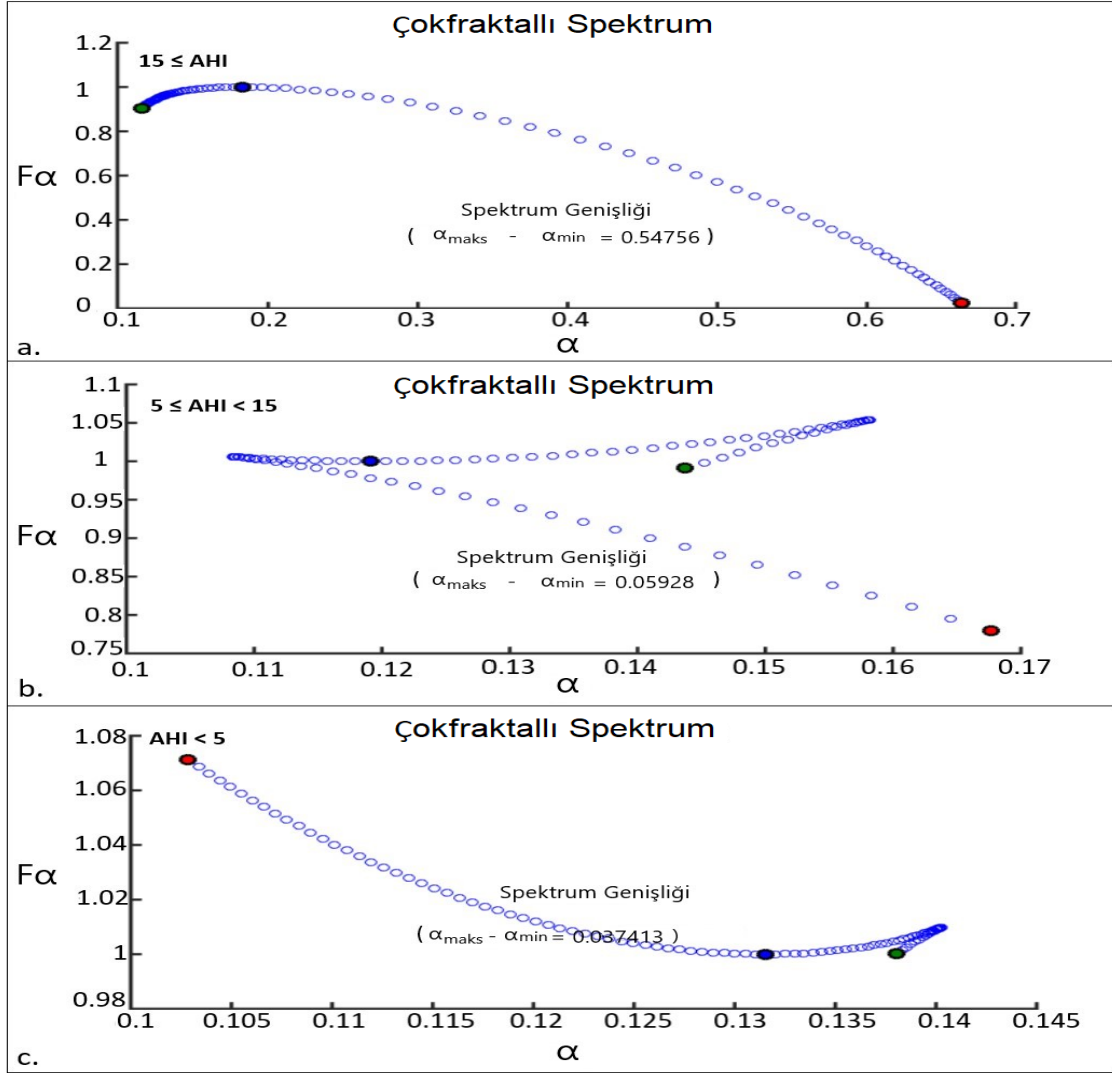
Şekil 5.1. q. dereceden Hurst üsteli



Şekil 5.2. q. dereceden Renyi üsteli

Hava akımı sinyallerinin Hurst ve Renyi üstellerinin hesaplanmasının ardından, MDFA yöntemi çokfraktallı spektrumu oluşturmak amacıyla Renyi üstellerini kullanarak tekillik üstellerini (α) ve tekillik spektrumlarını ($F\alpha$) üretmiştir. (Ihlen, 2012). Son olarak ise yöntem α 'ya karşı $F\alpha$ grafiklerini oluşturarak çokfraktallı spektrumların ortaya çıkmasını sağlamıştır (Márton ve ark., 2014). Farklı AHI alt gruplarına dahil 3 kişiye ait hava akımı sinyallerinin çokfraktallı spektrumları Şekil 5.3'de gösterilmektedir. Şekil 5.3'den görüldüğü üzere, farklı AHI alt gruplarındaki hastalar farklı spektrum tiplerine sahiptir. $15 \leq \text{AHI}$ 'li hastalarda nispeten güçlü ağırlıklı yüksek fraktal üslerle ilişkili sağa eğimli spektrum gözlenirken (Şekil 5.3.a), $\text{AHI} < 5$

olan sağlıklı bir kişi için düşük fraktal üsleri gösteren sola eğimli spektrum görülebilir (Şekil 5.3.c). AHI'si 5 ila 15 arasında olan bir hasta için ise her iki tarafa eğilmiş bir spektrum gözlemlenebilmektedir (Şekil 5.3.b). Bu nedenle hava akımı sinyallerinin çokfraktallı spektrumlarına ait farklı özelliklerinin kullanılmasının, farklı AHI alt gruplarını ayırt etmede yararlı olabileceği söylenebilir.



Şekil 5.3. Çokfraktallı spektrumlar, a. $15 \leq \text{AHI}$ için spektrum, b. $5 \leq \text{AHI} < 15$ için spektrum, c. $\text{AHI} < 5$ için spektrum

Bu tez çalışması kapsamında çok fraktallı yapının ayırt ediciliğinden faydalanmak amacıyla her bir kişinin hava akımı sinyali için MDFA yöntemi ile çokfraktallı spektrum oluşturulduktan sonra, aşağıda tanımlanan 23 özellik elde edilmiştir. Ayrıca çokfraktallı spektrumundan çıkarılan bu özelliklerden bazıları Şekil 5.4 üzerinde de gösterilmiştir.

ÇF1: Denklem 5.1’de görüldüğü gibi, -5 ile 5 arasındaki her bir q değeri için hesaplanan Hurst üstellerinin ortalaması. q , 0.1’lik adımlarla -5 ve 5 arasında değiştiği için denklemdeki $n=100$ olmaktadır.

$$\zeta_{F1} = \frac{1}{n} \sum_{q=-5}^5 h_q \quad (5.1)$$

ÇF2: Maksimum Hurst üsteli ($h_{q_{maks}}$).

ÇF3: Minimum Hurst üsteli ($h_{q_{min}}$).

ÇF4: Genelleştirilmiş Hurst üsteli.

ÇF5: Maksimum tekillik üsteli (α_{maks}).

ÇF6: Minimum tekillik üsteli (α_{min}).

ÇF7: Tekillik üstel değerlerinin ortalaması.

ÇF8: Spektrumun maksimum değerine karşılık gelen tekillik üstel değeri (σ_0).

ÇF9: Denklem 5.2 kullanılarak hesaplanan asimetrik indeks (AI) değeri (Li ve ark., 2015).

$$\begin{aligned} AI &= \frac{\Delta\sigma_L - \Delta\sigma_R}{\Delta\sigma_L + \Delta\sigma_R} \\ \Delta\sigma_L &= \sigma_0 - \alpha_{min} \\ \Delta\sigma_R &= \alpha_{maks} - \sigma_0 \end{aligned} \quad (5.2)$$

ÇF10: Spektrumun maksimum değerine karşılık gelen tekillik üsteli ile minimum tekillik üsteli arasındaki yatay mesafe (Denklem 5.2’deki $\Delta\sigma_L$) (Bose ve ark., 2019).

ÇF11: Spektrumun maksimum değerine karşılık gelen tekillik üsteli ile maksimum tekillik üsteli arasındaki yatay mesafe ($\sigma_0 - \alpha_{maks}$) (Bose ve ark., 2019).

ÇF12: Spektrumun maksimum değeri ($F\alpha_{maks}$).

ÇF13: Spektrumun ortalama değeri.

ÇF14: Spektrumun çarpıklık değeri (skewness).

ÇF15: Spektrumun basıklık değeri (kurtosis).

ÇF16: Spektrumun varyansı.

ÇF17: Maksimum tekillik üsteline denk gelen spektrum değeri ($F\alpha(\alpha_{maks})$).

ÇF18: Minimum tekillik üsteline denk gelen spektrum değeri ($F\alpha(\alpha_{min})$).

ÇF19: Denklem 5.3 ile hesaplanan spektrum genişliği.

$$S_{\text{genislik}} = \alpha_{\text{maks}} - \alpha_{\text{min}} \quad (5.3)$$

ÇF20: Denklem 5.4 ile hesaplanan spektrum yüksekliği.

$$S_{\text{yükseklik}} = F\alpha_{\text{maks}} - F\alpha_{\text{min}} \quad (5.4)$$

ÇF21: Denklem 5.5’de görüldüğü gibi hesaplanan spektrumun sol kesimi. (Maksimum spektrum değeri ile minimum tekillik üstel değerine karşılık gelen spektrum değerinin farkı)

$$S_{\text{sol}} = F\alpha_{\text{maks}} - F\alpha(\alpha_{\text{min}}) \quad (5.5)$$

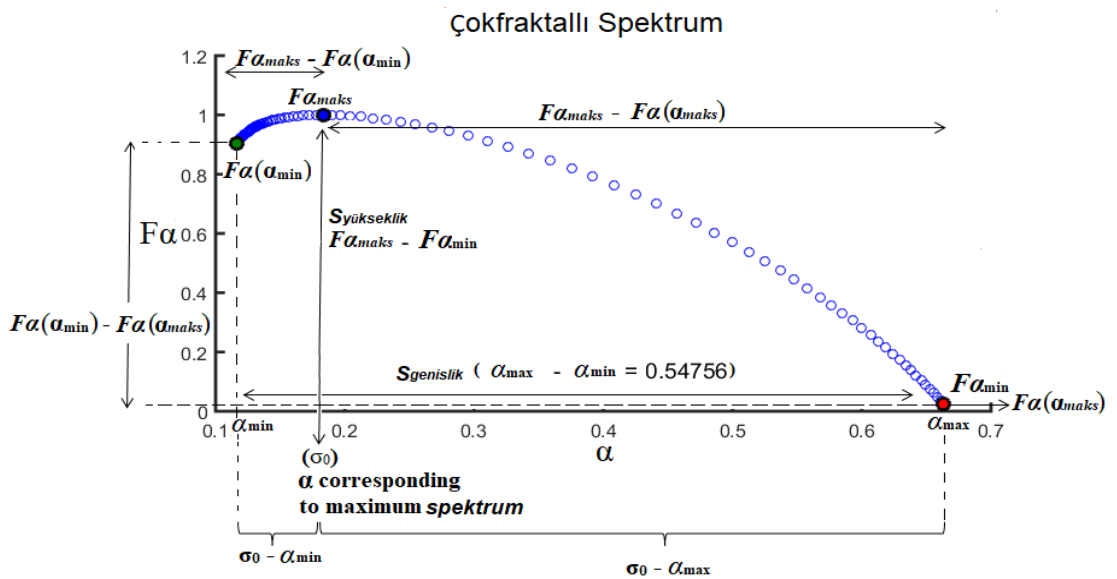
ÇF22: Denklem 5.6’da görüldüğü gibi hesaplanan spektrumun sağ kesimi. (Maksimum spektrum değeri ile maksimum tekillik üstel değerine karşılık gelen spektrum değerinin farkı)

$$S_{\text{sag}} = F\alpha_{\text{maks}} - F\alpha(\alpha_{\text{maks}}) \quad (5.6)$$

ÇF23: Denklem 5.7’deki gibi hesaplanan spektrumdaki düşey mesafe .

$$S_{\text{düşey}} = F\alpha(\alpha_{\text{min}}) - F\alpha(\alpha_{\text{maks}}) \quad (5.7)$$

Şekil 5.4, çokfraktallı spektrumundan çıkarılan bazı özellikleri göstermektedir.



Elde edilen özellikler sayesinde, kişilere ait hava akımı sinyalleri 23 özellik ile temsil edilmiştir. Bu özelliklerin kullanılması ile çalışmaya dahil edilen 145 kişinin OSAS hastası olup olmadığı ve CPAP terapi tedavisini gerektirip gerektirmediğinin belirlenmesi amaçlanmıştır. Bu amaç doğrultusunda kişilerin hava akımı sinyallerine ait 23 özellik ve RF sınıflandırma algoritması kullanılarak kişiler 3 farklı AHI alt grubundan ($AHI < 5$, $5 \leq AHI < 15$, $15 \leq AHI$) birine atanmıştır. Ayrıca her özelliğin AHI alt grupları üzerinde etkin olmayabileceği veya bazı özelliklerin diğerlerinden daha etkin olabileceği anlayışı benimsenmiş ve etkin özelliklerin belirlenmesi amacıyla çıkarılan özelliklere *Bilgi Kazancı Özellik Değerlendirme*, *Korelasyon Özellik Değerlendirme*, *OneR Özellik Değerlendirme*, *Korelasyon Tabanlı Alt Küme Değerlendirme* ve *Sarmal Alt Küme Değerlendirme* olmak üzere 5 farklı özellik seçme yöntemi uygulanmıştır. Böylelikle, her bir özellik seçme yönteminin kendi kriterine göre etkin sayabileceği özellikler elde edilmiştir. Her bir özellik seçme yöntemi ile seçilen özelliklere göre RF algoritması ile kişilerin 3 farklı AHI alt grubundan birine dahil edilmesi için sınıflandırma işlemleri tekrarlanmıştır. Tüm özelliklerin ve özellik seçme yöntemleri ile belirlenen özelliklerin RF ile sınıflandırılmaları sonucunda, en yüksek performansın elde edilmesini sağlayan özellikler en etkin özellikler olarak belirlenmiştir. Daha sonra en etkin olarak belirlenen bu özellikler RF sınıflandırıcısı haricinde ayrıca ANN, PolyKernel fonksiyonlu SVM, RBFKernel fonksiyonlu SVM, NB ve kNN sınıflandırıcıları ile de sınıflandırılarak performans karşılaştırması gerçekleştirilmiştir.

Tüm sınıflandırmaların sonunda en iyi performansı veren sınıflama sonucuna göre AHI'si 5'in altında olan kişiler sağlıklı olarak değerlendirilmiş ve bu kişilerin CPAP terapisi ile gerçekleştirilen tedaviye ihtiyacı olmadığı saptanmıştır. AHI değerleri 5'ten yüksek olan kişiler OSAS hastası olarak kabul edilmiştir. Bu kişiler arasından AHI değeri 5'ten yüksek ve 15'ten düşük olanlar için CPAP terapisi ile gerçekleştirilen tedavinin gerekli olup olmadığı, hastaların göstermiş oldukları semptomların ve diğer hastalıklara sahip olma gibi risk faktörlerinin uyku uzmanı tarafından incelenmesi sonucunda uzman görüşüne göre belirlenmiştir. OSAS hastası olup AHI değerleri 15 veya daha yüksek olan kişiler için ise CPAP terapisi ile gerçekleştirilen tedavi kesin olarak gereklidir sonucuna varılmıştır.

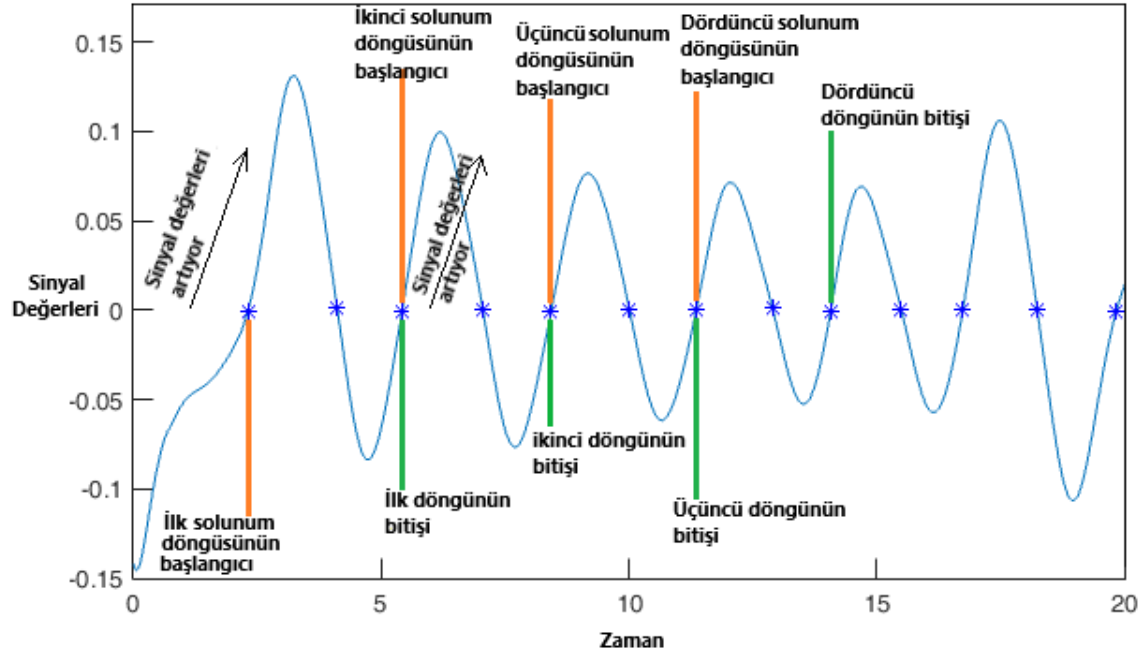
5.2. Kural Tabanlı Algoritma Yaklaşımı

OSAS teşhisinin konulması ve ardından teşhisi konulan hastalar için CPAP terapisinin gerekli olup olmadığının belirlenmesi, uyku uzmanları tarafından kişilerin gece boyunca geçirmiş oldukları apneik atakların tespiti ve bu atakların sayısına bağlı olarak AHI değerlerinin hesaplanması ile gerçekleştirilir. Gerçekleştirilen tez çalışması kapsamında da, çalışmaya dahil edilen kişilerin gece boyunca geçirmiş oldukları apneik atakların tespit edilebilmesi amacıyla hava akımı ve oksimetri polisomnografi sinyalleri kullanılarak kural tabanlı bir algoritma geliştirilmiştir. Ayrıca geliştirilen algorithmada ataklara eşlik eden oksijen desaturasyonlarının varlığı araştırılmış ve oluşan desaturasyonlar belirlenmiştir. Algoritmanın çalıştırılması sonucunda tespit edilen ataklara göre AHI değerleri hesaplanarak kişilerin durumları OSAS hastası veya değil, CPAP terapisi ile gerçekleştirilen basınç tedavisine ihtiyaç duyuyor veya duymuyor şeklinde tanımlanmıştır.

Algoritma geliştirilmeden önce apneik atakları tespit edilecek ve ataklara bağlı desaturasyonları belirlenecek olan kişiler %60'a %40 olacak şekilde rastgele eğitim ve test gruplarına ayrıştırılmıştır. Bu bölümün devamında anlatılan algoritmanın geliştirilmesi ve algorithmada kullanılan parametre değerlerinin belirlenmesi eğitim grubu hastalarına göre gerçekleştirilmiştir. Algoritma geliştirildikten sonra aynı parametrelerle test grubu hastalarının apneik atakları da tespit edilmiş ve ataklarına bağlı desaturasyonları belirlenmiştir.

Apneik atakların yani hem apnelerin hem de hipopnelerin tanımına göre atakların en az 10 sn süresince devam etmesi şarttır (AASM, 2012). En az 10 saniyelik zaman aralıklarının tespiti için, sinyalin bir bütün olarak değil, daha küçük parçalar halinde incelenmesinin avantajlı olacağı düşünülmüştür. Bu nedenle, ilk olarak, kişilere ait filtrelenmiş ve adaptif olarak normalize edilmiş tek kanallı hava akımı sinyalleri daha kısa zaman dilimlerine yani segmentlere bölünmüştür. Literatürdeki çalışmalar (Koley ve Dey, 2013; Moret-Bonillo ve ark., 2014; Huang ve ark., 2017) apneik atak tanımına bağlı kalınarak seçilen 10sn veya daha uzun segment sürelerinin bazı dezavantajları ortaya çıkardığını göstermiştir. Bu nedenle bu çalışmaya dahil edilen kişilerin hava akımı sinyallerinin segmentasyonu için 10 sn'den daha kısa sürelerde farklı denemeler gerçekleştirilmiş ve kişilerin yaklaşık solunum (nefes) döngü sürelerinin, onların hava akımı sinyalleri için en uygun segment süreleri (uzunlukları) olduğu kararına varılmıştır. Solunum döngüleri, hava akımı sinyalleri üzerinde Şekil

5.5’de görüldüğü gibi geleneksel geçiş (crossing) tekniği (Schmidt ve ark., 1998) kullanılarak belirlenmiştir. Her bir kişinin hava akımı sinyali için segment süresi, kişinin solunum döngü sürelerinin ortalaması alınarak hesaplanmıştır.



Şekil 5.5. Solunum döngülerinin belirlenmesi

Kişilerin solunum döngü süreleri birbirinden farklı olabilmektedir. Bu çalışmada da her hava akımı sinyali için segment süresinin literatürdeki çalışmalarca da desteklenen (Rostig ve ark., 2005; Zhang ve ark., 2014; Huang ve ark., 2017) 2 sn ile 6 sn arasında değiştiği görülmüştür. Kişiler için segment süreleri belirlendikten sonra, her bir hava akımı sinyali, her seferinde 1 sn kaydırılan kayan bir pencere (belirlenen segment süresi boyutlu) kullanılarak çakışan segmentlere bölünmüştür (Şekil 5.6.a).

Apneik ataklar meydana geldiği sırada, hava akımı sinyallerinin tepe değerleri, genlik, hız, enerji vb. özellikleri değişmektedir. Bu nedenle, literatürde, birçok araştırmacı tepe değerlerindeki, genliklerdeki ve solunum hızındaki değişiklikleri göz önünde bulundurarak, hava akımı sinyallerinden anlık solunum genliği (IRA- Instantaneous Respiration Amplitude), anlık solunum aralığı (IRI- Instantaneous Respiration Interval) sinyalleri gibi yeni sinyaller elde etmiştir. Araştırmacılar daha sonra hava akımı sinyalleri yerine bu yeni sinyalleri kullanarak apneik atakları tespit etmişlerdir (Otero ve ark., 2011; Koley ve Dey, 2013; Moret-Bonillo ve ark., 2014; Lee ve ark., 2016; Huang ve ark., 2017; Choi ve ark., 2018). Genlik ve hız değişikliklerinde olduğu gibi, apneik ataklar sırasında hava akımı sinyalinin enerjisinde de değişiklikler

meydana gelmektedir. Bu deęişikliklerin analiz edilmesi ile de apneik atakların tespit edilebilmesi mümkün olabilmektedir. Bu tez çalışması kapsamında bu durum dikkate alınmış ve çalışmaya dahil edilen her bir kişinin hava akımı sinyal segmentlerinden SVD yöntemi kullanılarak sinyal enerjisi bilgilerinin değerlendirilmesine dayanan yeni sinyaller üretilmiştir.

SVD yöntemi ile bir sinyale ait elde edilen tekil deęerler, gürültü seviyesi, sinyal enerjisi vb. hakkında bilgi vermektedir (Aytaş ve ark., 2018). Daha büyük deęerler verinin yapısı hakkında daha fazla enerji ve daha fazla bilgiye sahiptirler (Hassanpour ve ark., 2004; Xia ve ark., 2015). Dahası, tekil deęerler matris elemanlarındaki varyasyonlardan etkilenmez; dięer bir deyişle, bu deęerler iyi bir stabiliteye sahiptir. Verilerdeki ani deęişiklikler tekil deęerlerde bir deęişikliğe ve her alt uzaydaki enerjinin yeniden dağıtılmasına yol açmaktadır. Böylece, tekil deęerler biyomedikal sinyallerin yararlı özellikleri olarak kabul edilebilmektedir (Hassanpour ve ark., 2004). Hem bu nedenlerden dolayı hem de apneik ve normal hava akımı paternleri arasındaki enerji bilgisindeki farklılıklardan dolayı bu çalışmada SVD metodu tercih edilmiştir. Her bir hava akımı segmentine SVD metodu uygulanmış ve her segmente ait tekil deęerler elde edilmiştir.

Hassanpour ve ark. (2004) daha büyük tekil deęerlerin matrise gömülü verilerin ve örüntülerin yapısı hakkında dięer tekil deęerlere göre daha fazla bilgiye sahip olduğunu ve matrisin karakteristiğini daha fazla yansıttığını belirtmişlerdir. Tez çalışmasında bu ifade dikkate alınarak her bir segmente ait maksimum tekil deęer, o hava akımı segmentini temsil etmek üzere seçilmiştir. Sonucunda, SVD sinyali olarak adlandırılan yeni bir sinyal, çalışmaya dahil edilen her bir kişinin tüm hava akımı segmentlerine ait maksimum tekil deęerlerin birleştirilmesiyle üretilmiştir (Şekil 5.2.b).

Kişilerin geçirdikleri apneik atakların hemen bitiminde yeniden nefes alabilmesi amacıyla üst hava yolları aniden tekrar açılır (Ciolek ve ark., 2015). Bu ani açılmalar hava akım sinyallerinde çok ani piklerin, çok büyük deęerlerin ortaya çıkmasına neden olur (Ciolek ve ark., 2015). Dolayısıyla, özellikle apneik atakların tespiti gibi sinyallerdeki deęer deęişimlerine ve sinyal bazal deęerlerine baęlı olarak gerçekleştirilen işlemlerde yanlış kararlar ortaya çıkar. Bu tez çalışması kapsamında da bu durum ortaya çıkmış, apneik olayların tespiti amacıyla hava akımı sinyallerinden türetilmiş SVD sinyallerinde aşırı sayılabilecek tekil deęerler gözlemlenmiştir. Yanlış atak tespitlerinin önüne geçilmesi için, apneik atakların saptanmasından önce, SVD sinyallerindeki önemli ölçüde yüksek deęerler, Denklem 5.8’de görülen deęiştirilmiş-Z

skorları eşitsizliğine (Iglewicz ve Hoaglin, 1993) göre belirlenmiştir. SVD sinyalleri için Z-skoru mutlak değerce 2'den ($M_i > 2$) büyük olan sinyal değerlerinin en küçüğü *esik_deger_1* olarak kabul edilmiş (Denklem 5.9) ve bu eşik değerden büyük olan SVD sinyal değerleri aykırı değer olarak değerlendirilmiştir. Bu aykırı değerler apneik atakların tespiti sırasında dikkate alınmamıştır.

$$M_i = \frac{0.6745(s_i - \tilde{s})}{\text{medyan}(|s_i - \tilde{s}|)} \quad (5.8)$$

$$\text{esik_deger_1} = \min(s[M_i > 2]) \quad (5.9)$$

Denklem 5.8'de yer alan s SVD sinyalini, s_i sinyalin her bir örneğini, \tilde{s} sinyalin medyanını göstermektedir.

Her bir kişiye ait SVD sinyalindeki aykırı değerlerin belirlenmesi için *esik_deger_1* hesaplandıktan sonra, kişilerin geçirmiş olduğu apneik atakların tespiti amacıyla otomatik apneik atak tespit algoritması geliştirilmiştir. Bu algoritma aşağıda belirtilen adımları takip ederek çalışmaktadır.

i. *Başlangıç (ilk) bazal sinyal değerinin belirlenmesi*

AASM (2012), apneik ataklar için belirtilen bazal değeri, apneik ataktan önceki 2 dakikalık süre içinde hava akımı sinyalinin stabil haldeki ortalama değeri olarak tanımlar. Kişiler genellikle yataktaki ilk 2 dakika içinde apneik atak geçirmezler, daha düzenli ve stabil solunum yaparlar. Bu nedenle, geliştirilen algoritma, ilk bazal değeri, ilk 2 dakikadaki (dk) (120 sn) SVD sinyal örneklerini dikkate alarak belirler. Ancak, aykırı değerler bu 2 dk içinde de bulunabilir ve bazal değeri etkileyebilir. Bu nedenle, ilk 2 dk içerisindeki her bir sinyal örneğinin (s_i) *esik_deger_1*'den küçük olup olmadığı kontrol edilir ve sadece bu eşik değerden küçük olan örnekler, bazal değer hesaplamasında kullanılan Base[j] dizisinin elemanı olarak kabul edilir. Diğerleri aykırı değer olarak kabul edilir ve hesaplama için dikkate alınmaz. Daha sonra, bazal değer (Base_Val), Base [j] dizisini oluşturan değerlerin ortalaması alınarak hesaplanır (mean (Base [j])).

(s; SVD sinyalini, i; SVD sinyalleri için örnek indisini, Base[]; Bazal değerinin hesaplanması için kullanılan sinyal örneklerini içeren diziyi, j;

Base[] dizisinin indisini, Base_Val; Bazal değeri temsil etmektedir. Base dizisinin indisi olan j yalnızca sinyal örnekleri *esik_deger_1*'den küçük olduğu sürece artırılır.)

- ii. İlk iki dakikadan sonraki ilk örnekten sinyal sonuna kadar her bir SVD sinyal örneği için aşağıdaki aşamalar tekrar edilir.
 - a. *apneik_esik* isminde yeni bir eşik değeri $0.7 \times \text{Base_Val}$ olacak şekilde hesaplanır.
(*apneik_esik*, algoritmadaki ikinci eşik değeridir. Bu eşik, apneik bir atağın meydana gelip gelmediğine karar vermek için kullanılır. Eşik hesaplamasında kullanılan 0.7 katsayısı, AASM'ye göre en az % 30 azalmaya karşılık gelir.)
 - b. Her bir sinyal örneği (s_i) için iki soru sorulur.
Birinci Soru: Sinyal örneği (s_i) *esik_deger_1*'den küçük mü? Eğer öyleyse, ikinci soru sorulur. Aksi takdirde, örnek aykırı değer olarak kabul edilir ve önemsenmez.
İkinci Soru: Sinyal örneği (s_i) *apneik_esik* değerinden küçük mü? Öyleyse, örnek otomatik olarak apneik bir atağa aittir ("A") olarak etiketlenir. Aksi takdirde, sinyal örneği bazal değeri hesaplamak için Base [j] 'ye eklenir ve j indeksi artırılır. (j indeksi, yalnızca sinyal örneği *esik_deger_1*'den küçük olduğunda ve örnek 'A' olarak etiketlenmediğinde, diğer bir deyişle, herhangi bir apneik atak aralığına ait olmadığında artırılır.) Bu kısımda ayrıca ek bir kontrol daha gerçekleştirilir. A olarak etiketlenen örneğin bazal değerinin %10'nundan da küçük olup olmadığı değerlendirilir (%90'lık azalma). Eğer küçük ise bu 'A' örneği *Apnea []* olarak isimlendirilen ayrı bir dizide daha saklanır. Küçük değilse *Apnea []* dizisine eklenmesine gerek yoktur.
 - c. Bazal değer (Base_Val), Base dizisindeki son 2 dk'ya ait örneklerin ortalaması temel alınarak güncellenir.
- iii. SVD sinyallerindeki tüm örneklerin incelenmesi tamamlandıktan sonra, "A" olarak etiketlenmemiş sinyal örnekleri normal ("N") olarak etiketlenir.

- iv. SVD sinyalindeki tüm örnekler “A” veya “N” olacak şekilde etiketlendikten sonra, bir dizi kural yardımıyla bu etiketler yumuşatılır.

Kural 1: Aynı etiketlenmiş örnekler arasında bir veya iki adet farklı etiketlenmiş örnek var ise, bu örneklerin etiketleri aynı etiketlenenkilere dönüştürülür.

Kural 2: “A” ile etiketlenen herhangi bir örnek en az 10 sn süreli ardışık “A” etiketli örnek dizisinin bir parçası olmalıdır. Aksi halde, “A” etiketli örneğin etiketi “N” olacak şekilde yeniden düzenlenir.


Kural 3: Her bir ardışık “A” etiketli örnek dizileri 10 sn veya daha uzun süre devam ediyorsa, bu örnek dizisi bir apneik atak olarak düşünülür. İlk “A” etiketli örneğin zamanı apneik atağın başlangıç zamanını, son “A” etiketli örneğin zamanı ise apneik atağın bitiş zamanını gösterir.

Kural 4: Apneik atak süresi başlangıç ve bitiş zamanları arasındaki fark alınarak hesaplanır.

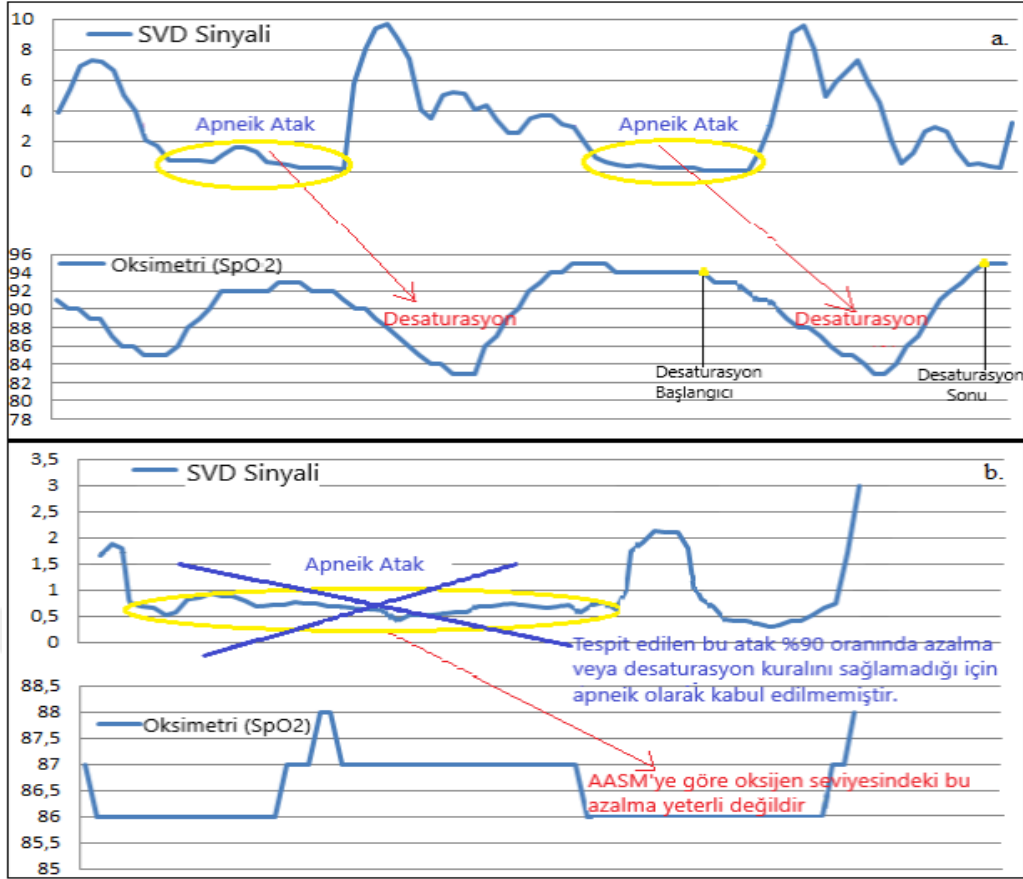
Geliştirilen algoritmanın ilk 4 adımının icrası sonucunda, öncelikle kişilere ait SVD sinyallerinin her bir örneği normal 'N' veya apneik 'A' olarak etiketlenmektedir. Daha sonra, 4 kuralın uygulanmasıyla birlikte apneik ataklar başlangıç ve bitiş zamanlarıyla birlikte tespit edilmiş olmaktadır. Şekil 5.6, geliştirilen algoritmanın ilk 4 adımında atakların nasıl tespit edildiğini göstermektedir. Algoritmanın bu adımları ile apneik ataklar tespit edildikten sonra, her bir apneik atağın sahip olduğu örnekler, *Apnea[]* dizisindeki sinyal örnekleri ile karşılaştırılır. Eğer atağın %90'nı *Apnea []* dizisinden ardışık örnekleri içeriyorsa bu atak apnedir olarak değerlendirilir.

- v. Algoritmanın son adımı önceki adımlar ile tespit edilen atakları doğrulamak veya reddetmek için çalıştırılır. AASM (2012) kriterleri, apneik ataklardan olan hipopnelere ya oksijen desaturasyonlarının ya da arousalların eşlik etmesi gerektiğini belirtmektedir. Bundan dolayı, algoritma bu adımında önceki adımları sonucunda tespit ettiği ataklara eşlik eden oksijen desaturasyonlarının olup olmadığını inceler. Oksijen desaturasyonu, apneik bir atağın başlangıcından itibaren belirli bir zaman gecikmesi ile başlar. Bu gecikme süresi için herhangi bir kriter olmamasına rağmen, apneik atak başladıktan sonra genellikle 20-40 sn

içerisinde desaturasyon görülür (Moret-Bonillo ve ark., 2014). Yani oksijen desaturasyonu atak başladıktan sonra 20 sn içerisinde oluşabilmektedir Ancak bazı durumlarda bu süre 40 sn'ye kadar da çıkabilmektedir. Bu nedenle, oksimetri sinyalindeki 40 sn zaman aralığı, algoritmanın ilk 4 adımı ile tespit edilen her bir apneik atağın başlangıcından itibaren otomatik olarak belirlenir. Daha sonra, AASM (2012) tarafından belirtilen % 3 oksijen desatürasyonu, algoritmaya göre hava akışında %90'luk bir azalmaya karşılık gelen ataklar hariç, her atak için belirlenen aralıklar dahilinde aranır. Hava akımındaki %90'luk azalmaya karşılık gelen ataklar apneleri temsil eder, bu nedenle onlar için desatürasyon aranmaz ve onlar kesin olarak apneik ataktır olarak onaylanır. Diğerleri arasında, oksijen desatürasyonunun eşlik ettiği ataklar da apneik atak olarak doğrulanır. Ancak geri kalan ataklar AASM (2012) kriterlerini sağlamadığı için apneik olarak kabul edilemez. Bu nedenle bu ataklara ait her bir örneğin etiketi “N” olarak değiştirilir. Şekil 5.7, tespit edilen apneik atakların desaturasyona göre apneik atak olarak doğrulanmasına ve reddedilmesine ait bir örneği göstermektedir. Desaturasyonların başlangıcı oksijen azalmasının başladığı ilk değer zamanı, sonu ise oksijen artışının son bulunduğu değer zamanı olarak belirlenir. Desaturasyon süresi ise desaturasyon başlangıç ve bitiş zamanları arasında fark alınarak hesaplanır.



Şekil 5.6. Kural tabanlı otomatik apneik atak tespit algoritmasının ilk 4 adımı a) Hava akımı sinyallerinin segmentasyonu ve segmentlere SVD'nin uygulanması, b) Yeni SVD sinyalinin oluşturulması, c) SVD sinyalindeki her bir örneğin 'A' veya 'N' olarak etiketlenmesi, d) Apneik atakların belirlenmesi



Şekil 5.7. Oksijen desaturasyonlarının apneik ataklarla senkronizasyonu, a. Apneik atakların doğrulanması, b. Apneik atakların reddedilmesi

Apneik atakların tespitinin ve desaturasyonların belirlenmesinin ardından, çalışmaya dahil olan kişilerin AHI değerleri, kişilerin gece boyunca geçirdikleri ve otomatik olarak tespit edilen toplam apneik atak sayılarının toplam uyku sürelerine bölünmesi ile elde edilmiştir. Elde edilen AHI değerlerine göre kişiler AASM (2012) kriterleri ve Medicare & Medicaid Hizmet Merkezleri (Centers for Medicare and Medicaid Services: CMS) (CMS, 2005) kılavuzuna göre sağlıklı ve tedavi gerektirmeyen birey ($AHI < 5$), tedavileri için CPAP terapisinin uygulanıp uygulanmaması konusunda uzman görüşüne ihtiyaç duyulmakta ($5 \leq AHI < 15$) ve CPAP terapisi ile sağlanan tedavi gereklidir ($15 \leq AHI$) olarak ayrıştırılmıştır. 5-15 aralığında AHI değerlerine sahip hastaların uzman görüşüne göre semptomlarının incelenmesi gerektiği, belirgin semptomlar gösteren ve/veya kardiyovasküler, serebrovasküler risk faktörleri olan kişilere de CPAP terapisi ile gerçekleştirilen tedavinin önerilmesi gerektiği kararına varılmıştır.

6. CPAP TAHMİN MODELLERİNİN OLUŞTURULMASI

Bu tez çalışması kapsamında, OSAS şüphesi ile ilgili uyku kliniğine başvuran kişilerden OSAS teşhisi konulan ve ardından CPAP terapisi ile tedavi edilmesi gerektiğine karar verilen kişilere ait optimum tedavi edici CPAP seviyelerinin tahmini için; farklı yöntemlerle elde edilen özelliklerden oluşan tahmin parametreleri, doğrusal regresyon analizleri, ANN, PolyKernel fonksiyonlu SVM, RBFKernel fonksiyonlu SVM, kNN ve RF yöntemleri kullanılmış ve CPAP tahmin modelleri geliştirilmiştir.

6.1. Özellik Setleri

Gerçekleştirilen tez çalışmasında, optimum CPAP seviyelerinin tahmini için tahmin parametreleri olarak kullanılabilir özellikleri içeren 4 farklı özellik seti oluşturulmuştur. İlk özellik setini CPAP terapisine ihtiyaç duyan hastaların demografik ve antropometrik özellikleri oluşturmaktadır. İkinci özellik seti bu hastaların hava akımı ve oksimetri sinyallerine ait güç spektrum ve istatistiksel özellikleri içermektedir. Üçüncü özellik seti aynı hastaların hava akımı ve oksimetri sinyallerinin doğrusal olmayan özelliklerinden oluşturulmuştur. Son özellik setini ise CPAP terapisi ile tedavi edilmeye ihtiyaç duyan hastaların hava akımı ve oksimetri sinyalleri kullanılarak tespit edilmiş apneik ataklarına ve oksijen desaturasyonlarına ait özellikler oluşturmuştur.

6.1.1. Demografik ve antropometrik özellikler

OSAS şüphesi ile ilgili kliniğe başvuran kişilerin teşhis ve tedavi için uyku laboratuvarlarına yatırılmasından önce hastalara ait demografik (yaş, cinsiyet, ırk vb.) ve antropometrik (boy, kilo, vücut kitle indeksi (BMI), boyun çevresi, bel çevresi vb.) bilgiler kliniklerde uyku uzmanları tarafından kayıt altına alınır. İleri yaş, erkek cinsiyet, kısa kalın boyun yapısı, obezite, sigara, alkol ve sedatif ilaç kullanımı gibi faktörler uykuda üst solunum yolunun açıklığını azaltan faktörlerdendir ve OSAS oluşumunu kolaylaştırmaktadır. Bu nedenle bu faktörlerin bilinmesi önem arz etmektedir.

Çalışma verilerinin alındığı laboratuvarında hastaların yalnızca yaş, cinsiyet ve BMI bilgilerinin tam olarak kaydedilmesi ve boyun çevresi, sigara-alkol kullanım oranı, sedatif ilaç kullanımı gibi bilgilerin hastaların çoğu için eksik olmasından dolayı, tez çalışmasında oluşturulan ilk özellik seti (**Özellik Seti 1: ÖS1**) CPAP terapisi ile tedavi edilmesi gerekli görülen hastaların yalnızca yaş, cinsiyet ve BMI değerlerini içerecek

şekilde oluşturulmuştur. Çizelge 6.1 ÖS1'i göstermektedir. Çizelgede görülen ÖS1_1, Özellik Seti 1'in 1. özelliği anlamına gelmektedir. Benzer şekilde ÖS1_2, Özellik Seti 1'in 2. özelliğini ve ÖS1_3, Özellik Seti 1'in 3. özelliğini ifade etmektedir. CPAP tahmini için hazırlanan diğer özellik setleri de aynı mantıkla numaralandırılmıştır.

Çizelge 6.1. Özellik Seti 1

Num.	Özellik
ÖS1_1	Yaş
ÖS1_2	Cinsiyet
ÖS1_3	BMI

*Num.: Özellik numarası

6.1.2. Hava akımı ve oksimetri sinyal özellikleri

OSAS, uyku sırasında üst solunum yolundaki tıkanıklıklar sonucu meydana gelen ve sık sık soluk kesilmeleri ile karakterize olan bir rahatsızlık olduğu için hava akımı (solunum) ve oksimetri sinyalleri bu rahatsızlığın teşhis ve tedavisinde temel teşkil eder. Hastalık şüphesiyle uyku kliniğine başvuran kişilerin hava akımı ve oksimetri sinyal özellikleri gece boyunca değişkenlik gösterir. OSAS teşhisi ve CPAP tedavisi de bu sinyallerin uyku uzmanları tarafından değerlendirilmesi ile gerçekleştirilir. Uyku uzmanları teşhis işlemi hava akımı sinyallerinin genlik ve soluk hızı değişimlerini ve oksimetri sinyallerindeki değer azalmasını (desaturasyon) temel olarak gerçekleştirirler. Tedavi gecesinde ise hastalara uygulanacak optimum basınç değeri kişiye ait yine bu sinyallerdeki değişimler dikkate alınarak belirlenir. Bu nedenle hava akımı ve oksimetri sinyallerinden elde edilen özellikler optimum CPAP seviyesinin tahmini için oldukça önemlidir. Bu bilgiler ışığında, **Özellik Seti 2 (ÖS2)** CPAP terapisi ile tedavi edilmesi gerekli görülen hastaların hava akımı ve oksimetri sinyallerinden çıkarılacak 39 özellikten oluşturulmuştur. Çizelge 6.2 ÖS2'yi tanımlamaktadır.

Çizelge 6.2. Özellik Seti 2

Sinyal	Num.	Özellik	
Güç Spektrum Özellikleri	ÖS2_1	Maksimum Güç	
	ÖS2_2	Baskın Frekans	
	ÖS2_3	Ortalama Güç	
	ÖS2_4	Ar-Parametrelerinin Özelliği	
Hava Akımı Sinyali	ÖS2_5	Mutlak Minimum	
	ÖS2_6	Maksimum	
	ÖS2_7	Mutlak Ortalama	
	ÖS2_8	Mutlak Ortanca	
	ÖS2_9	Standart Sapma	
	ÖS2_10	Varyans	
	İstatistiksel Özellikler	ÖS2_11	Çarpıklık
		ÖS2_12	Basıklık
	ÖS2_13	Hjorth parametreleri hareketlilik (mobility)	
	ÖS2_14	Hjorth parametreleri karmaşıklık(complexity)	
	ÖS2_15	Bazal Hava Akımı Değerinin %30'undan daha düşük değere sahip sinyal tepe (zirve-peak) değerlerinin oranı	
	ÖS2_16	Bazal Hava Akımı Değerinin %90'nından daha düşük değere sahip sinyal tepe değerlerinin oranı	
Güç Spektrum Özellikleri	ÖS2_17	Maksimum Güç	
	ÖS2_18	Baskın Frekans	
	ÖS2_19	Ortalama Güç	
	ÖS2_20	Ar-Parametrelerinin Özelliği	
Oksimetri Sinyali	ÖS2_21	Minimum	
	ÖS2_22	Maksimum	
	ÖS2_23	Ortalama	
	ÖS2_24	Standart Sapma	
	ÖS2_25	Varyans	
	ÖS2_26	Çarpıklık	
	ÖS2_27	Basıklık	
	ÖS2_28	Hjorth parametreleri hareketlilik (mobility)	
	ÖS2_29	Hjorth parametreleri karmaşıklık(complexity)	
	İstatistiksel Özellikler	ÖS2_30	Delta_İndeks
		ÖS2_31	ODIS2
		ÖS2_32	ODIS3
		ÖS2_33	ODIS4
		ÖS2_34	ODIS5
		ÖS2_35	70 değerinin altında kalan saat başına oksimetri sinyal değerlerinin sayısı
		ÖS2_36	80 değerinin altında kalan saat başına oksimetri sinyal değerlerinin sayısı
		ÖS2_37	85 değerinin altında kalan saat başına oksimetri sinyal değerlerinin sayısı
		ÖS2_38	90 değerinin altında kalan saat başına oksimetri sinyal değerlerinin sayısı
		ÖS2_39	95 değerinin altında kalan saat başına oksimetri sinyal değerlerinin sayısı

*Num.: Özellik numarası

ÖS2’de görüldüğü üzere ilk 16 özellik (ÖS2_1,...,ÖS2_16) hava akımı sinyaline ait güç spektrum ve istatistiksel özelliklerden, diğer 23 özellik (ÖS2_17,...,ÖS2_39) ise oksimetri sinyaline ait güç spektrum ve istatistiksel özelliklerden oluşmaktadır.

Hava akımı ve oksimetri sinyallerinin güç spektrum özellikleri AR yönteminin Burg tekniği kullanılarak elde edilmiştir. Bu teknik ile ön işlemlerden geçirilen hava akımı ve oksimetri sinyallerine ait güç spektrumları elde edilmiş ve spektrumlardan maksimum güç, baskın frekans, ortalama güç özellikleri elde edilmiştir. ÖS2’nin 4. ve 20. özelliklerini oluşturan AR parametrelerinin karakteristiğini yansıtan özellikler ise AR parametre değerlerinin kareleri toplamının karekökü alınarak elde edilmiştir.

ÖS2_15 ve ÖS2_16 sırasıyla hava akımı sinyallerindeki hipopne ve apnelerdeki %30 ve %90 azalmayı temsilen çıkarılan özellikler olmuştur. Bu özelliklerin çıkarılabilmesi için öncelikle hava akımı sinyallerine ait tepe değerler belirlenerek işaretlenmiştir. Ardından hava akımının her bir 30 saniyelik epogu incelenmiş ve tespiti yapılan apneik atakları içermeyen epoklara ait tepe değerlerinin ortalaması alınarak bazal değer hesaplanmıştır. Tüm sinyal göz önünde bulundurularak bu bazal değerden en az %30 ve %90 daha küçük olan tepe değerlerinin sayısı bulunmuş ve bu sayının tüm tepe değerleri sayısına oranı ile 15. ve 16. özellikler elde edilmiştir.

ÖS2_30 (Delta_Indeks) özelliği, oksimetri sinyallerindeki değişimi gözlemlemek amacıyla oluşturulmuştur. Xie ve Minn (2012)’nin önerdiği şekilde bu özelliğin hesaplanabilmesi için öncelikle oksimetri sinyali 12 sn’lik aralıklara bölünmüş ve her aralığın ortalama değeri hesaplanmıştır. Daha sonra Delta_Indeks ardışık bölümlerin ortalamalarının mutlak farklarının ortalaması alınarak hesaplanmıştır (Xie ve Minn, 2012).

ÖS2_31, ÖS2_32, ÖS2_33, ÖS2_34 oksijen desaturasyon indekslerini belirtmektedir. Bu değerler bazal oksimetri değerinin sırasıyla en az % 2 (ODIS2), % 3 (ODIS3), % 4 (ODIS4) ve % 5 (ODIS5) altına düşen saat başına oksimetre sinyal değerlerinin sayısı olarak hesaplanır. Bazal oksimetri değeri, apneik atak içermeyen 30sn’lik epokların oksimetri sinyal değerlerinin ortalaması alınarak hesap edilmiştir.

6.1.3. Hava akımı ve oksimetri sinyallerinin doğrusal olmayan özellikleri

Bölüm 5.1’de bahsedildiği gibi hem uyku hem de uyku ile ilişkili solunum bozuklukları yapısı gereği doğrusal olmayan bir davranış sergiler. Dolayısıyla uyku bozukluğu olan bireylerin uykuları sırasında kaydedilen vücut sinyalleri de doğrusal

olmayan dinamikler sergiler ve varyasyonlara sahiptir. Bu nedenle tez çalışması kapsamında optimum CPAP seviyelerinin tahmini için oluşturulan **Özellik Seti 3(ÖS3)**, CPAP terapisi ile tedavi edilmesi gerekli bulunan hastaların ön işlemlerden geçirilmiş hava akımı ve oksimetri sinyallerinin doğrusal olmayan özelliklerini içermektedir. Çizelge 6.3, ÖS3'ü göstermektedir.

Çizelge 6.3. Özellik Seti 3

Sinyal	Num.	Özellik
Hava Akımı Sinyali	ÖS3_1	Herbir q değeri için hesaplanan Hurst üstellerinin ortalaması.
	ÖS3_2	Maksimum Hurst üstel değeri
	ÖS3_3	Minimum Hurst üstel değeri
	ÖS3_4	Genelleştirilmiş Hurst Üsteli
	ÖS3_5	Maksimum tekillik üsteli
	ÖS3_6	Minimum tekillik üsteli
	ÖS3_7	Tekillik üstellerinin ortalama değeri
	ÖS3_8	Çokfraktallı spektrumun maksimum değerine karşılık gelen tekillik üsteli
	ÖS3_9	Asimetrik İndeks Değeri
	ÖS3_10	Spektrumun maksimum değerine karşılık gelen tekillik üsteli ile minimum tekillik üsteli arasındaki yatay mesafe
	ÖS3_11	Spektrumun maksimum değerine karşılık gelen tekillik üsteli ile maksimum tekillik üsteli arasındaki yatay mesafe
	ÖS3_12	Çokfraktallı spektrumun maksimum değeri
	ÖS3_13	Çokfraktallı spektrumun ortalama değeri
	ÖS3_14	Çokfraktallı spektrumun çarpıklık değeri
	ÖS3_15	Çokfraktallı spektrumun basıklık değeri
	ÖS3_16	Çokfraktallı spektrumun varyansı
	ÖS3_17	Maksimum tekillik üsteline denk gelen çokfraktallı spektrum değeri
	ÖS3_18	Minimum tekillik üsteline denk gelen çokfraktallı spektrum değeri
	ÖS3_19	Çokfraktallı spektrum genişliği
	ÖS3_20	Çokfraktallı spektrum yüksekliği
	ÖS3_21	Spektrumun sağ kesimi. (Maksimum spektrum değeri ile maksimum tekillik üstel değerine karşılık gelen spektrum değerinin farkı)
	ÖS3_22	Spektrumun sol kesimi. (Maksimum spektrum değeri ile minimum tekillik üstel değerine karşılık gelen spektrum değerinin farkı)
	ÖS3_23	Spektrumdaki düşey mesafe
	ÖS3_24	H_YakEn
	ÖS3_25	H_ÖrEn
	ÖS3_26	H_CTM25
	ÖS3_27	H_CTM50
	ÖS3_28	H_CTM75
	ÖS3_29	H_CTM100
	ÖS3_30	H_LZK
Oksimetri Sinyali	ÖS3_31	O_YakEn
	ÖS3_32	O_ÖrEn
	ÖS3_33	O_CTM25
	ÖS3_34	O_CTM50
	ÖS3_35	O_CTM75
	ÖS3_36	O_CTM100
	ÖS3_37	O_LZK

*Num.: Özellik numarası

ÖS3'e ait ilk 23 özellik, Bölüm 5.1'de bahsedildiği şekilde hava akımı sinyallerine ait oluşturulan çokfraktallı spektrumlardan elde edilmiştir. ÖS3'ün geri kalan 14 özelliğini ise hem hava akımı hem de oksimetri sinyallerine ait entropi ölçüleri (YakEn ve ÖrEn), Merkezi eğilim ölçüleri (CTM) ve Lempel Ziv Karmaşıklığı (LZK) oluşturmaktadır.

ÖS3'deki son 14 özelliğin oluşturulabilmesi için öncelikle Jiménez-García ve ark. (2020) tarafından önerildiği gibi hem hava akımı hem de oksimetri sinyalleri 30 sn'lik epoklara ayrıştırılmıştır. Ardından Çizelge 6.3'teki 24. özellikten 37. özelliğe kadar olan tüm özellikler sinyallerin her bir epogu için çıkarılmıştır. Her bir sinyal için nihai özellik bu epok özelliklerinin ortalaması alınarak elde edilmiştir.

Hava akımı sinyalleri için yaklaşık ve örnek entropilerin hesaplamasında kullanılan tolerans değeri (ϵ) ve gömülü uzayın boyutu (m) literatür çalışmalarına göre Yamauchi ve ark. (2011) ve Gutierrez-Tobal ve ark. (2013)'ün önerdiği gibi sırasıyla sinyalin standart sapmasının 0.2 katı ve 2 olarak belirlenmiştir. Aynı şekilde oksimetri sinyallerine ait bu entropi değerleri için ise yine literatür çalışmalarına göre (Alvarez ve ark., 2006; Hornero ve ark., 2007; Alvarez ve ark., 2010; Crespo ve ark., 2017) ϵ değeri oksimetri sinyalinin standart sapmasının 0.25 katı olarak, gömülü boyutun değeri m ise 1 olarak seçilmiştir.

Hem hava akımı (H) hem de oksimetri (O) sinyallerine ait olan H_{CTM25} , H_{CTM50} , H_{CTM75} , H_{CTM100} , O_{CTM25} , O_{CTM50} , O_{CTM75} , O_{CTM100} özellikleri merkezi eğilim ölçülerini ifade etmektedir. Bölüm 4'te bahsedildiği gibi bu özellikler Denklem 4. 25'te belirtilen fark grafiğinin merkezinden belirtilen yarıçaplarda çizilen çember içerisinde kalan sinyal değerlerinin, sinyal uzunluğuna bölünmesi ile hesaplanır (Alvarez ve ark., 2006). Bu özellikler için yarıçap değerleri 0.25, 0.50, 0.75 ve 1 olarak belirlenmiştir (Alvarez ve ark., 2006; Xie ve Minn, 2012).

ÖS3'ün 30. ve 37. özellikleri H_{LZK} ve O_{LZK} hava akımı ve oksimetri sinyallerine ait Lempel Ziv karmaşıklığını belirtmektedir. Bu ölçütte Bölüm 4'te belirtildiği gibi bir eşik değerine ihtiyaç duyulmaktadır. Bu eşik değerine göre sinyal 0-1 şeklindeki sembolik bir diziyeye dönüştürülür ve karmaşıklık ölçütü o dizi üzerinden hesaplanır. Hem hava akımı hem de oksimetri sinyalleri için LZK eşik değeri sinyal değerlerinin ortanca değeri alınarak hesaplanmıştır.

6.1.4. Apneik atak ve desaturasyon özellikleri

Apneik ataklarla ilişkili olan özellikler örneğin AHI değeri kişilerin OSAS derecesinin (hafif, orta, ağır) belirlenmesinde kullanılan ölçütlerdendir. Literatürde yapılan çalışmalar (Otero ve ark., 2012; Kulkas ve ark., 2013) AHI değerinin dışında birçok özelliğin hastalık derecesine etki edebileceğini savunmuş, apneik ataklarla ilişkili farklı özellikler önermiş (apne-hipopne süresi, desaturasyon özellikleri vb.) ve yaptıkları çalışmalar sonucunda, AHI'den daha etkili özelliklerin olduğunu belirtmişlerdir (Otero ve ark., 2012; Kulkas ve ark., 2013). Bu gibi özellikler OSAS derecesinin belirlenmesinde literatürde birçok kez kullanılmasına rağmen, CPAP seviyelerinin optimum olarak belirlenmesi için yapılan hiçbir çalışmada değerlendirmeye alınmamıştır. Bu nedenle gerçekleştirilen tez çalışması kapsamında, optimum CPAP seviyelerinin tahmini için oluşturulan ve Çizelge 6.4'te görülen **Özellik Seti 4 (ÖS4)**, CPAP terapisi ile tedavi edilmesine karar verilen hastaların tespit edilen apneik ataklarına ait özellikleri, desaturasyon özelliklerini ve atakları takiben oluşabilen hiperpne örüntü özelliklerini içermektedir.


ÖS4'te bahsedilen hiperpne, solunum derinliğinin artması manasına gelmektedir. Apneik atakların bitiminde yeniden nefes alınabilmesi için üst hava yolları aniden tekrar açılır ve tüm ataklarda olmasa da bazen hastaların atağı sonlandırması için çok derin nefes almaları hava akımı sinyallerinde gözlenen hiperpne örüntülerinin ortaya çıkmasına neden olur. Daha önce Bölüm 5.2'de bahsedildiği gibi, üst solunum yolunun ani açılması sebebiyle hava akım sinyallerinde çok ani pikler, çok büyük değerler ortaya çıkmaktadır. Bu büyük değerler Denklem 5.8 ve 5.9 kullanılarak belirlenmiş ve apneik atak tespitinde aykırı değer olarak tanımlanmıştı. Bu tez çalışması kapsamında hiperpne örüntüleri tanımlanırken de ön işlemlerden geçirilmiş hava akımı sinyallerinin tepe değerleri için Denklem 5.8 ve 5.9 kullanılarak bir eşik değeri belirlenmiş ve atakların bitimindeki bu eşik değerden büyük sinyal tepe değerlerini içeren solunum döngüleri hiperpne olarak belirlenmiştir. Ardından, ÖS4'ün son 4 özelliği de hava akımı sinyallerindeki bu hiperpne örüntülerinden çıkarılmıştır.

Şekil 6.1 ÖS4'ü oluşturan bazı özellikleri göstermektedir. Şekil 6.2 ise apneik bir atak sonucunda oluşan hiperpne örüntüsünü ve ondan çıkarılan özellikleri göstermektedir.

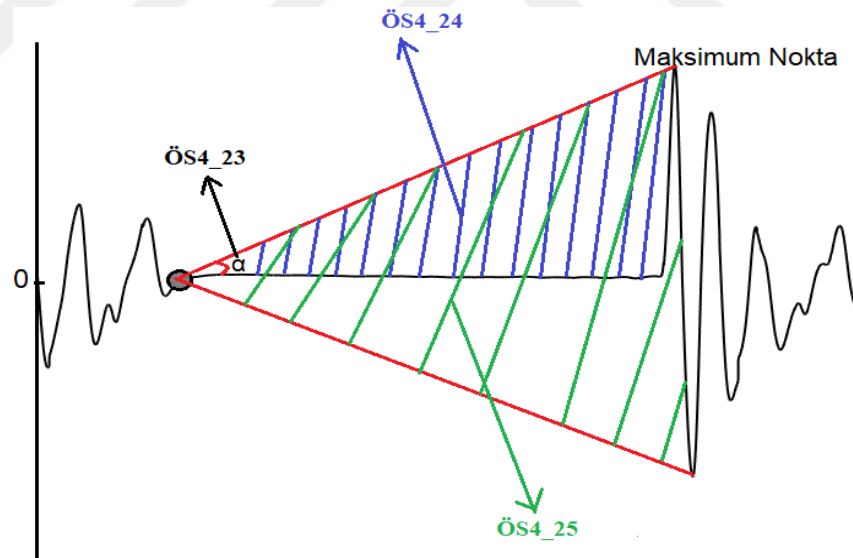
Çizelge 6.4. Özellik Seti 4

Num.	Özellik
ÖS4_1	Apne Hipopne İndeksi (AHI)
ÖS4_2	Ortalama apneik atak süresi
ÖS4_3	Maksimum apneik atak süresi
ÖS4_4	Uyku boyunca hastanın apneik atakta kaldığı süre oranı (Apneik atak süreleri toplamının toplam uyku süresine oranı)
ÖS4_5	Ortalama desaturasyon süresi
ÖS4_6	Maksimum desaturasyon süresi
ÖS4_7	Uyku boyunca hastanın desaturasyonda kaldığı süre oranı (Desaturasyon süreleri toplamının toplam uyku süresine oranı)
ÖS4_8	Ortalama (apneik atak + desaturation) süresi
ÖS4_9	Maksimum (apneik atak + desaturation) süresi
ÖS4_10	Uyku boyunca hastanın apneik atakta ve desaturasyonda kaldığı süre oranı (Apneik atak ve desaturasyon süreleri toplamının toplam uyku süresine oranı)
ÖS4_11	Desaturasyon başlangıcından desaturasyon süresince oksimetri değerinin minimum olduğu ana kadar geçen ortalama süre
ÖS4_12	Desaturasyon başlangıcı ile desaturasyon süresince oksimetri'nin minimum olduğu değer arasındaki ortalama genlik
ÖS4_13	Desaturasyon süresince oksimetri sinyalinin minimum olduğu değerden desaturasyon sonuna kadar geçen ortalama süre
ÖS4_14	Desaturasyon süresince oksimetrimin minimum olduğu değer ile desaturasyon bitişi arasındaki ortalama genlik
ÖS4_15	Apneik atak başlangıcından desaturasyon başlangıcına kadar geçen ortalama süre
ÖS4_16	Apneik atak bitişinden desaturasyon bitişine kadar geçen ortalama süre
ÖS4_17	Apneik atak bitişinden desaturasyon süresince oksimetri sinyal değerinin minimum olduğu ana kadar geçen ortalama süre
ÖS4_18	Apneler arası ortalama süre
ÖS4_19	Desaturasyon düşme eğimi (Desaturasyon başlangıcı ile desaturasyon minimumu arasındaki eğim)
ÖS4_20	Desaturasyon yükselme eğimi (Desaturasyon minimumu ile desaturasyon bitişi arasındaki eğim)
ÖS4_21	Desaturasyon alanı
ÖS4_22	Hiperpne örüntülerinin sayısı
ÖS4_23	Apneik atak başlangıcı ile apneik atak sonucunda oluşan hiperpne örüntülerinin maksimum değeri arasındaki ortalama açı
ÖS4_24	Apneik atak başlangıcı ile apneik atak sonucunda oluşan hiperpne örüntülerinin maksimum değeri arasındaki ortalama alan
ÖS4_25	Apneik atak başlangıcı ile apneik atak sonucunda oluşan hiperpne örüntüsünde oluşan maksimum genliğe göre ortalama alan

*Num.: Özellik numarası



Şekil 6.1. ÖS4'e ait bazı özelliklerin hesaplanması

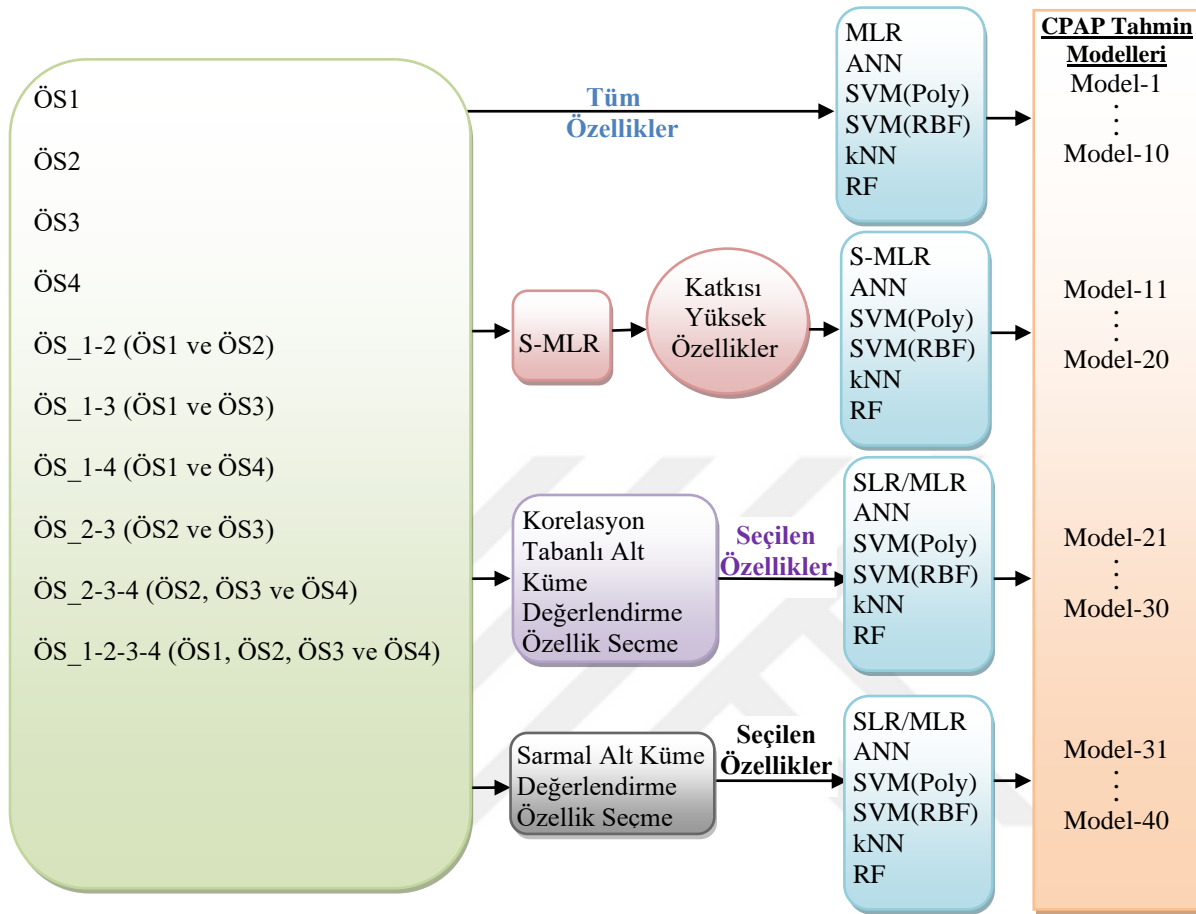


Şekil 6.2. ÖS4'te bulunan 4 hiperpne özelliklerinin hesaplanması

6.2. Tahmin Modelleri

Bu tez çalışmasında oluşturulan özellik setlerindeki özelliklerin doğrusal regresyon analizleri (SLR veya MLR(SLR/MLR) ve S-MLR) ve farklı yapay zeka yöntemleri (ANN, PolyKernel fonksiyonlu SVM, RBFKernel fonksiyonlu SVM, kNN ve RF) ile kullanılması sonucunda “CPAP terapisi ile tedavi edilmesi gereklidir” olarak

belirlenen hastaların optimum CPAP seviyeleri tahmin edilmiş ve CPAP tahmin modelleri geliştirilmiştir. Şekil 6.3, CPAP tahmin modellerinin geliştirilme sürecini özetlemektedir.



Şekil 6.3. Tahmin modeli geliştirme süreci

Şekil 6.3'ten görüldüğü üzere, optimum CPAP seviyelerinin tahmini için 4 özellik setinin kullanılması haricinde bu özellik setleri birlikte de değerlendirilerek CPAP seviye tahminleri gerçekleştirilmiştir. Böylelikle 6 özellik seti daha türetilmiş olup, toplamda 10 özellik seti elde edilmiştir. 10 özellik seti kullanılarak optimum CPAP seviyelerinin tahmini 4 farklı şekilde gerçekleştirilmiştir.

1. Özellik setlerindeki özelliklerin tamamı doğrusal regresyon analizi, ANN, PolyKernel fonksiyonlu SVM, RBFKernel fonksiyonlu SVM, kNN ve RF yöntemleri ile birlikte kullanılmış ve hastalara ait optimum CPAP seviyeleri tahmin edilmiştir. Regresyon analizi sırasında tüm özellikler bağımsız değişken olarak değerlendirildiği için birden fazla bağımsız değişken içerilmiş ve dolayısıyla kullanılan doğrusal regresyon analizi çoklu değişkenleri içeren MLR analizi olmuştur. Tahmin süreçleri sonucunda her

bir özellik seti için en yüksek başarıyı sağlayan yöntem ile geliştirilen model *CPAP tahmin modeli* olarak kabul edilmiştir. Böylelikle bu tahmin işlemleri sonucunda 10 adet özellik setindeki özelliklerin kullanılmasıyla 10 adet CPAP tahmin modeli elde edilmiştir.

2. Tüm özellik setlerindeki özelliklerin S-MLR ile analizi sırasında sonuca katkısı en fazla olan özellikler yüksek korelasyon değerlerine göre analiz tarafından otomatik olarak belirlenmiş ve optimum CPAP seviye tahminleri yalnızca belirlenen özellikler kullanılarak gerçekleştirilmiştir. Her bir özellik seti için S-MLR analizi ile belirlenen özellikler ayrıca ANN, PolyKernel fonksiyonlu SVM, RBFKernel fonksiyonlu SVM, kNN ve RF yapay zeka yöntemleri ile de kullanılmış ve optimum CPAP seviyelerinin tahmini gerçekleştirilmiştir. Sonuç olarak her bir özellik seti için en yüksek performansı sağlayan yöntem ile geliştirilen model *CPAP tahmin modeli* olarak kabul edilmiştir. Bu sayede 10 adet özellik setinin S-MLR analizi ile belirlenen özelliklerinin kullanılmasıyla 10 adet CPAP tahmin modeli daha üretilmiştir.
3. 10 özellik setinin her birine Korelasyon Tabanlı Alt Küme Değerlendirme özellik seçme yöntemi uygulanmış ve bu yöntem ile CPAP seviyeleri üzerinde en etkili olan özellikler seçilmiştir. Her bir özellik setinin seçilen özelliklerinin özellik sayısına göre SLR veya MLR analizlerinden biri ve ANN, PolyKernel fonksiyonlu SVM, RBFKernel fonksiyonlu SVM, kNN ve RF yapay yöntemleri ile kullanılmasıyla hastalara ait optimum CPAP seviyeleri tahmin edilmiştir. Özellik setleri için seçilen etkin özellikleri kullanarak en yüksek başarıyı üreten yöntemler ile oluşturulan modeller CPAP tahmin modeli olarak tanımlanmış, bu sayede 10 adet CPAP tahmin modeli geliştirilmiştir.
4. 10 özellik setinin her birine Sarmal Alt Küme Değerlendirme özellik seçim yöntemi uygulanmış ve optimum CPAP seviyeleri üzerinde en çok etkiye sahip olan özellikler seçilmiştir. Her bir özellik seti için Sarmal Alt Küme Değerlendirme yöntemi ile seçilen özelliklerin özellik sayısına göre SLR veya MLR analizlerinden biri ve ANN, PolyKernel fonksiyonlu SVM, RBFKernel fonksiyonlu SVM, kNN ve RF yapay zeka yöntemleri ile birlikte kullanılması sonucunda hastalara ait optimum CPAP seviyeleri tahmin edilmiştir. Her bir özellik seti için seçilen özellikleri kullanarak en yüksek

başarının elde edilmesini sağlayan yöntem ile geliştirilen model, **CPAP tahmin modeli** olarak tanımlanmış ve 10 adet CPAP tahmin modeli geliştirilmiştir.

Gerçekleştirilen tüm bu işlemlerle tez çalışması kapsamında 240 farklı optimum CPAP seviye tahmini gerçekleştirilmiş ve nihai olarak yüksek performansların sağlandığı sonuçlara göre toplam 40 adet CPAP tahmin modeli ortaya konmuştur.



7. SONUÇLAR VE TARTIŞMA

Bu tez çalışmasında öncelikle Doğrusal Olmayan Analiz Yaklaşımı ve Kural Tabanlı Algoritma Yaklaşımı kullanılarak çalışmaya dahil edilen 145 kişinin OSAS hastası olup olmadığı ve CPAP terapisi ile tedavi edilmeye ihtiyaç duyup duymadığı belirlenmiştir. Ardından, CPAP terapisine ihtiyacı olan hastaların, tedavi edici optimum CPAP seviyelerinin tahmini gerçekleştirilmiş ve CPAP tahmin modelleri geliştirilmiştir. Bu bölüm tez çalışması kapsamında gerçekleştirilen tüm bu işlemlerin sonuçlarını içermektedir.

7.1. OSAS Teşhisi ve CPAP Tedavi Gerekliliğini Belirleme Çalışmaları Sonuçları

Bu tez çalışmasının temel amacı olan optimum CPAP seviyelerinin tahmin edilebilmesi için öncelikle, çalışmaya dahil edilen kişilerin OSAS hastası olup olmadıkları ve CPAP terapisi ile gerçekleştirilen tedaviyi gerektirip gerektirmediği belirlenmelidir. Bu durumları belirlemenin ilk yolu kişilerin AHI değer aralıklarının yani hangi AHI alt grubuna dahil olduklarının tanımlanmasıdır. Gerçekleştirilen tez çalışması kapsamında, 2 farklı yaklaşım ile kişilerin dahil oldukları AHI alt grupları belirlenmiş ve yaklaşımların sonuçları karşılaştırılmıştır. İlk yaklaşımı, kişilerin yalnızca hava akımı sinyallerine ait doğrusal olmayan özelliklerin MDFA yöntemiyle çıkarılması ve bu özelliklerin farklı sınıflandırma algoritmaları (RF, ANN, SVM, NB ve kNN) tarafından kullanılarak kişilerin 3 farklı AHI alt grubundan ($AHI < 5$, $5 \leq AHI < 15$, $15 \leq AHI$) birine dahil edilmesi oluşturmaktadır. İkinci yaklaşımda ise, başlangıçta ön işlemlerden geçirilmiş hava akımı ve oksimetre sinyalleri kullanılarak hastaların gece boyunca geçirmiş oldukları apneik ataklar, geliştirilen kural tabanlı algoritma ile otomatik olarak tespit edilmiş ve ataklara eşlik eden oksijen desaturasyonları belirlenmiştir. Tespit edilen ataklara göre AHI değerleri hesaplanmış ve bu değerlere göre kişilerin AHI alt grupları belirlenmiştir.

Gerçekleştirilen 2 yaklaşımın sonuçları aşağıda sırasıyla verilmiş ve sonuçlar yorumlanmıştır.

7.1.1. Doğrusal olmayan analiz yaklaşımına ait sonuçlar

Bu yaklaşımda, uyku bozukluğundan muzdarip 145 kişinin OSAS hastası olup olmadığı ve CPAP terapisi ile sağlanan tedaviye ihtiyaç duyup duymadığı, kişilerin AHI alt gruplarının otomatik olarak tanımlanmasıyla bulunmaktadır. Bunun için öncelikle kişiler rastgele %60'ı eğitim ve %40'ı test olacak şekilde 2 gruba ayrıştırılmıştır. Eğitim grubundaki 87 kişiden 53'ünün AHI değerleri 15'e eşit ve daha büyüktür ($15 \leq \text{AHI}$) ve bu kişilerin tedavisi için CPAP terapisinin uygulanması gerekmektedir. Eğitim grubundaki 17 kişinin AHI'si 5 ile 15 arasındadır ($5 \leq \text{AHI} < 15$) ve geriye kalan 17 kişinin AHI değerleri de 5'in altındadır ($\text{AHI} < 5$). 145 kişinin kalan 58'i ise test grubunu oluşturmaktadır. Test grubundaki 26 kişinin AHI değerleri 15'e eşit ve daha büyüktür. Test grubundaki geriye kalan 32 kişinin 16'sının AHI değerleri 5 ile 15 arasında iken 16'sının AHI değerleri de 5'ten küçüktür.

Yaklaşımda hem eğitim hem de test grubundaki kişilerin hava akımı sinyallerine ait MDFA yöntemi ile çokfraktallı spektrumlar elde edilmiş ve bu spektrumlar kullanılarak sinyallere ait 23 doğrusal olmayan özellik çıkarılmıştır. Daha sonra, eğitim grubuna dahil olan kişilere ait özelliklere *Bilgi Kazancı Özellik Değerlendirme*, *Korelasyon Özellik Değerlendirme*, *OneR Özellik Değerlendirme*, *Korelasyon Tabanlı Alt Küme Değerlendirme* ve *Sarmal Alt Küme Değerlendirme* olmak üzere 5 farklı özellik seçme yöntemi uygulanmıştır. Bu işlemlerin ardından, eğitim grubunun üç sınıflı ($\text{AHI} < 5$, $5 \leq \text{AHI} < 15$, $15 \leq \text{AHI}$) sınıflandırma süreci, hem çıkarılan tüm özellikler hem de her bir özellik seçme yöntemi tarafından belirlenen özellikler kullanılarak 10 kat çapraz doğrulama yaklaşımı RF algoritması ile gerçekleştirilmiştir. Eğitim grubunun sınıflandırılmasında maksimum performansı veren sınıflandırıcı parametrelerine göre test grubunda bulunan kişiler de aynı özellikler ve RF ile üç AHI alt grubundan birine atanmıştır.

Çizelge 7.1, özellik seçme yöntemleri ile seçilen özellikleri, RF ile gerçekleştirilen tüm sınıflandırmalar sonucunda elde edilen sınıflandırma doğruluklarını ve kappayı istatistiksel değerlerini göstermektedir. Bu çizelge ayrıca her bir sınıflandırma işleminde eğitim grubuna göre maksimum sonuç elde edilmesini sağlayan RF sınıflandırıcısında kullanılan ağaç sayısını da göstermektedir. Test grubu sınıflandırılması da eğitim grubuna göre belirlenen bu ağaç sayılarına sahip RF sınıflandırıcılar ile gerçekleştirilmiştir.

Çizelge 7.1. Yaklaşım 1 için özellik seçme yöntemlerine göre RF sınıflandırma sonuçları

RF Ağaç Sayısı	Özellik Seçme Yöntemi	Özellikler	Eğitim		Test	
			CA(%)	K	CA(%)	K
100	-	Tüm Özellikler	79.31	0.64	79.31	0.68
101	Bilgi Kazancı	ÇF2, ÇF3, ÇF4, ÇF5, ÇF6, ÇF7, ÇF11	80.46	0.65	82.76	0.72
70	Korelasyon Özellik Değerlendirme	ÇF3, ÇF6, ÇF8, ÇF9, ÇF13, ÇF15, ÇF17, ÇF18, ÇF20, ÇF21, ÇF23	81.61	0.66	84.48	0.75
100	One R	ÇF1, ÇF2, ÇF3, ÇF4, ÇF5, ÇF6, ÇF7, ÇF13, ÇF19	80.46	0.64	81.03	0.70
110	Korelasyon Alt Küme Değerlendirme	ÇF3, ÇF4, ÇF6, ÇF7, ÇF9, ÇF18, ÇF22	86.21	0.75	87.93	0.80
90	Sarmal Alt Küme Değerlendirme	ÇF4, ÇF6, ÇF9, ÇF15, ÇF18, ÇF23	87.36	0.77	89.66	0.84

Çizelge 7.1'de sunulduğu üzere, ilk sınıflandırma 23 özelliğin tümü ile gerçekleştirilmiştir. Bu sınıflandırmada hem eğitim hem de test grupları için doğruluk %79.31 olarak elde edilmiştir. Daha sonra, farklı özellik seçme yöntemleri ile etkili özellikler belirlenmiş ve bu özellikler kullanılarak yapılan sınıflandırmalar daha az özellik ile daha iyi sonuçlar üretmiştir.

Çizelge 7.1'de görülen ilk üç özellik seçim yöntemi, özellikleri bağımsız olarak değerlendirmiş ve her özelliğe bir puan atamıştır. Bu yöntemlerle özellik seçiminde öncelikle en yüksek puana sahip ilk 3 özellik RF sınıflandırma algoritması ile değerlendirilmiştir. Daha sonra özellikler etkinlik puanlarına göre sırasıyla eklenmiş ve sınıflandırma işlemi her defasında RF ile tekrarlanmıştır. Nihayetinde, en iyi özellikler maksimum sınıflandırma sonucunu verecek şekilde belirlenmiştir. Buna göre Bilgi Kazancı, Korelasyon Özellik Değerlendirme ve OneR yöntemleri ile sırasıyla 7 özellik, 11 özellik ve 9 özellik en etkililer olarak belirlenmiştir. Çizelge 7.1, bu 3 özellik seçim yöntemi arasında 11 özellikli Korelasyon Özellik Değerlendirme yönteminin, eğitim ve test grubu sınıflandırması için sırasıyla %81.61 ve %84.48 ile en yüksek sınıflandırma doğruluklarını sağladığını göstermektedir. Ayrıca bu sınıflandırmada kappa değerleri de eğitim ve test grupları için 0.66 ve 0.75 bulunarak hem tüm özelliklerin sınıflandırılmasında hem de Bilgi Kazancı ve OneR yöntemlerine göre yapılan sınıflamalarda elde edilenlere kıyasla daha yüksek bulunmuştur.

Korelasyon Alt Küme Değerlendirme ve Sarmal Alt Küme Değerlendirme seçim yöntemleri en iyi arama (best-first search) tekniği ile özelliklerin farklı alt kümelerini değerlendirerek en etkili özellik alt kümesine karar vermişlerdir. Korelasyon Alt Küme Değerlendirme tarafından 7 özellik en etkili olarak seçilmiş ve bu özelliklerin RF ile

sınıflandırılması sonucunda eğitim grubunda %86.21 sınıflandırma doğruluğu ve 0.75 kappa değeri, test grubunda %87.93 sınıflama doğruluğu ve 0.80 kappa değeri elde edilmiştir. Sarmal Alt Küme Değerlendirme yönteminin uygulanması ile 6 özellikli özellik alt kümesi en iyi sonucu vermiş ve bu özellikler ile yapılan sınıflandırmada eğitim grubu için %87.36 doğruluğa ve 0.77 kappa değerine ulaşılmıştır. Bu sınıflama test grubu için ise %89.66 sınıflandırma doğruluğu ve 0.84 kappa değeri üretmiştir.

Çizelge 7.1, Korelasyon Alt Küme Değerlendirme ve Sarmal Alt Küme Değerlendirme yöntemlerinde olduğu gibi özelliklerin birlikte değerlendirilmesinin bireysel değerlendirmeye göre performansı artırdığını göstermektedir. Bu çizelge ayrıca bu sınıflamaların sonucunda Sarmal Alt Küme Değerlendirme yöntemi ile seçilen 6 özelliğin en yüksek doğruluk ve kappa değerlerini sağladığını da göstermektedir. Bu nedenle bu 6 özellik en etkin özellikler olarak kabul edilmiştir. Bu özellikler;

ÇF4: Genelleştirilmiş Hurst üsteli

ÇF6: Minimum tekillik üsteli değeri (min hq)

ÇF9: Asimetrik indeks değeri

ÇF15: Çokfraktallı spektrumun basıklık değeri

ÇF18: Minimum tekillik üsteline denk gelen spektrum değeri ($F\alpha(\alpha_{min})$).

ÇF23: Spektrumdaki düşey mesafe ($F\alpha(\alpha_{min})$ ve $F\alpha(\alpha_{max})$ arasındaki düşey mesafe)

Bu 6 özellik ve 90 ağaçtan oluşan RF sınıflandırıcısı kullanılarak gerçekleştirilen eğitim grubunun detaylı sınıflandırma sonuçları Çizelge 7.2'te, bu sınıflamaya ait konfüzyon matrisi de Çizelge 7.3'te verilmiştir.

Çizelge 7.2. Sarmal Alt Küme Değerlendirme yöntemi ile seçilen 6 özellik ve RF ile eğitim sonuçları

Sınıf	Duyarlılık (%)	Özgüllük (%)	Kesinlik (%)	F-Skor (%)	CA(%)	K
15≤AHI	90.57	88.24	92.31	91.43		
5≤AHI<15	82.35	95.71	82.35	82.35	87.36	0.77
AHI<5	82.35	94.29	77.78	80.00		

Çizelge 7.3. Sarmal Alt Küme Değerlendirme yöntemi ile seçilen 6 özellik ve RF ile eğitim sonucu konfüzyon matrisi

		Tahmin		
		15≤AHI	5≤AHI<15	AHI<5
Gerçek	15≤AHI	48	2	3
	5≤AHI<15	2	14	1
	AHI<5	2	1	14

Çizelge 7.2 ve Çizelge 7.3'te görüldüğü gibi, eğitim grubundaki AHI değeri 15'ten büyük 53 hastanın 48'i doğru sınıflanmış ve %90.57 duyarlılık, %88.24

özgüllük, %92.31 kesinlik ve %91.43 F-Skor değerleri elde edilmiştir. Hem $5 \leq \text{AHI} < 15$ sınıfında hem de $\text{AHI} < 5$ sınıfında bulunan kişilerden 3'er kişi yanlış sınıflanmış ve bu iki sınıf için de %82.35 duyarlılık değerleri elde edilmiştir.

Sarmal Alt Küme Değerlendirme ile seçilen etkin 6 özelliğin ve 90 ağaçlı RF algoritmasının kullanılmasıyla test grubu için elde edilen detaylı sınıflandırma sonuçları Çizelge 7.4'te gösterilmektedir. Çizelge 7.5 de bu sınıflandırmaya ait konfüzyon matrisini göstermektedir.

Çizelge 7.4. Sarmal Alt Küme Değerlendirme yöntemi ile seçilen 6 özellik ve RF ile test sonuçları

Sınıf	Duyarlılık (%)	Özgüllük (%)	Kesinlik (%)	F-Skor (%)	CA(%)	K
$15 \leq \text{AHI}$	100	81.25	81.25	89.66		
$5 \leq \text{AHI} < 15$	81.25	100	100	89.66	89.66	0.84
$\text{AHI} < 5$	81.25	100	100	89.66		

Çizelge 7.5. Sarmal Alt Küme Değerlendirme yöntemi ile seçilen 6 özellik ve RF ile test sonucu konfüzyon matrisi

		Tahmin		
		$15 \leq \text{AHI}$	$5 \leq \text{AHI} < 15$	$\text{AHI} < 5$
Gerçek	$15 \leq \text{AHI}$	26	0	0
	$5 \leq \text{AHI} < 15$	3	13	0
	$\text{AHI} < 5$	3	0	13

Çizelge 7.4 ve 7.5'in gösterdiği üzere, test grubundaki $15 \leq \text{AHI}$ sınıfında bulunan kişilerin tamamı doğru sınıflandırılmış ve %100 duyarlılık elde edilmiştir. Diğer iki sınıfta da 3'er kişi yanlış sınıflandırılmış ve %81.25'er duyarlılıklara ulaşılmıştır.

Bu yaklaşımda Sarmal Alt Küme Değerlendirme yöntemi ile seçilen ve etkin olarak belirlenen özellikler RF sınıflandırma algoritması dışında ayrıca ANN, PolyKernel ve RBFKernel fonksiyonlu SVM, NB ve kNN ile de sınıflandırılmış ve bu sınıflandırıcıların performansları (sınıflama doğruluğu ve Kappa değerleri) Çizelge 7.6'da gösterilmiştir.

Çizelge 7.6. Etkin 6 özelliğin ANN, SVM, NB ve kNN sınıflayıcıları ile sınıflandırılma sonuçları

Sınıflandırıcı	3-sınıf ($\text{AHI} < 5$, $5 \leq \text{AHI} < 15$, $15 \leq \text{AHI}$)			
	Eğitim		Test	
	CA(%)	K	CA(%)	K
ANN (öo:0.3, m:0.1, İterasyon:500)	73.56	0.50	82.76	0.72
SVM (c:10, 2. Dereceden PolyKernel)	73.56	0.48	72.41	0.55
SVM (c:21, RBFKernel)	72.41	0.49	70.69	0.52
NB	73.56	0.48	75.86	0.61
kNN (k=4)	75.06	0.54	67.04	0.47

*öo: öğrenme oranı, m:momentum, c: ceza parametresi

Çizelge 7.1 ve Çizelge 7.6’da görüldüğü gibi, tüm sınıflandırıcılar arasından en yüksek performansı hem CA hem de K değerleri bakımından RF sağlamıştır. RF’den sonra ikinci iyi performansı ANN gösterdiği de Çizelge 7.6’dan açıkça gözlemlenmektedir.

OSAS teşhisi ve CPAP terapisi ile tedavi gerekliliğinin belirlenmesi amacıyla gerçekleştirilen bu yaklaşım sonucunda, AHI alt gruplarının tanımlanması için en yüksek performans RF sınıflayıcısı tarafından sağlanmıştır. Bu nedenle, bu yaklaşımda, AHI alt grupları tanımlanan 145 kişinin OSAS hastası olup olmadığı ve CPAP terapi tedavisini gerektirip gerektirmediği RF sınıflayıcı sonuçlarına göre yapılmıştır.

Sarmal Alt Küme Değerlendirme özellik seçme yöntemi ile elde edilen 6 özelliğin ve RF sınıflandırıcısının birlikte kullanılması sonucundaki hem eğitim hem test grubu sonuçlarının değerlendirmesi birlikte yapıldığında aşağıda verilen çıkarımlar yapılabilir;

- $15 \leq \text{AHI}$ sınıfında bulunan yani OSAS hastası ve CPAP terapi tedavisi gerektiren toplam 79 kişinin **74’ü doğru sınıflanmış, bu kişiler OSAS hastasıdır ve bu hastalar için CPAP terapisi ile gerçekleştirilecek olan tedavi kesinlikle gereklidir kararına varılmıştır.** Bu sınıftaki eğitim grubuna dahil 3 kişi $\text{AHI} < 5$ alt grubunda yani sağlıklı ve tedavi gerektirmiyor olarak sınıflanmış , böylelikle bu 3 kişi için yanlış karara varılmıştır. Bu sınıftaki geriye kalan 2 kişi ise eğitim grubunda $5 \leq \text{AHI} < 15$ sınıfında olacak şekilde yanlış sınıflandırılmıştır. Bu 2 kişi yanlış sınıflandırılrsa dahi AHI değer aralıkları yine de 5’ten büyük olduğu için OSAS hastası olarak doğru teşhis edilmiştir. ***Ancak $5 \leq \text{AHI} < 15$ sınıfındaki hastaların CPAP kararları uzman görüşüne bağlı olduğu için bu 2 hasta için uyku uzmanına danışılarak CPAP terapisi ile tedavi gerektiriyor kararına varılmıştır.*** Yani bu sınıflama sonucuna göre $15 \leq \text{AHI}$ sınıfındaki **76 kişi için OSAS hastası ve CPAP terapisi ile sağlanan OSAS tedavisi gereklidir kararı verilirken,** sağlıklı birey olarak yanlış sınıflanan 3 kişi için hem OSAS hastası değil hem de tedavi gerekli değildir olarak yanlış değerlendirmede bulunulmuştur.
- $5 \leq \text{AHI} < 15$ sınıfında bulunan 33 kişinin 27’si doğru sınıflanmış, bu kişilerin 5’i $15 \leq \text{AHI}$ sınıfında 1’i $\text{AHI} < 5$ sınıfında olacak şekilde yanlış sınıflanmıştır. Yani demek oluyor ki bu gruptaki 32 kişinin AHI’si 5’ten büyük olarak belirlendiği için 32 kişi OSAS hastası olarak doğru

tanımlanmış, 1 kişi ise sağlıklı olarak yanlış tanımlanmıştır. Ayrıca bu sınıftaki 5 kişi (2'si eğitim grubunda, 3'ü test grubunda), $15 \leq \text{AHI}$ sınıfında bulunduğundan dolayı tedavileri için kesin olarak CPAP terapisi gerektirmektedir olarak değerlendirilmiştir. ***Ancak uzman görüşü alındığında görülmüştür ki; bu 5 hastanın test sınıfında bulunanlarından yalnızca 1'i CPAP terapi tedavisine ihtiyaç duymaktadır,*** diğer 4'ü kişi (2'si eğitim grubunda, 2'si test grubunda) için bu tedaviden önce başka tedavi seçenekleri değerlendirilmelidir.

- $\text{AHI} < 5$ sınıfında yani sağlıklı bireylerin sınıfındaki 33 kişinin 27'si sağlıklı olarak doğru sınıflanmıştır. Bu sınıftaki 5 kişi $15 \leq \text{AHI}$ sınıfında, 1 kişi de $5 \leq \text{AHI} < 15$ sınıfında olacak şekilde yanlış sınıflanmıştır. Yani bu 6 kişi OSAS hastasıdır ve ***bunlardan 5'i kesin olarak CPAP terapisi ile gerçekleştirilen tedaviye ihtiyaç duyuyor,*** 1'i için ise uzmana danışılmalıdır sonucuna varılıyor. Ancak bu kişilerin gerçek AHI sınıfı $\text{AHI} < 5$ (sağlıklı ve tedavi gerektirmiyor) olduğu için, bu yanlış bir çıkarım olmaktadır.

Klinikteki teşhis sürecine göre uzmanlar tarafından 145 kişiden 112'sine OSAS teşhisi konulmuşken, bu yaklaşım ile 114 kişinin AHI değeri 5'ten büyük bulunmuş yani 114 kişi OSAS hastası çıkmıştır (Çizelge 7.3 ve Çizelge 7.5). Bu kişilerin 108'i için sonuç doğru iken 6 sağlıklı birey OSAS hastası olarak yanlış değerlendirilmiştir. 4 OSAS hastasının ise AHI değerleri 5'ten küçük bulunmuş yani bu kişiler sağlıklı olarak yanlış teşhis edilmiştir. Doğrusal Olmayan Analiz Yaklaşımı sonucunda elde edilen sonuçlara göre söylenebilir ki Sarmal Alt Küme Değerlendirme Yöntemi ile seçilen etkin 6 özellik ve RF sınıflandırıcı algoritması ile OSAS hastaları, normal sağlıklı bireylerden %93.10 doğruluk, %96.43 duyarlılık, %81.82 özgüllük ve %94.73 kesinlik değerleri ile ayırt edilmiştir.

Yine klinikteki tedavi sürecine göre uzmanlar tarafından 145 kişiden 80'ini için tedavilerinde CPAP terapisine ihtiyaç duyuyor kararı verilmişken, bu yaklaşım ile 86 kişi CPAP terapisi gerektiriyor sonucuna ulaşılmıştır. Bu hastaların 77'si için bu sonuç doğru iken 9'u için gerekli olmayan bir tedavi türü gerekli görülmüştür. Ayrıca CPAP terapisi ile gerçekleştirilecek tedaviye ihtiyaç duyan 3 hasta için ise tedavi gerekmiyor kararı yanlış verilmiştir. Yani bu yaklaşım ile tüm kişilerin CPAP terapi gerekliliğinin belirlenmesinde %91.72 doğruluk, %96.25 duyarlılık, %86.15 özgüllük ve %89.53 kesinlik sağlanmıştır.

Bu yaklaşımda kullanılan yöntemler ve elde edilen sonuçlar, Çizelge 7.7’de gösterilen literatürdeki benzer çalışmalarla karşılaştırılmıştır.

Çizelge 7.7. Doğrusal Olmayan Analiz Yaklaşımı ile sağlanan sonuçların literatürle kıyaslanması

Araştırmacılar	Sinyaller	Yöntem	Performans
Kaimakamis ve ark. (2009)	Nazal Hava Akımı, Göğüs Hareketi ve Oksimetri	En Büyük Lyapunov Üssü, DFA, YakEn, C4.5	OSAS teşhisi için CA: %84.9 OSAS hastalık derecesi için CA: %74.2
Kaimakamis ve ark. (2016)	Nazal Hava Akımı, Göğüs Hareketi ve Oksimetri	En Büyük Lyapunov Üssü, DFA, YakEn Doğrusal Regresyon, Karar Ağacı	AHI = 8 sınır değerine göre doğrusal regresyon kullanılarak hastaları ve normal kişileri ayırt etmede duyarlılık ve özgüllük %93 ve %71.4 olarak elde edilmiştir. Hastalar ile normal kişiler arasındaki ayırım için karar ağacı kullanıldığında sırasıyla %91 duyarlılık ve %60 özgüllüğe ulaşılmıştır.
Vaquerizo-Villar ve ark. (2018)	Oksimetri	ODI3, DFA, ANN	Saatte 1, 5 ve 10 ataklık pediatrik AHI sınır değerleri için sırasıyla %82.7, %81.9 ve %91.1 doğruluk elde edilmiştir.
da Silva ve ark. (2015)	Kalp Atış Hızı	DFA, ROC Analizi	Kişilerin orta derecede OSAS olduğu %86.11 duyarlılıkla ile ağır derecede OSAS olduğu %63.64 duyarlılıkla öngörülmüştür.
Deng ve ark. (2006)	Kalp Atış Hızı	DFA, Güç Spektral Analizi, Sayısal Titrasyon, ÖrEn, ROC Analizi	Pediatrik OSAS teşhisinde, %72.2 özgüllük ve %81.3 duyarlılık elde edilmiştir.
Gutierrez-Tobal ve ark. (2013)	Hava Akımı	Spektral Analiz, Merkezi Eğilim Ölçüsü, Lempel Ziv Karmaşıklığı, YakEn, İstatistiksel özellikler, ANN	OSAS teşhisi %92.5 duyarlılık, %89.5 özgüllük ve %91.5 doğruluk ile gerçekleştirilmiştir.
Jiménez-García ve ark. (2020)	Hava Akımı Oksimetri	Spektral Analiz, Merkezi Eğilim Ölçüsü, Lempel Ziv Karmaşıklığı, ÖrEn, İstatistiksel özellikler, Adaboost	AHI sınır değerleri 1, 5, 10 olarak seçildiğinde pediatrik OSAS ve OSAS değil ayırımı sırasıyla %81.28, %82.05 ve %90.26 doğruluklarla sağlanmıştır.
Bu yaklaşım (Doğrusal Olmayan Analiz Yaklaşımı)	Nazal Hava Akımı	MDFA RF	Farklı AHI alt gruplarının belirlenmesinde %89.66 doğruluk ve 0.84 kappa değeri elde edilmiştir. $15 \leq$ AHI alt grubu için %100 duyarlılık ve %81.25 özgüllük, $5 \leq$ AHI <15 alt grubu için %81.25 duyarlılık ve %100 özgüllük, AHI <5 alt grubu için de aynı şekilde %81.25 duyarlılık ve %100 özgüllük elde edilmiştir OSAS hastaları normal sağlıklı bireylerden %93.10 doğruluk, %96.43 duyarlılık, %81.82 özgüllük ve %94.73 kesinlik değerleri ile ayırt edilmiştir.

Çizelge 7.7’de görülmektedir ki; OSAS hastalarının normal sağlıklı bireylerden ayırt edilmesinde bu çalışmanın genel performansı, %93.10 doğruluk, %96.43 duyarlılık %81.82 özgüllük ve %94.73 kesinlik değerleri ile literatürdeki benzer çalışmalara göre

daha iyidir. Bu çalışma aynı zamanda CPAP terapisi ile sağlanan tedaviye ihtiyaç duyan veya ihtiyaç duymayan hastaları ayırt etmede de yüksek performans sağlamıştır. $15 \leq \text{AHI}$, $5 \leq \text{AHI} < 15$ ve $\text{AHI} < 5$ alt gruplarının duyarlılık değerleri sırasıyla %100, %81.25 ve %81.25 olarak elde edilmiştir. Ayrıca önceki çalışmalardan farklı olarak bu çalışmada sadece tek kanallı nazal kanül hava akımı sinyali ve sadece MDFA yöntemi kullanılmıştır. Bununla birlikte, bu çalışma, birden fazla sinyal ve teknik kullanılan önceki çalışmalardan daha yüksek performans göstermiştir. Bu da, kullanılan MDFA yönteminin literatürdeki diğer tekniklere kıyasla OSAS hastalarını sağlıklı kişilerden daha doğru bir şekilde ayırt edebildiğine işarettir. Bunun nedeni, bu yöntemle birçok yeni özellik çıkarılmış ve hava akımı sinyallerinde meydana gelen küçük dalgalanmalar ve değişiklikler daha doğru bir şekilde yakalanabilmiştir. Klinik ortamda hava akımı sinyalleri ve bu sinyallerde ortaya çıkan değişiklikler, uyku uzmanları tarafından OSAS tanısı ve tedavisi için anahtar rol oynamaktadır. Bu çalışmada hava akımı sinyallerindeki değişimler MDFA yöntemi ile kolaylıkla değerlendirildiği için çalışmada başka herhangi bir yöntem ve başka herhangi bir sinyale ihtiyaç duyulmadan daha yüksek performanslar elde edilmiştir.

7.1.2. Kural tabanlı algoritma yaklaşımına ait sonuçlar

Tez çalışmasına dahil edilen kişilere OSAS teşhisi konulması ve kişiler için CPAP terapisi ile tedavi edilme gerekliliğinin belirlenmesi amacıyla gerçekleştirilen diğer bir yaklaşım kliniklerdeki uyku uzmanlarının izlediği yola bağlı kalınarak oluşturulmuştur. Yaklaşımında geliştirilen kural tabanlı bir algoritma ile kişilerin gece boyunca geçirmiş oldukları apneik ataklar tespit edilmiş, ataklara bağlı desaturasyonlar belirlenmiş ve tespit edilen ataklara göre hesaplanan AHI değerlerine göre kişilerin OSAS hastası olup olmadığına veya CPAP terapisi ile gerçekleştirilen tedaviye gerek duyup duymadığına karar verilmiştir.

Bu yaklaşımda da 145 kişi yine rastgele bir şekilde %60'ı eğitim (87 hasta, 9521 apneik atak) ve %40'ı test (58 Hasta, 4477 apneik atak) olacak şekilde 2 gruba ayrıştırılmıştır. Eğitim grubunda bulunan kişilerin hava akımı sinyalleri kullanılarak kural tabanlı bir algoritma geliştirilmiş, geliştirilen algoritma ile bu kişilerin gece boyunca uykuda geçirmiş oldukları ataklar tespit edilmiş ve son olarak bu kişilerin tespit edilen ataklarına bağlı oksimetri sinyallerindeki desaturasyonlar belirlenerek atakların apneik olup olmadığı kesinleştirilmiştir. Eğitim grubu dikkate alınarak

geliştirilen algoritma test grubunda bulunan kişiler için de çalıştırılmış ve aynı işlemlerle test grubu kişilerinin de apneik atakları tespit edilmiştir. Çizelge 7.8 geliştirilen kural tabanlı algoritma ile apneik atak tespit sonuçlarını göstermektedir.


Çizelge 7.8 Geliştirilen kural tabanlı algoritma ile apneik atak tespit sonuçları

Grup	GAS	DTAS	EAS	FTAS	Duyarlılık (%)	Kesinlik (%)
Eğitim	9521	9017	504	92	94.70	98.99
Test	4477	4220	257	39	94.25	99.08

*GAS: Gerçek apneik atak sayısı, DTAS: Doğru olarak tespit edilen atak sayısı, EAS: Eksik atak sayısı yani tespit edilemeyen atakların sayısı, FTAS: Fazladan tespit edilen atak sayısı yani gerçekte olmayıp algoritma tarafından tespit edilen atakların sayısı

Apneik olay tespitinin performans değerlendirmesinde duyarlılık, doğru olarak saptanan apneik atakların sayısının toplam apneik atak sayısına oranını ifade etmektedir. Çizelge 7.8'e göre bu ölçüt eğitim grubu için %94.70, test grubu için %94.25 olarak bulunmuştur. Kesinlik ölçütü ise doğru olarak tespit edilen apneik atakların tüm tespit edilen apneik ataklara oranını ifade etmektedir. Bu ölçüt değeri de hem eğitim hem test grubu için oldukça yüksek ve sırasıyla %98.99 ve %99.08'dir.

Eğitim ve test grubunda bulunan toplam 145 kişiye ait apneik atakların tespitinin ardından, her bir kişinin AHI değerleri AASM (2012)'ye göre toplam apneik atak sayısının toplam uyku süresine oranı ile hesaplanmıştır. Şekil 7.1 çalışmada tespit edilen ataklara göre hesaplanan AHI değerleri ile uyku uzmanları tarafından belirlenen referans AHI değerleri arasındaki dağılım (Şekil 7.1.a) ve Bland-Altman (Şekil 7.1.b) grafiklerini göstermektedir.



Şekil 7.1. Hesap edilen ve Referans AHI değerleri arasındaki, **a.** Dağılım grafiği, **b.** Bland-Altman grafiği

Dağılım grafiği (Şekil 7.1.a), hesaplanan ve referans AHI değerleri arasında istatistiksel olarak önemli bir korelasyonun olduğunu göstermektedir ($r = 0.9974$,

$r^2=0.99$). Bland-Altman grafiğine (Şekil 7.1.b) göre hesaplanan ve referans AHI değerleri arasındaki mutlak ortalama fark 1.2'dir.

Kural tabanlı algoritma ile apneik atak tespit işleminde tespit edilemeyen veya fazladan tespit edilen ataklar olmasına rağmen, Şekil 7.1'deki grafiklerden anlaşılacağı üzere bunların sayısı oldukça azdır ki kişilerin AHI değerlerini önemli ölçüde etkilememiştir.

Kişilerin OSAS teşhisinin gerçekleştirilmesi ve CPAP terapisi ile tedavi gerekliliğinin belirlenmesi amacıyla, hesaplanan AHI'lere göre tüm kişiler $15 \leq \text{AHI}$, $5 \leq \text{AHI} < 15$ ve $\text{AHI} < 5$ alt gruplarına ayrıştırılmıştır. Çizelge 7.9 kişilerin hesaplanan AHI değerlerine göre AHI alt gruplarına ayrıştırılma performansını, Çizelge 7.10 ise konfüzyon matrisini göstermektedir.

Çizelge 7.9 Kural Tabanlı Algoritma Yaklaşımı ile belirlenen AHI değerlerine göre tüm kişilerin AHI alt gruplarına ayrıştırılma sonuçları

AHI Alt Grup	Duyarlılık (%)	Özgüllük (%)	Kesinlik (%)	F-Skor (%)	Doğruluk (%)	K
$15 \leq \text{AHI}$	97.47	98.48	98.72	98.09		
$5 \leq \text{AHI} < 15$	90.91	98.21	93.75	92.31	96.55	0.94
$\text{AHI} < 5$	100	98.21	94.29	97.06		

Çizelge 7.10 Kural Tabanlı Algoritma Yaklaşımı ile AHI alt gruplarına ayrıştırılma konfüzyon matrisi

		Tahmin		
		$15 \leq \text{AHI}$	$5 \leq \text{AHI} < 15$	$\text{AHI} < 5$
Gerçek	$15 \leq \text{AHI}$	77	2	0
	$5 \leq \text{AHI} < 15$	1	30	2
	$\text{AHI} < 5$	0	0	33

Apneik atak tespitine ve buna bağlı olarak hesaplanan AHI değerlerine göre gerçekleştirilen OSAS teşhisi ve CPAP terapisi ile tedavi gerekliliği değerlendirilecek olursa, Çizelge 7.10'da görüldüğü üzere AHI'si 5'ten büyük yani OSAS hastası olan 112 kişiden 110'nun AHI değeri 5'ten büyük bulunmuş ve bu kişiler OSAS hastasıdır olarak değerlendirilmiştir. Bu 112 hastanın 2 tanesinin AHI değerleri 5'in altında bulunmuş yani bu kişiler OSAS hastası olmasına rağmen sağlıklı olarak değerlendirilmiştir. Sağlıklı olan 33 birey ise yine sağlıklı olarak bulunmuştur. Bu bulgulara bağlı olarak, Kural Tabanlı Algoritma Yaklaşımı ile OSAS hastaları sağlıklı bireylerden %98.62 doğruluk, %98.21 duyarlılık, %100 özgüllük ve %100 kesinlik ile ayırt edilmiştir.

Klinikteki tedavi sürecine göre uzmanlar tarafından tedavileri için CPAP terapisi gerekli görülen 80 hasta mevcuttur. Çizelge 7.10'a göre kesin olarak CPAP terapisi ile gerçekleştirilecek tedavi gerekli görülen hasta grubu ($15 \leq \text{AHI}$) 79 kişiden oluşmaktadır

ve bu kişilerin **77'si yine bu gruba dahil edilerek CPAP terapi tedavisi gereklidir olarak belirlenmiştir**. Bu gruptaki 2 kişi hesaplanan AHI değerlerine göre $5 \leq \text{AHI} < 15$ alt grubuna dahil edilmiştir. Bu AHI değer aralığındaki hastalar için uzman görüşüne ihtiyaç duyulduğu için uzmana danışılmış ve bu **2 hastanın göstermiş olduğu semptomlar nedeniyle CPAP terapisi ile tedavi edilmeye gerek duyduğu kararına varılmıştır**. $5 \leq \text{AHI} < 15$ alt grubuna dahil 33 kişiden 30'u yine bu alt gruba dahil edilmiş ancak 1'i $15 \leq \text{AHI}$ grubuna, 2'si de $\text{AHI} < 5$ grubuna dahil edilmiştir. Bu aralıktaki hastalar için uzman görüşü önemli olduğu için uzmana danışılmış, **yanlışlıkla $15 \leq \text{AHI}$ grubuna dahil olan 1 hastanın zaten belirgin semptomlar gösterdiği ve bu hastanın tedavisi için de CPAP terapisinin gerekli olduğu bilgisi alınmıştır**. Uzmanlar tarafından $5 \leq \text{AHI} < 15$ alt grubundaki diğer hastalar için CPAP terapisi yerine alternatif tedavi yöntemleri uygulanması gerektiği belirtilmiştir. Klinikte tedavisi için CPAP terapisi gerekli görülen 80 hasta, bu yaklaşım ile de CPAP terapisi ile tedavi edilmesi gereklidir olarak değerlendirilmiş ve tedavi ihtiyacı olmayan hiçbir bir hasta da tedavi edilmelidir şeklinde yorumlanmamıştır. Böylelikle bu yaklaşım sayesinde tüm kişilerin CPAP terapisi ile tedavi gerekliliklerinin belirlenmesinde %100 doğruluk, %100 duyarlılık, %100 özgüllük ve %100 kesinlik ölçütleri elde edilmiştir.

Gerçekleştirilen bu yaklaşım, izlenen yöntem ve elde edilen sonuçlar, Çizelge 7.11'de gösterildiği gibi literatürdeki benzer çalışmalarla karşılaştırılmıştır. Çizelge 7.11'deki sonuçlardan görüldüğü üzere, gerçekleştirilen çalışma hem atak tespiti, hem AHI'ler arasındaki ilişki, hem de OSAS teşhisindeki performansı bakımından literatürdeki çalışmalarla kıyaslanacak düzeydedir. Literatürdeki çalışmalar genellikle sinyal tepe değeri, genlik, soluk hızı ve soluk miktarındaki değişimleri dikkate alarak hava akımı sinyallerinden yeni sinyaller üretmişler ve AASM (2012) kriterleri doğrultusunda apneik atak tespitini gerçekleştirmişlerdir. Bu tez çalışmasında gerçekleştirilen Kural Tabanlı Algoritma Yaklaşımında ise SVD yöntemi ile maksimum tekil değer kullanımı sonucu hava akımı sinyallerini temsil eden yeni bir SVD sinyali üretilmiş ve yine AASM (2012) kriterleri dikkate alınarak belirli kurallara dayalı algoritma ile yüksek performans sergileyen bir algoritma geliştirilmiştir. Böylelikle görülmüştür ki, tıpkı klasik genlik veya soluk hızı değişimlerinde olduğu gibi apneik atakların hava akımı sinyallerinde oluşturduğu enerji farklılıkları SVD yöntemi tarafından ortaya çıkarılmış ve geliştirilen kural tabanlı algoritma ile bu farklılıklar algılanarak OSAS teşhisine ve kişilerin CPAP terapisi ile gerçekleştirilecek tedaviye ihtiyaç duyup duymadıklarını belirlemeye yardımcı olunmuştur.

Çizelge 7.11. Kural tabanlı algoritma ile sağlanan sonuçların literatürle kıyaslanması

Araştırmacılar	Sinyaller	İzlenen Yöntem	Performans
Otero ve ark. (2011)	Hava Akımı Oksimetri	*Hava akımı sinyallerinden her bir andaki soluk alma (sinyalin maksimum değeri) ve soluk verme (sinyalin minimum değeri) miktarları kullanılarak solunum miktarı sinyalinin üretilmesi *Solunum miktarı sinyallerindeki 2 dakikalık anlık enerjiye göre bazal değer belirleme ve her örnekte genlik azalımını inceleme * Oksijen desaturasyonun incelenmesi	<u>Apneik atakların tespitinde;</u> Duyarlılık: % 95.7 Yanlış Negatif: % 1.6 AHI'ler için korelasyon (r):-
Koley ve Dey (2013)	Hava Akımı	✓ Genlik ve solunum hızındaki değişiklikler baz alınarak anlık solunum genliği ve anlık solunum aralığı sinyallerinin üretilmesi ✓ 8 sn'lik segmentlerden özellik çıkarılması ve SVM ile segment sınıflaması	<u>Apneik atakların tespitinde;</u> Bilinen veriler için Doğruluk: %96.8 Bilinmeyenler için Doğruluk: %96.1 <u>AHI değerleri arasındaki r: 0.98</u>
Moret-Bonillo ve ark. (2014)	Hava Akımı Oksimetri	*Hava akımı sinyallerindeki genlik değişimine göre yeni sinyal üretilmesi *AASM kurallarına göre değer azalımının incelenmesi *Oksijen desaturasyonun incelenmesi	<u>Apneik atakların tespitinde;</u> Duyarlılık: %81.3 Özgüllük: %91.6 AHI'ler için korelasyon (r):-
Lee ve ark. (2016)	Nazal Kanül Hava Akımı	✓ Hava akımı sinyal tepe değerleri kullanılarak yapılan genlik değerlerine göre apneik atak tespiti	<u>Apneik atakların tespitinde;</u> Duyarlılık: %86.4 Kesinlik: %84.5 <u>AHI değerleri arasındaki r: 0.94</u>
Huang ve ark. (2017)	Nazal Kanül Hava Akımı Oksimetri	*Hava akımı genlik değişimlerine göre apneik atak tespiti *Oksijen desaturasyonun incelenmesi	Duyarlılık: %97.6 Kesinlik: %95.7 AHI'ler için korelasyon (r):-
Choi ve ark. (2018)	Nazal Kanül Hava Akımı	✓ Hava akımı sinyal segmentlerinin Konvülsiyonel Sinir Ağları ile değerlendirilmesi	<u>OSAS tespitinde;</u> Doğruluk: %94.9 <u>AHI değerleri arasındaki r: 0.99</u>
Bu yaklaşım (Kural Tabanlı Algoritma Yaklaşımı ile atak tespiti)	Nazal Kanül Hava Akımı Oksimetri	*Hava akımı sinyal segmentlerinden SVD yöntemi ile yeni SVD sinyalinin üretilmesi *Çıkarılan belirli kurullarla apneic atak tespiti * Oksijen desaturasyonun incelenmesi	<u>Apneik atakların tespitinde;</u> Duyarlılık: %94.25 Kesinlik: %99.08 <u>AHI değerleri arasında;</u> r=0.99, r ² =0.99, p<0.0001 <u>AHI alt gruplarına ayırıştırma;</u> Doğruluk=%96.55 <u>OSAS tespitinde;</u> Doğruluk: %98.62 Duyarlılık: %98.21 Özgüllük: % 100 Kesinlik: %100

Tez çalışmasında gerçekleştirilen iki yaklaşım kıyaslanacak olursa, Kural Tabanlı Algoritma Yaklaşımı OSAS hastalarını sağlıklı bireylerden %98.62 doğruluk, %98.21 duyarlılık , %100 özgüllük ve %100 kesinlik ile ayırırken, Doğrusal Olmayan Analiz Yaklaşımı %93.10 doğruluk, %96.43 duyarlılık, %81.82 özgüllük ve %94.73 kesinlik değerleri ile ayırabilmiştir. Yani kişilerin OSAS teşhisinin konulmasında,

klinipteki izlenen yola baęlı kalınarak oluřturulan Kural Tabanlı Algoritma Yaklařımı daha bařarılı olmuřtur. Kural Tabanlı Algoritma Yaklařımı ile CPAP terapisi gerekli olan 80 OSAS hastasının tm yine CPAP terapisi ile tedaviye ihtiyaçı vardır řeklinde doęru tanımlanmıřken, Doğrusal Olmayan Analiz Yaklařımı ile 80 hastanın 77'si iin bu karara varılmıř, 9 hasta iin ise gerekli olmayan tedavi řekli grlmřtr. Bu sonulara gre kiřilerin CPAP terapisi ile gerekleřtirilen tedaviye ihtiya duyup duymadıklarının belirlenmesinde de Kural Tabanlı Algoritma Yaklařımı stn performans gstermiřtir. Bu nedenle Kural Tabanlı Algoritma Yaklařımı sonucunda "CPAP terapisi gereklidir" olarak karara varılan 80 hasta iin tez alıřması devam ettirilmif ve bu 80 hastanın optimum CPAP seviyelerinin tahmini gerekleřtirilmiřtir.

7.2. CPAP Seviyesi Tahmin Modelleri ve Sonuları

Bu tez alıřmasının temel amacı olan optimum CPAP seviyelerinin tahmini iin, CPAP terapisi ile tedavi edilmesine karar verilen hastaların demografik ve antropometrik zelliklerini, PSG sinyal kayıt zelliklerini, gece boyunca geirmif oldukları apneik atak ve desaturasyon zelliklerini ieren 4 farklı zellik seti (*S1*, *S2*, *S3* ve *S4*) oluřturulmuřtur. Daha sonra bu zellik setlerinin birlikte deęerlendirilmeleri ile 6 farklı zellik seti (*S_1-2*, *S_1-3*, *S_1-4*, *S_2-3*, *S_2-3-4* ve *S_1-2-3-4*) daha elde edilmiřtir. Elde edilen tm zellik setlerindeki zelliklerin tamamının ve farklı yntemlerle seilen en etkililerinin kullanılması ile alıřmaya dahil edilen 80 hastanın optimum CPAP seviyeleri tahmin edilmiřtir. 80 hastanın rastgele ayrıřtırılmıř yaklařık %60'ı (50 hasta) eęitim amacıyla, %40'ı (30 hasta) test amacıyla kullanılmıřtır. Hastaların optimum CPAP seviye tahminleri SLR, MLR veya S-MLR analizlerinden biri ve ANN, PolyKernel fonksiyonlu SVM, RBFKernel fonksiyonlu SVM, kNN ve RF yapay zeka yntemleri ile gerekleřtirilmiřtir. Tahminler neticesinde test sonuları bakımından en yksek performansların saęlandıęı zellikler ve yntemler ile CPAP tahmin modelleri geliřtirilmiřtir. Tahmin iřlemini gerekleřtiren yntemler eęitim (ęrenme) ařamasında 10 kat apraz doęrulama teknięini kullanmıřlardır.

Tahmin performanslarının deęerlendirilmesi iin Pearson korelasyon katsayısı (r), belirlilik katsayısı (r^2) ve p deęeri ltleri kullanılmıřtır. r katsayısı, tahmin edilen CPAP seviyeleri ile referans optimum CPAP seviyeleri arasındaki iliřkiyi belirtmektedir. r^2 katsayısı, referans optimum CPAP seviyelerindeki deęiřkenlięin yzde kaının geliřtirilen tahmin modeli tarafından temsil edildięini gstermektedir. Bu

katsayı değerlerinin 1.0'a yakın olması, tahmin edilen ve referans seviyeler arasındaki ilişki gücünü tanımlaması bakımından istenilen bir durumdur. Gerçekleştirilen tez çalışmasında p değerinin 0.05'ten küçük olması ise tahmin edilen ve referans optimum seviyeler arasında istatistiksel anlamlılık bulunduğu şeklinde yorumlanmıştır. Ayrıca hastaların yüzde(%) kaçında referans optimum seviyelerin ± 3 cmH₂O aralığında tahmin gerçekleştirildiği de önemli bir değerlendirme kriteri olmuştur. Bu yüzdeliğin, 90 ve üzerinde olması çalışmada istenilen bir durum olarak belirlenmiştir.

Bu tez çalışmasında hastaların optimum CPAP seviyelerinin tahmini için öncelikle özellik setlerindeki tüm özellikler MLR analizi, ANN, PolyKernel ve RBFKernel fonksiyonlu SVM, kNN ve RF yöntemleri ile kullanılmış ve Çizelge 7.12'de görülen sonuçlara ulaşılmıştır. Her bir özellik setinin kullanılmasıyla sağlanan maksimum test performansları Çizelge 7.12'de farklı yazı renkleri ile belirtilmiştir.

Çizelge 7.12. Özellik setlerinin tüm özelliklerinin kullanılmasıyla elde edilen CPAP tahmin sonuçları

Özellik Seti	PÖ.	Eğitim						Test					
		MLR	ANN	SVM Poly	SVM RBF	kNN	RF	MLR	ANN	SVM Poly	SVM RBF	kNN	RF
ÖS1 (3 özellik)	r:	0.35	0.41	0.43	0.43	0.43	0.39	0.64	0.69	0.64	0.62	0.45	0.40
	p <	0.05	0.005	0.005	0.005	0.005	0.005	0.001	0.001	0.001	0.001	0.05	0.05
	r ² :	0.12	0.17	0.18	0.18	0.18	0.15	0.41	0.48	0.41	0.38	0.20	0.16
ÖS2 (39 özellik)	r:	0.15	0.47	0.24	0.32	0.24	0.48	0.35	0.48	0.41	0.48	0.34	0.40
	p <	0.5	0.001	0.5	0.05	0.5	0.001	0.05	0.005	0.05	0.05	0.05	0.05
	r ² :	0.02	0.22	0.05	0.10	0.05	0.23	0.12	0.23	0.17	0.23	0.12	0.16
ÖS3 (37 özellik)	r:	0.29	0.42	0.44	0.45	0.37	0.31	0.12	0.45	0.44	0.45	0.35	0.50
	p <	0.05	0.05	0.05	0.005	0.05	0.05	0.5	0.05	0.05	0.05	0.05	0.005
	r ² :	0.08	0.18	0.19	0.20	0.14	0.09	0.01	0.20	0.19	0.20	0.12	0.25
ÖS4 (25 özellik)	r:	0.40	0.46	0.50	0.50	0.46	0.44	0.75	0.56	0.75	0.79	0.61	0.67
	p <	0.005	0.001	0.001	0.001	0.001	0.005	0.001	0.005	0.001	0.001	0.001	0.001
	r ² :	0.16	0.21	0.25	0.25	0.21	0.19	0.56	0.31	0.56	0.62	0.37	0.45
ÖS_1-2 (42 özellik)	r:	0.37	0.54	0.52	0.56	0.43	0.55	0.52	0.71	0.64	0.66	0.52	0.54
	p <	0.05	0.001	0.001	0.001	0.005	0.001	0.005	0.001	0.001	0.001	0.005	0.005
	r ² :	0.13	0.29	0.27	0.32	0.18	0.30	0.27	0.50	0.41	0.43	0.27	0.29
ÖS_1-3 (40 özellik)	r:	0.51	0.55	0.59	0.57	0.38	0.37	0.43	0.58	0.64	0.58	0.26	0.56
	p <	0.001	0.001	0.001	0.001	0.005	0.05	0.05	0.005	0.001	0.005	0.5	0.005
	r ² :	0.26	0.30	0.35	0.32	0.14	0.14	0.18	0.34	0.41	0.34	0.06	0.31
ÖS_1-4 (28 özellik)	r:	0.42	0.48	0.53	0.54	0.59	0.50	0.69	0.52	0.77	0.78	0.58	0.71
	p <	0.005	0.001	0.001	0.001	0.001	0.001	0.001	0.005	0.001	0.001	0.005	0.001
	r ² :	0.18	0.23	0.28	0.29	0.35	0.25	0.48	0.27	0.61	0.61	0.34	0.50
ÖS_2-3 (76 özellik)	r:	0.29	0.41	0.35	0.40	0.27	0.48	0.24	0.56	0.55	0.63	0.56	0.50
	p <	0.05	0.005	0.05	0.05	0.05	0.005	0.5	0.005	0.005	0.001	0.005	0.005
	r ² :	0.08	0.17	0.12	0.16	0.07	0.23	0.05	0.31	0.30	0.40	0.31	0.25
ÖS_2-3-4 (101 özellik)	r:	0.23	0.46	0.50	0.49	0.45	0.53	0.50	0.56	0.71	0.68	0.57	0.68
	p <	0.05	0.001	0.001	0.001	0.005	0.001	0.005	0.005	0.001	0.001	0.005	0.001
	r ² :	0.05	0.21	0.25	0.24	0.20	0.28	0.25	0.31	0.50	0.46	0.32	0.46
ÖS_1-2-3-4 (104 özellik)	r:	0.29	0.55	0.52	0.54	0.50	0.58	0.27	0.61	0.73	0.64	0.42	0.61
	p <	0.05	0.001	0.001	0.001	0.001	0.001	0.5	0.001	0.001	0.001	0.05	0.001
	r ² :	0.08	0.30	0.27	0.29	0.25	0.34	0.07	0.37	0.53	0.41	0.18	0.37

*PÖ.:Performans Ölçütü

Çizelge 7.12’de görülen her bir özellik seti için maksimum performansı sağlayan yöntem ile CPAP tahmin modeli geliştirilmiştir.

Model-1: ÖS1’in tüm özellikleri ve ANN yöntemi kullanılarak geliştirilen model CPAP tahmini için ilk model olarak kabul edilmiştir. 3 özelliğin tahmin parametresi olduğu bu modelde eğitim için r değeri 0.41, r^2 değeri 0.17 olarak, test için r değeri 0.69, r^2 değeri 0.48 olarak bulunmuştur. Hem eğitimde hem de testte p değeri 0.005’ten küçük bulunduğu için istatistiksel olarak bir anlam olduğu ifade edilebilir. Bu model ile gerçekleştirilen tahmin işleminde, hastaların %83.75’inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur.

Model-2: CPAP tahmini için ikinci modeli, ÖS2’nin tüm özellikleri ve ANN yöntemi oluşturmaktadır. RBFKernel fonksiyonlu SVM yöntemi, ANN ile eşit test performansı sağlasa da eğitim performansı ANN’den düşük olduğu için model gelişiminde ANN tercih edilmiştir. Hava akımı ve oksimetri sinyallerine ait 39 özelliğin tahmin parametresi olduğu bu model ile eğitimde r değeri 0.47, r^2 değeri 0.22, testte r değeri 0.48, r^2 değeri 0.23 olarak elde edilmiştir. Model ile elde edilen p değerleri de istatistiksel anlamlılığı ifade edecek şekilde 0.005’ten küçük bulunmuştur. Bu model kullanıldığında hastaların %43.75’inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur.

Model-3: Üçüncü model, ÖS3’ün tüm özellikleri ve RBFKernel fonksiyonlu SVM yöntemi ile geliştirilmiştir. ANN ve RBFKernel fonksiyonlu SVM yöntemleri eşit test performansları üretmişlerdir. Ancak RBFKernel fonksiyonlu SVM yönteminin hem eğitim performansı ANN’e göre daha yüksektir hem de bu yöntemle tahmin edilen CPAP seviyelerinin referans optimum seviyelerin ± 3 cmH₂O aralığında olduğu hasta sayısı ve yüzdesi daha fazladır. Bu nedenle, model gelişimi için RBFKernel fonksiyonlu SVM yöntemi tercih edilmiştir. Hava akımı ve oksimetri sinyallerine ait 37 doğrusal olmayan özelliğin tahmin parametresi olarak kullanıldığı bu model ile eğitim r değeri 0.45, r^2 değeri 0.20, test r değeri 0.45, r^2 değeri 0.20 olarak elde edilmiştir. Model ile elde edilen eğitim ve test p değerleri istatistiksel anlamlılığı ifade eden 0.05’ten küçük olarak hesaplanmıştır. Bu model hastaların %82.5’inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur.

Model-4: RBFKernel fonksiyonlu SVM yöntemi ve ÖS4’e ait tüm özelliklerin kullanılması ile dördüncü model üretilmiştir. Bu modelde tahmin parametreleri olarak hastaların gece boyunca geçirmiş oldukları apneik atak ve ataklara bağlı desaturasyon özellikleri tercih edilmiştir. 25 parametrelili bu model ile eğitim aşamasındaki r değeri

0.50 ve r^2 değeri 0.25 olarak hesaplanmıştır. Test aşamasında ise bu değerler sırasıyla 0.79 ve 0.62 olmuştur. p değerleri de 0.001'ten küçük olarak bulunmuştur. Model 4'ün kullanılması ile hastaların %80'inde tahmin edilen seviyeler, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur.

Model-5: ÖS1 ve ÖS2'nin birleştirilmesi ile elde edilen ÖS_1-2'ye ait tüm özelliklerin ve ANN yönteminin kullanılması ile geliştirilen beşinci model, 42 özelliği tahmin parametresi olarak kabul etmektedir. Bu model ile eğitim r değeri 0.54 ve r^2 değeri 0.29 olarak bulunmuşken test r değeri 0.71 ve test r^2 değeri 0.50 olarak hesap edilmiştir. Hem eğitim hem test için p değerleri ise 0.001'den küçük olarak istatistiksel anlamlı bulunmuştur. Model-5 ile tahmin sonucunda, hastaların %81.25'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur.

Model-6: Çalışmadaki altıncı model, ÖS1 ve ÖS3'ün birleştirilmesi ile elde edilen ÖS_1-3'e ait tüm özellikler ve PolyKernel fonksiyonlu SVM yöntemi ile geliştirilmiştir. Bu model 40 özelliği tahmin parametresi olarak kabul etmektedir. Model ile eğitim r değeri 0.59 ve r^2 değeri 0.35 olarak, test r değeri 0.64 ve r^2 değeri 0.41 olarak hesap edilmiştir. Eğitim ve test için p değerleri 0.001'den küçük olarak istatistiksel anlamlı bulunmuştur. Bu model ile gerçekleştirilen tahminde, hastaların %83.75'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur.

Model-7: Yedinci model, ÖS1 ve ÖS4'ün birleştirilmesi ile elde edilen ÖS_1-4'e ait tüm özelliklerin ve RBFKernel fonksiyonlu SVM yönteminin kullanılması ile geliştirilmiştir. 28 özelliğin tahmin parametresi olarak kabul edildiği Model-7 ile eğitim r değeri 0.54 ve r^2 değeri 0.29 olarak, test r değeri 0.78 ve r^2 değeri 0.61 olarak hesaplanmıştır. Eğitim ve test için p değerleri istatistiksel anlamlılığı ifade edecek şekilde 0.001'den küçük bulunmuştur. Bu model ile gerçekleştirilen tahminde, hastaların %86.25'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur.

Model-8: ÖS2 ve ÖS3'ün birleştirilmesi ile elde edilen ÖS_2-3'e ait tüm özellikler ve RBFKernel fonksiyonlu SVM yöntemi ile geliştirilen sekizinci model, hava akımı ve oksimetri sinyallerine ait 76 özelliği tahmin parametresi olarak kabul etmiştir. Model-8 ile eğitim r değeri 0.40 ve r^2 değeri 0.16 olarak, test r değeri 0.63 ve r^2 değeri 0.40 olarak elde edilmiştir. Eğitim ve test için p değerleri istatistiksel anlamlılığı ifade eden 0.05'ten küçük bulunmuştur. Bu model sayesinde, hastaların

%85’inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur.

Model-9: Geliştirilen dokuzuncu modeli, ÖS2, ÖS3 ve ÖS4’ün birleştirilmesi ile elde edilen ÖS_2-3-4’e ait tüm özellikler ve PolyKernel fonksiyonlu SVM yöntemi oluşturmuştur. 101 özelliği tahmin parametresi olarak kabul eden model, eğitim r değerini 0.50 ve r^2 değerini 0.25 olarak, test r değerini 0.71 ve r^2 değerini 0.50 olarak üretmiştir. p değerleri istatistiksel anlamlılığı ifade edecek şekilde 0.001’den küçük olarak bulunmuştur. Bu model ile hastaların %81.25’inin CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olacak şekilde tahmin edilmiştir.

Model-10: Onuncu model, ÖS1, ÖS2, ÖS3 ve ÖS4’ün birleştirilmesi ile elde edilen ÖS_1-2-3-4’e ait tüm özellikler ve PolyKernel fonksiyonlu SVM yöntemi ile geliştirilmiştir. 104 özelliğin tahmin parametresi olarak kullanıldığı bu model ile, eğitim r ve r^2 değerleri sırasıyla 0.52 ve 0.27 olarak, test r ve r^2 değerleri ise sırasıyla 0.73 ve 0.53 olarak elde edilmiştir. p değerleri istatistiksel anlamlılığı ifade edecek şekilde 0.001’den küçük olarak bulunmuştur. Model-10 ile hastaların %85’inde CPAP seviyeleri, referans olarak belirlenen optimum seviyelerin ± 3 cmH₂O aralığında olacak şekilde tahmin edilmiştir.

İlk 10 modelin geliştirilmesinde kullanılan öğrenme parametreleri Çizelge 7.13’te gösterilmiştir.

Çizelge 7.13 Model-1...Model-10 için öğrenme parametreleri

Model	Yöntem	Parametreler
Model-1	ANN	öo: 0.014, m:0.015, İterasyon: 600, Gizli Katman Nöron Sayısı: 2
Model-2	ANN	öo: 0.3, m: 0.07, İterasyon: 430, Gizli Katman Nöron Sayısı: 3
Model-3	SVM	Fonksiyon: RBFKernel, c=0.7
Model-4	SVM	Fonksiyon: RBFKernel, c=18
Model-5	ANN	öo: 0.01, m: 0.2, İterasyon: 500, Gizli Katman Nöron Sayısı: 3
Model-6	SVM	Fonksiyon: PolyKernel, c=0.9
Model-7	SVM	Fonksiyon: RBFKernel, c=5.1
Model-8	SVM	Fonksiyon: RBFKernel, c=4.2
Model-9	SVM	Fonksiyon: PolyKernel, c=0.17
Model-10	SVM	Fonksiyon: PolyKernel, c=0.04

*öo: öğrenme oranı, m:momentum, c: ceza parametresi

10 adet CPAP tahmin modelinin geliştirilmesinin ardından, özellik setleri kullanılarak S-MLR analizi gerçekleştirilmiş ve analiz sırasında her bir özellik setine ait hedef değerlere katkısı en fazla olan özellikler belirlenmiştir. Bu özelliklerin hem S-MLR analizi hem de ANN, PolyKernel fonksiyonlu SVM, RBFKernel fonksiyonlu

SVM, kNN ve RF yapay zeka yöntemleri ile kullanılmasıyla optimum CPAP seviyeleri tahmin edilmiş, tahmin sonuçları Çizelge 7.14'te gösterilmiştir. Çizelge 7.14'te her bir özellik seti için S-MLR analizi ile belirlenen özelliklerin kullanılmasıyla elde edilen maksimum test performansları farklı yazı renkleri ile gösterilmiştir.

Çizelge 7.14. S-MLR analizine göre belirlenen özelliklerin farklı yöntemlerle kullanılması ile elde edilen CPAP tahmin sonuçları

S-MLR Analizi ile Belirlenen Özellikler	PÖ.	Eğitim						Test					
		S-MLR	ANN	SVM Poly	SVM RBF	kNN	RF	S-MLR	ANN	SVM Poly	SVM RBF	kNN	RF
ÖS1	r:	0.35	0.41	0.43	0.43	0.43	0.39	0.64	0.69	0.64	0.62	0.45	0.40
ÖS1_1, ÖS1_2, ÖS1_3 (3 özellik)	p <	0.05	0.005	0.005	0.005	0.005	0.005	0.001	0.001	0.001	0.001	0.05	0.05
	r ² :	0.12	0.17	0.18	0.18	0.18	0.15	0.41	0.48	0.41	0.38	0.20	0.16
ÖS2	r:	0.65	0.66	0.68	0.62	0.52	0.47	0.55	0.52	0.55	0.56	0.43	0.43
ÖS2_8, ÖS2_21, ÖS2_34 (3 özellik)	p <	0.001	0.001	0.001	0.001	0.001	0.001	0.005	0.005	0.005	0.005	0.05	0.05
	r ² :	0.42	0.43	0.46	0.38	0.27	0.22	0.30	0.27	0.30	0.31	0.18	0.18
ÖS3	r:	0.39	0.36	0.37	0.40	0.28	0.17	0.50	0.54	0.61	0.61	0.50	0.36
ÖS3_33 (1 özellik)	p <	0.005	0.05	0.05	0.005	0.05	0.5	0.005	0.005	0.001	0.001	0.005	0.05
	r ² :	0.15	0.13	0.14	0.16	0.07	0.02	0.25	0.29	0.37	0.37	0.25	0.13
ÖS4	r:	0.55	0.50	0.55	0.53	0.63	0.61	0.76	0.69	0.79	0.75	0.79	0.71
ÖS4_17, S4_22, ÖS4_23 (3 özellik)	p <	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
	r ² :	0.30	0.25	0.30	0.28	0.40	0.37	0.58	0.48	0.62	0.56	0.62	0.50
ÖS 1-2	r:	0.70	0.70	0.68	0.67	0.57	0.52	0.71	0.71	0.69	0.70	0.57	0.53
ÖS1_3, ÖS2_8, ÖS2_34 (3 özellik)	p <	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.005	0.005
	r ² :	0.49	0.49	0.46	0.45	0.32	0.27	0.50	0.50	0.48	0.49	0.32	0.28
ÖS 1-3	r:	0.64	0.57	0.60	0.60	0.50	0.40	0.71	0.72	0.76	0.70	0.66	0.69
ÖS1_3, ÖS3_24, ÖS3_30 (3 özellik)	p <	0.001	0.001	0.001	0.001	0.001	0.005	0.001	0.001	0.001	0.001	0.001	0.001
	r ² :	0.41	0.32	0.36	0.36	0.25	0.16	0.50	0.52	0.58	0.49	0.44	0.48
ÖS 1-4	r:	0.77	0.76	0.72	0.61	0.72	0.56	0.83	0.82	0.74	0.82	0.79	0.76
ÖS1_3, ÖS4_19, ÖS4_22, ÖS4_23 (4 özellik)	p <	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
	r ² :	0.59	0.58	0.52	0.37	0.52	0.31	0.69	0.67	0.55	0.67	0.62	0.58
ÖS 2-3	r:	0.68	0.66	0.65	0.63	0.64	0.54	0.55	0.56	0.60	0.60	0.67	0.57
ÖS2_8, ÖS3_26 (2 özellik)	p <	0.001	0.001	0.001	0.001	0.001	0.001	0.005	0.005	0.001	0.001	0.001	0.005
	r ² :	0.46	0.44	0.42	0.40	0.41	0.29	0.30	0.31	0.36	0.36	0.45	0.32
ÖS 2-3-4	r:	0.82	0.74	0.77	0.70	0.72	0.62	0.82	0.80	0.81	0.78	0.75	0.67
ÖS2_4, ÖS2_8, ÖS3_26, ÖS3_37, ÖS4_2, ÖS4_18, ÖS4_22 (7 özellik)	p <	0.001	0.01	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
	r ² :	0.67	0.55	0.59	0.49	0.52	0.38	0.67	0.64	0.66	0.61	0.56	0.45
ÖS 1-2-3-4	r:	0.75	0.58	0.70	0.70	0.74	0.63	0.85	0.73	0.80	0.80	0.72	0.75
ÖS1_3, ÖS2_8, ÖS2_18, S2_34, ÖS4_22, S4_23 (6 özellik)	p <	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
	r ² :	0.56	0.34	0.49	0.49	0.55	0.40	0.72	0.53	0.64	0.64	0.52	0.56

* PÖ.:Performans Ölçütü

S-MLR analizi sırasında her bir özellik seti için belirlenen en yüksek katkılı özellikleri kullanarak maksimum performansları üreten yöntemler ile CPAP tahmin modelleri geliştirilmiştir.

Model-11: ÖS1 zaten 3 adet özellik içerdiği için S-MLR ile analizi sırasında da bu 3 özelliğin tamamı herhangi bir seçme yapılmadan CPAP tahmininde kullanılmıştır. Bu nedenle, bu özellikler ile gerçekleştirilen tahmin işlemi aslında ÖS1'in tüm özelliklerinin kullanıldığı tahmin işlemi ile aynıdır. Yani Model-11, Model-1 ile aynıdır ve ÖS1'in üç özelliği ile ANN yöntemini içermektedir. Dolayısıyla ürettiği sonuçlar da Model-1'in sonuçları ile aynıdır.

Model-12: On ikinci model, ÖS2'nin S-MLR ile analizi sırasında belirlenen 3 özelliği ve PolyKernel fonksiyonlu SVM yönteminden oluşmaktadır. S-MLR analizi ve PolyKernel fonksiyonlu SVM yöntemleri eşit test performansları üretseler de, PolyKernel fonksiyonlu SVM yönteminin eğitim performansı daha yüksek olmuştur. Bu nedenle Model-12, PolyKernel fonksiyonlu SVM yöntemi ile geliştirilmiştir. Hava akımı ve oksimetri sinyallerine ait yalnızca 3 özelliğin tahmin parametresi olduğu bu model ile eğitimde r değeri 0.68, r^2 değeri 0.46, testte r değeri 0.55, r^2 değeri 0.30 olarak elde edilmiştir. Model ile elde edilen p değerleri de istatistiksel anlamlılığı ifade edecek şekilde 0.005'ten küçük bulunmuştur. Bu model kullanıldığında hastaların %83.75'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. Bu 3 parametrelili Model-12 ile ÖS2'nin tüm 39 özelliğini parametre olarak kullanan Model-2 karşılaştırılırsa, daha az parametrelili olan Model-12'nin daha yüksek performans sağladığı söylenebilmektedir.

Model-13: ÖS3'ün S-MLR analizi sırasında belirlenen yalnızca 1 özelliği ve RBFKernel fonksiyonlu SVM yöntemi kullanılarak on üçüncü model geliştirilmiştir. PolyKernel fonksiyonlu SVM yöntemi de aynı test performansını sağlamasına rağmen, RBFKernel fonksiyonlu SVM yöntemi daha yüksek eğitim performansı ürettiği için Model-13'ün geliştirilmesinde RBFKernel fonksiyonlu SVM tercih edilmiştir. Bu model ile eğitim r değeri 0.40, r^2 değeri 0.16, test r değeri 0.61, r^2 değeri 0.37 olarak elde edilmiştir. Hem eğitim hem test için p değeri 0.005'ten küçük olarak hesaplanmıştır. Bu model kullanılarak hastaların %85'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. 1 parametrelili Model-13, ÖS3'ün 37 özelliğini parametre olarak kullanan Model-3'e göre test aşamasında daha yüksek performans sağlamıştır.

Model-14: S-MLR ile analizi sırasında ÖS4'e ait 3 özellik belirlenmiş, PolyKernel fonksiyonlu SVM ve kNN yöntemleri ile en yüksek test performansı sağlanmıştır. kNN yönteminin eğitim performansının SVM'ye daha yüksek olmasından dolayı kNN ile Model-14 geliştirilmiştir. ÖS4'e ait 3 özelliği tahmin parametresi olarak kabul eden Model-14 ile eğitim r değeri 0.63, r^2 değeri 0.40, test r değeri 0.79, r^2 değeri 0.62 ve p değerleri 0.001'den küçük olarak elde edilmiştir. Model-14 kullanılarak CPAP seviyeleri tahmininde, hastaların %85'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. Daha az parametre ile Model-14, ÖS4'ün 25 özelliğini parametre olarak kullanan Model-4'e göre daha yüksek performans sağlamıştır.

Model-15: S-MLR ile analizi sırasında ÖS_1-2'ye ait 3 özellik belirlenmiş ve hem S-MLR analizi hem de ANN yöntemi ile en yüksek performans sağlanmıştır. 3 özelliğin tahmin parametresi olduğu bu süreçte Model-15 ile eğitim r değeri 0.70, r^2 değeri 0.49, test r değeri 0.71, r^2 değeri 0.50 olarak elde edilmiştir. Eğitim ve test p değerleri ise 0.001'den küçük hesaplanarak tahmin edilen ve optimum basınç seviyeleri arasında istatistiksel anlamlılığın bulunduğunu göstermiştir. S-MLR analizinin ve ANN yönteminin korelasyon katsayıları bakımından performansları eşit olmasına rağmen, tahmin edilen seviyelerin referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olduğu hasta sayısı S-MLR analizinde daha fazladır. Bu nedenle Model-15'in geliştirilmesi için belirlenen 3 özellik ile S-MLR analizi tercih edilmiştir ve denklem 7.1'de görülen tahmin formülü üretilmiştir. Böylelikle Model-15 ile, hastaların %85'inde tahmin edilen CPAP seviyeleri, referans optimum seviyelerin ± 3 cmH₂O aralığında olmuştur. Daha az parametre ile Model-15, ÖS_1-2'nin 42 özelliğini parametre olarak kullanan Model-5'e göre daha yüksek performans sağlamıştır.

$$\text{Model} - 15 = 12.065 + 0.1688 \times \text{ÖS1}_3 - 6.3913 \times \text{ÖS2}_8 - 0.0017 \times \text{ÖS2}_{34} \quad (7.1)$$

Model-16: ÖS_1-3'ün S-MLR analizi sırasında belirlenen 3 özelliği ve PolyKernel fonksiyonlu SVM yöntemi ile oluşturulan Model-16, eğitim r değerini 0.60, r^2 değerini 0.36, test r değerini 0.76, r^2 değerini 0.58 olarak üretmiştir. Model p değerlerini ise 0.001'den küçük olacak şekilde hesap etmiştir. Model-16 ile hastaların %83.75'inin CPAP seviyeleri, referans optimum seviyelerin ± 3 cmH₂O aralığında olacak şekilde tahmin edilmiştir. 3 tahmin parametrelili Model-16, 40 parametrelili Model-6'ya göre daha yüksek performans sağlamıştır.

Model-17: On yedinci model, ÖS_1-4'ün S-MLR ile analizi sırasında belirlenen 4 özelliği ve bu regresyon analizi ile geliştirilmiştir (Denklem 7.2). Model eğitim r değerini 0.77, r² değerini 0.59, test r değerini 0.83, r² değerini 0.69 olarak hesaplamıştır. Bu model ile p değerleri ise 0.001'den küçük olacak şekilde elde edilmiştir. Model-17 kullanılarak hastaların %90'ında CPAP seviyeleri referans optimum seviyelerin ±3 cmH₂O aralığında olacak şekilde tahmin edilmiştir. 4 tahmin parametresi içeren Model-17, ÖS_1-4'ün 28 özelliğini parametre olarak içeren Model-7'ye göre daha yüksek performans sağlamıştır.

$$\begin{aligned} \text{Model -17} = & (-10.597) + 0.5856 \times \text{ÖS1}_3 + 12.917 \times \text{ÖS4}_{19} - 0.004 \times \text{ÖS4}_{22} + \\ & 0.2625 \times \text{ÖS4}_{23} - 0.7497 \times (\text{ÖS1}_3 \times \text{ÖS4}_{19}) + 0.037 \times (\text{ÖS4}_{19} \times \text{ÖS4}_{22}) \end{aligned} \quad (7.2)$$

Model-18: S-MLR ile analiz sırasında ÖS_2-3'e ait 2 özellik belirlenmiş ve bu özellikler ile en yüksek test performansı sağlayan kNN yönteminden oluşan model, Model-18 olarak kabul edilmiştir. Bu model ile eğitimde r ve r² değerleri sırasıyla 0.64 ve 0.41 olarak, testte r ve r² değerleri sırasıyla 0.67 ve 0.45 olarak ve p değerleri 0.001'den küçük olarak hesaplanmıştır. Model-18'in icrası sonucunda, hastaların %88.75'inde CPAP seviyeleri, referans optimum seviyelerin ±3 cmH₂O aralığında olacak şekilde tahmin edilmiştir. 2 tahmin parametresi içeren Model-18, ÖS_2-3'ün 76 özelliğini parametre olarak içeren Model-8'e göre daha yüksek performans sağlamıştır.

Model-19: S-MLR analizi ile ÖS_2-3-4'e ait 7 özellik belirlenmiş ve en yüksek performans yine bu regresyon analizi sonucunda elde edilmiştir. Bu nedenle Model-19'u S-MLR analizi ve bu analiz ile belirlenen 7 özellik oluşturmuştur. Modele ait üretilen formül Denklem 7.3'te gösterilmektedir. Bu model ile hem eğitimde hem de testte r ve r² değerleri sırasıyla 0.82 ve 0.67 olarak, p değerleri 0.001'den küçük olarak elde edilmiştir. Model-19 kullanılarak hastaların %90'ında CPAP seviyeleri, referans optimum CPAP seviyelerinin ±3 cmH₂O aralığında olacak şekilde tahmin edilmiştir. 7 tahmin parametresi içeren Model-19, ÖS_2-3-4'ün 101 özelliğini parametre olarak içeren Model-9'a göre daha yüksek performans sağlamıştır.

$$\begin{aligned} \text{Model -19} = & 29.491 + 6.15 \times \text{ÖS2}_4 - 10.67 \times \text{ÖS2}_8 - 52.70 \times \text{ÖS3}_{26} - \\ & 21.73 \times \text{ÖS3}_{37} - 0.23 \times \text{ÖS4}_2 - 0.005 \times \text{ÖS4}_{18} + 0.01 \times \text{ÖS4}_{22} \end{aligned} \quad (7.3)$$

Model-20: S-MLR analizi ile ÖS_1-2-3-4'e ait 6 özellik belirlenmiş ve en yüksek performans yine bu regresyon analizi sonucunda elde edilmiştir. Bu nedenle

Model-20, S-MLR ve bu analiz ile belirlenen 6 özelliğin kullanımı sonucu oluşan Denklem 7.4'teki formülü içermektedir. Bu model ile eğitim r değeri 0.75, r^2 değeri 0.56, test r değeri 0.85, r^2 değeri 0.72 olarak elde edilmiştir. Model ayrıca eğitim ve testte p değerlerini 0.001'den küçük olarak hesaplamıştır. Model-20 sayesinde hastaların %91.25'inde CPAP seviyeleri, referans optimum seviyelerin ± 3 cmH₂O aralığında olacak şekilde tahmin edilmiştir. 6 tahmin parametresi içeren Model-20, ÖS_1-2-3-4'ün 104 özelliğini parametre olarak içeren Model-10'a göre daha yüksek performans sağlamıştır.

$$\begin{aligned} Model - 20 = & 6.2664 + 0.15782 \times \text{ÖS1}_3 - 4.4912 \times \text{ÖS2}_8 - 114.52 \times \text{ÖS2}_{18} - \\ & 0.0019 \times \text{ÖS2}_{34} + 0.0135 \times \text{ÖS4}_{22} + 0.13464 \times \text{ÖS4}_{23} \end{aligned} \quad (7.4)$$

Model-11,...,Model-20'nin oluşturulmasında kullanılan öğrenme parametreleri Çizelge 7.15'te gösterilmiştir.

Çizelge 7.15 Model-11,..., Model-20 için öğrenme parametreleri

Model	Yöntem	Parametreler
Model-11	ANN	öo: 0.014, m:0.015, İterasyon: 600, Gizli Katman Nöron Sayısı: 2
Model-12	SVM	Fonksiyon: PolyKernel, c=0.8
Model-13	SVM	Fonksiyon: RBFKernel, c=6
Model-14	kNN	k=3
Model-15	S-MLR	Özelliklerin modele eklenme eşik değeri p=0.05, çıkarılma eşik değeri p=0.1
Model-16	SVM	Fonksiyon: 2. Dereceden PolyKernel, c=2
Model-17	S-MLR	Özelliklerin modele eklenme eşik değeri p=0.05, çıkarılma eşik değeri p=0.1
Model-18	kNN	k=3
Model-19	S-MLR	Özelliklerin modele eklenme eşik değeri p=0.05, çıkarılma eşik değeri p=0.1
Model-20	S-MLR	Özelliklerin modele eklenme eşik değeri p=0.05, çıkarılma eşik değeri p=0.1

*öo: öğrenme oranı, m:momentum, c: ceza parametresi

Özellik setlerindeki tüm özelliklerin CPAP seviyeleri üzerinde etkili olamayabileceği, bazı özelliklerin diğerlerine göre daha etkin olabileceği ve tahmin için daha fazla katkı sağlayabileceği düşünülmüş ve tüm özellik setlerine en iyi arama (best-first search) tekniğini kullanan Korelasyon Tabanlı Alt Küme Değerlendirme ve Sarmal Alt Küme Değerlendirme olmak üzere iki farklı özellik seçme yöntemi uygulanmıştır. Böylelikle iki yöntemle de her özellik seti için etkin özellikler seçilerek optimum CPAP seviye tahminleri yalnızca etkin özellikler ile gerçekleştirilmiştir.

Korelasyon Tabanlı Alt Küme Değerlendirme özellik seçme yönteminin her bir özellik seti için seçtiği özelliklerin özellik sayılarına göre SLR veya MLR analizlerinden biri ve ANN, PolyKernel ve RBFKernel fonksiyonlu SVM, kNN ve RF yapay zeka yöntemleri ile kullanılmasıyla gerçekleştirilen optimum CPAP seviye

tahmin sonuçları Çizelge 7.16'da gösterilmektedir. Her bir özellik setinin seçilmiş özelliklerinin kullanılması sonucunda CPAP seviye tahminlerine ait elde edilen maksimum test performansları çizelge 7.16'da farklı yazı renkleri ile belirtilmiştir.

Çizelge 7.16. Korelasyon Tabanlı Alt Küme Değerlendirme ile seçilen özelliklerin farklı yöntemlerle kullanılmasıyla elde edilen CPAP tahmin sonuçları

Özellik Seti	PÖ.	Eğitim						Test					
		MLR	ANN	SVM Poly	SVM RBF	kNN	RF	MLR	ANN	SVM Poly	SVM RBF	kNN	RF
ÖS1 ÖS1_2,ÖS1_3	r:	0.47	0.49	0.52	0.52	0.32	0.32	0.65	0.66	0.69	0.63	0.58	0.33
	p <	0.001	0.001	0.001	0.001	0.005	0.005	0.001	0.001	0.001	0.001	0.001	0.5
	r ² :	0.22	0.24	0.27	0.27	0.10	0.10	0.42	0.44	0.48	0.40	0.34	0.11
ÖS2 ÖS2_2,ÖS2_5, ÖS2_8	r:	0.59	0.61	0.65	0.62	0.72	0.63	0.55	0.57	0.62	0.60	0.64	0.49
	p <	0.001	0.001	0.001	0.001	0.001	0.001	0.005	0.05	0.001	0.001	0.001	0.05
	r ² :	0.35	0.37	0.42	0.39	0.52	0.40	0.30	0.32	0.38	0.36	0.41	0.34
ÖS3 ÖS3_24,ÖS3_30, ÖS3_33,ÖS3_34, ÖS3_35	r:	0.44	0.45	0.43	0.46	0.49	0.27	0.53	0.56	0.56	0.56	0.39	0.36
	p <	0.005	0.001	0.05	0.001	0.001	0.5	0.005	0.005	0.005	0.005	0.05	0.005
	r ² :	0.19	0.20	0.18	0.21	0.24	0.07	0.28	0.31	0.31	0.31	0.15	0.13
ÖS4 ÖS4_1,ÖS4_7, ÖS4_15,ÖS4_17, ÖS4_22,ÖS4_23	r:	0.44	0.48	0.56	0.53	0.52	0.59	0.61	0.62	0.64	0.60	0.60	0.62
	p <	0.005	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
	r ² :	0.19	0.23	0.31	0.28	0.27	0.35	0.37	0.38	0.41	0.36	0.36	0.39
ÖS 1-2 ÖS1_3,ÖS2_2, ÖS2_5,ÖS2_8	r:	0.55	0.56	0.56	0.65	0.65	0.55	0.58	0.59	0.60	0.60	0.52	0.55
	p <	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
	r ² :	0.60	0.31	0.31	0.42	0.42	0.30	0.34	0.35	0.36	0.36	0.27	0.30
ÖS 1-3 ÖS1_3,ÖS3_11, ÖS3_14,ÖS3_24, ÖS3_26,ÖS3_27, ÖS3_28,ÖS3_29, ÖS3_30,ÖS3_31, ÖS3_33,ÖS3_34, ÖS3_35,ÖS3_36, ÖS3_37	r:	0.47	0.67	0.54	0.54	0.47	0.39	0.56	0.57	0.55	0.55	0.48	0.54
	p <	0.001	0.001	0.001	0.001	0.001	0.005	0.001	0.001	0.001	0.001	0.001	0.001
	r ² :	0.22	0.45	0.29	0.29	0.22	0.15	0.31	0.32	0.30	0.30	0.23	0.29
ÖS 1-4 ÖS1_2,ÖS1_3, ÖS4_7,ÖS4_10, ÖS4_22,ÖS4_23	r:	0.55	0.53	0.58	0.58	0.55	0.52	0.61	0.63	0.65	0.61	0.59	0.62
	p <	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
	r ² :	0.30	0.28	0.34	0.34	0.30	0.27	0.37	0.40	0.42	0.37	0.35	0.38
ÖS 2-3 ÖS2_2,ÖS2_5, ÖS2_8,ÖS3_24	r:	0.58	0.59	0.70	0.63	0.56	0.61	0.57	0.57	0.60	0.58	0.58	0.57
	p <	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
	r ² :	0.34	0.35	0.49	0.40	0.31	0.37	0.33	0.33	0.36	0.34	0.34	0.33
ÖS 2-3-4 ÖS2_3,ÖS2_5, ÖS2_8, ÖS3_24, ÖS4_18	r:	0.62	0.66	0.64	0.56	0.55	0.59	0.60	0.61	0.57	0.58	0.56	0.58
	p <	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
	r ² :	0.38	0.44	0.41	0.31	0.30	0.35	0.36	0.37	0.33	0.34	0.31	0.34
ÖS 1-2-3-4 ÖS1_3,ÖS2_2, ÖS2_5,ÖS2_8, ÖS3_24,ÖS4_18	r:	0.64	0.71	0.74	0.65	0.60	0.57	0.63	0.75	0.76	0.75	0.62	0.69
	p <	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.01
	r ² :	0.41	0.50	0.55	0.42	0.36	0.32	0.40	0.56	0.58	0.56	0.38	0.48

*PÖ.:Performans Ölçütü

Özellik setlerinin maksimum performanslarını üreten seçilmiş özellikleri ve yöntemler ile CPAP tahmin modelleri geliştirilmiştir.

Model-21: Model-21, ÖS1'in Korelasyon Tabanlı Alt Küme Değerlendirme yöntemi ile seçilen 2 özelliği ve en yüksek test sonucunu üreten PolyKernel fonksiyonlu SVM yönteminden oluşmaktadır. 2 özelliğin tahmin parametresi olarak kullanıldığı bu model ile eğitimde r değeri 0.52, r^2 değeri 0.27, testte r değeri 0.69, r^2 değeri 0.48 olarak elde edilmiştir. Model ile elde edilen p değerleri de istatistiksel anlamlılığı ifade edecek şekilde 0.001'den küçük bulunmuştur. Bu model kullanıldığında hastaların %83.75'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. Bu 2 parametrelili Model-21 ile ÖS1'in 3 özelliğini de parametre olarak kullanan Model-1 ve Model-11 kıyaslanırsa, modellerin test performanslarının eşit olduğu ancak Model-21'in daha az özellikle bu performansı sağladığı söylenebilmektedir.

Model-22: Korelasyon Tabanlı Alt Küme Değerlendirme yöntemi ile ÖS2'ye ait 3 etkin özellik seçilmiş ve bu özelliklerin kNN tarafından kullanımı sonucunda CPAP tahmininde diğer yöntemlere göre daha yüksek performans elde edilmiştir. Bu nedenle Model-22, ÖS2'ye ait Korelasyon Tabanlı Alt Küme Değerlendirme yöntemi ile seçilen 3 özellik ve kNN yöntemi kullanılarak geliştirilmiştir. 3 tahmin parametrelili bu model ile eğitim r ve r^2 değerleri sırasıyla 0.72 ve 0.52 olarak, test r ve r^2 değerleri sırasıyla 0.64 ve 0.41 olarak elde edilmiştir. Eğitim ve test p değerleri 0.01'den küçük hesaplanarak istatistiksel anlamlılığı göstermiştir. Model-22 ile gerçekleştirilen optimum CPAP seviyelerinin tahmini ile hastaların %81.25'inde tahmin edilen CPAP seviyeleri, referans optimum seviyelerin ± 3 cmH₂O aralığında olmuştur. ÖS2'ye ait 3 özelliği parametre olarak değerlendiren Model-22'nin performansı aynı özellik setinden geliştirilen 39 parametrelili Model-2 ve 3 parametrelili Model-12'ye göre daha yüksek olmuştur.

Model-23: ÖS3'e Korelasyon Tabanlı Alt Küme Değerlendirme yönteminin uygulanmasıyla 5 etkin özellik seçilmiş ve etkin özelliklerin ANN, PolyKernel fonksiyonlu SVM ve RBFKernel fonksiyonlu SVM yöntemleriyle kullanılmasıyla en yüksek test performansları elde edilmiştir. Bu 3 yöntemin test performansları aynı olmasına rağmen RBFKernel fonksiyonlu SVM'in eğitim performansı diğer iki yönteminkine göre daha yüksektir. Ayrıca tahmin edilen CPAP seviyelerinin referans optimum seviyelerin ± 3 cmH₂O aralığında olduğu hasta sayısı ve yüzdesi, RBFKernel fonksiyonlu SVM yöntemi ile diğer 2 yönteme göre daha fazla olarak bulunmuştur. Bu

nedenle Model-23, ÖS3'ün Korelasyon Tabanlı Alt Küme Değerlendirme yöntemiyle seçilen 5 özelliğinden ve RBFKernel fonksiyonlu SVM yönteminden oluşturulmuştur. Model-23 kullanılarak eğitim r ve r^2 değerleri sırasıyla 0.46 ve 0.21 olarak, test r ve r^2 değerleri sırasıyla 0.56 ve 0.31 olarak elde edilmiştir. Eğitim ve test p değerleri de 0.01'den küçük hesaplanarak istatistiksel anlamlı bulunmuştur. Model-23 ile gerçekleştirilen optimum CPAP seviyelerinin tahmini ile hastaların %85'inde tahmin edilen CPAP seviyeleri, referans optimum seviyelerin ± 3 cmH₂O aralığında olmuştur. ÖS3'e ait 5 özelliği tahmin parametresi olarak değerlendiren Model-23'ün performansı aynı özellik setinden geliştirilen 37 parametrelili Model-3'ten daha yüksektir. Model 23 aynı özellik setine ait yalnızca 1 özelliği parametre olarak kullanan Model-13 ile karşılaştırıldığında ise Model-23'ün eğitim performansının daha yüksek Model-13'ün de test performansının daha yüksek olduğu görülmüştür.

Model-24: Model-24, ÖS4'ün Korelasyon Tabanlı Alt Küme Değerlendirme yöntemiyle seçilen 6 özelliği ve en yüksek test tahmin performansını sağlayan PolyKernel fonksiyonlu SVM yöntemi ile geliştirilmiştir. 6 özelliği tahmin parametresi olarak kullanan Model-24 ile eğitim için r değeri 0.56, r^2 değeri 0.31 olarak, test için r değeri 0.64, r^2 değeri 0.41 olarak, eğitim ve test p değerleri 0.001'den küçük olarak hesaplanmıştır. Model-24'ün kullanılması ile hastaların %86.25'inin CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olacak şekilde tahmin edilmiştir. 6 parametrelili Model-24'ün eğitim ve test performansları ÖS4'ten geliştirilen 3 parametrelili Model-14'e göre daha düşüktür. Model-24'ün eğitim performansı aynı özellik setinden geliştirilen 25 parametrelili Model-4'e göre daha yüksek ancak Model-4'ün test performansından daha düşüktür.

Model-25: Korelasyon Tabanlı Alt Küme Değerlendirme yöntemi ile ÖS_1-2'ye ait 4 etkin özellik seçilmiştir. PolyKernel fonksiyonlu ve RBFKernel fonksiyonlu SVM yöntemleri bu özellikleri kullanarak eşit test performansları üretmişlerdir. Ancak RBFKernel fonksiyonlu yöntem hem daha yüksek eğitim performansı sağlamış hem de bu yöntem ile daha fazla sayıda hastanın tahmin edilen seviyeleri referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. Bu nedenlerden dolayı RBFKernel fonksiyonlu SVM yöntemi model oluşumu için tercih edilmiştir. Böylelikle Model-25, ÖS_1-2'ye ait seçilen 4 etkin özellik ve RBFKernel fonksiyonlu SVM yöntemi kullanılarak geliştirilmiştir. 4 özelliğin tahmin parametresi olduğu bu model ile eğitim r ve r^2 değerleri sırasıyla 0.65 ve 0.42 olarak, test r ve r^2 değerleri sırasıyla 0.60 ve 0.36 olarak elde edilmiştir. Eğitim ve test p değerleri de 0.001'den küçük olarak

hesaplanmıştır. Model-25 ile gerçekleştirilen tahmin işleminde, hastaların %90'nı için tahmin edilen CPAP seviyeleri, referans optimum seviyelerin ± 3 cmH₂O aralığında olmuştur. 4 parametrelili Model-25'in eğitim ve test performansları, ÖS_1-2'den geliştirilen 3 parametrelili Model-15'e göre daha düşüktür. Model-25'in eğitim performansı aynı özellik setinden geliştirilen 42 parametrelili Model-5'e göre daha yüksek ancak Model-5'in test performansından daha düşüktür.

Model-26: ÖS_1-3'e Korelasyon Tabanlı Alt Küme Değerlendirme yönteminin uygulanması sonucunda 15 özellik etkin olarak seçilmiştir. Bu özelliklerin ANN yöntemi ile kullanılmasıyla en yüksek performansa ulaşılmıştır ve Model-26 geliştirilmiştir. ÖS_1-3'e ait 15 özelliğin tahmin parametresi olduğu bu model ile eğitim r ve r^2 değerleri sırasıyla 0.67 ve 0.45 olarak, test r ve r^2 değerleri sırasıyla 0.57 ve 0.32 olarak elde edilmiştir. Eğitim ve test p değerleri 0.001'den küçük hesaplanarak istatistiksel anlamlılığı ifade etmiştir. Bu model ile hastaların %78.75'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. 15 tahmin parametrelili Model-26 aynı özellik setinden geliştirilen 40 tahmin parametrelili Model-6 ve 3 tahmin parametrelili Model-16'ya göre eğitim performansı bakımından yüksek performans sağlasa da test performansı bu iki modelinkinden de daha düşük olmuştur.

Model-27: Model-27, ÖS_1-4'ün Korelasyon Tabanlı Alt Küme Değerlendirme yöntemiyle seçilen 6 özelliği ve PolyKernel fonksiyonlu SVM yöntemi kullanılarak geliştirilmiştir. 6 özelliğin tahmin parametresi olduğu Model-24 ile eğitim r ve r^2 değerleri sırasıyla 0.58 ve 0.34 olarak, test r ve r^2 değerleri sırasıyla 0.65 ve 0.42 olarak hesaplanmıştır. Hem eğitim hem de test p değerleri 0.001'den küçük olarak elde edilmiştir. Model-27 kullanılarak gerçekleştirilen tahmin ile hastaların %85'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. ÖS_1-4'e ait 6 özelliği tahmin parametresi olarak değerlendiren Model-27'nin performansı aynı özellik setinden geliştirilen 4 parametrelili Model-17'nin performansından daha düşüktür. Model 27 aynı özellik setine ait 28 özelliği parametre olarak kullanan Model-7 ile karşılaştırıldığında ise Model-27'nin eğitim performansının daha yüksek, Model-7'nin ise test performansının daha yüksek olduğu görülmüştür.

Model-28: Korelasyon Tabanlı Alt Küme Değerlendirme özellik seçimi yöntemi ile ÖS_2-3'e ait 4 etkin özellik seçilmiş ve bu etkin özelliklerin PolyKernel fonksiyonlu SVM yöntemi ile kullanılması sonucunda en yüksek tahmin performansı elde edilmiştir. Bu nedenle Model-28, ÖS_2-3'e ait 4 özellik ve PolyKernel fonksiyonlu SVM yöntemi

ile geliştirilmiştir. 4 özelliği tahmin parametresi olarak kabul eden Model-28 ile eğitim r değeri 0.70, r^2 değeri 0.49 olarak, test r değeri 0.60 r^2 değeri 0.36 olarak hem eğitim hem test p değerleri 0.001'den küçük olarak hesaplanmıştır. Bu modelin kullanılmasıyla hastaların %87.5'inde referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olacak şekilde CPAP seviyeleri tahmin edilmiştir. 4 tahmin parametresine sahip Model-28 aynı özellik setinden geliştirilen 76 tahmin parametrelili Model-8 ve 2 tahmin parametrelili Model-18'e göre eğitim performansı bakımından yüksek performans sağlasa da test performansı bakımından bu iki modelinkinden de daha düşük performansa sahip olmuştur.

Model-29: ÖS_2-3-4'e ait Korelasyon Tabanlı Alt Küme Değerlendirme yöntemiyle seçilen 5 özellik ve en yüksek performansı sağlayan ANN kullanılarak Model-29 geliştirilmiştir. 5 özelliği tahmin parametresi olarak kabul eden bu model ile eğitim r ve r^2 değerleri sırasıyla 0.66 ve 0.44 olarak, test r ve r^2 değerleri sırasıyla 0.61 ve 0.37 olarak elde edilmiştir. Eğitim ve test p değerleri ise 0.001'den küçük olacak şekilde hesaplanmıştır. Bu model sayesinde hastaların %85'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. 5 tahmin parametrelili Model-29'un performansı, aynı özellik setinden geliştirilen 101 parametrelili Model-9'a ve 7 parametrelili Model-19'a ait performanslarla karşılaştırılmış ve görülmüştür ki; Model-19'un CPAP seviyelerini tahmin performansı Model-29'dan daha yüksektir ve Model-9'un eğitim performansı Model-29'dan daha düşük olsa da test performansı daha yüksektir.

Model-30: Korelasyon Tabanlı Alt Küme özellik seçim yönteminin uygulanmasıyla CPAP tahmini için ÖS_1-2-3-4'e ait 6 etkin özellik seçilmiş ve en yüksek performans PolyKernel fonksiyonlu SVM yöntemiyle sağlanmıştır. Bu nedenle Model-30, ÖS_1-2-3-4'ün seçilmiş 6 özelliği ve PolyKernel fonksiyonlu SVM yöntemi kullanılarak geliştirilmiştir. Model-30 ile CPAP tahmininde, eğitim r değeri 0.74, r^2 değeri 0.55 olarak, test r değeri 0.76, r^2 değeri 0.58 olarak hesaplanmıştır. Eğitim ve test için p değerleri 0.001'den küçük bulunarak istatistiksel anlamlılığı belirtmiştir. Model-30'un CPAP tahmini sonucunda hastaların %86.25'inde tahmin edilen CPAP seviyeleri, referans optimum seviyelerin ± 3 cmH₂O aralığında olmuştur. 6 tahmin parametrelili Model-30'un tahmin performansı aynı özellik setinden geliştirilen 104 parametrelili Model-10 ve 6 parametrelili Model-20'nin tahmin performansları ile karşılaştırılmış ve görülmüştür ki; Model-20'nin CPAP seviyelerini tahmin performansı Model-30'dan daha yüksektir ve Model-10'un tahmin performansı Model-30'dan daha düşüktür.

Model-21,...,Model-30'un oluşturulmasında kullanılan öğrenme parametreleri Çizelge 7.17'de gösterilmiştir.

Çizelge 7.17. Model-21,..., Model-30 için öğrenme parametreleri

Model	Yöntem	Parametreler
Model-21	SVM	Fonksiyon: PolyKernel, c=7
Model-22	kNN	k=3
Model-23	SVM	Fonksiyon: RBFKernel, c=2.5
Model-24	SVM	Fonksiyon: 2. Dereceden PolyKernel, c=1
Model-25	SVM	Fonksiyon: RBFKernel, c=2
Model-26	ANN	öo: 0.08, m:0.07, İterasyon: 400, Gizli Katman Nöron Sayısı: 4
Model-27	SVM	Fonksiyon: PolyKernel, c=2
Model-28	SVM	Fonksiyon: PolyKernel, c=0.5
Model-29	ANN	öo: 0.02, m:0.01, İterasyon: 510, Gizli Katman Nöron Sayısı: 6
Model-30	SVM	Fonksiyon: PolyKernel, c=0.9

*öo: öğrenme oranı, m:momentum, c: ceza parametresi

Sarmal Alt Küme Değerlendirme yönteminde özelliklerin seçimi belirlenen öğrenme algoritmasına göre gerçekleştirilir. Bu nedenle tez çalışması kapsamında her bir özellik seti için doğrusal regresyon analizine (SLR veya MLR) ve ANN, PolyKernel fonksiyonlu SVM, RBFKernel fonksiyonlu SVM, kNN ve RF yapay zeka yöntemlerine göre özellik seçimleri gerçekleştirilmiş ve seçilen özelliklerle hastalara ait optimum CPAP seviyeleri tahmin edilmiştir. Tahmin sonuçlarına göre en yüksek test performansı sağlayan özellikler ile yöntemlerin oluşturduğu modeller CPAP tahmin modelleri olarak kabul edilmiştir.

Çizelge 7.18.a ÖS1, ÖS2, ÖS3 ve ÖS4 için Sarmal Alt Küme Değerlendirme yöntemi ile elde edilen etkin özellikleri ve bu özelliklerin farklı yöntemler tarafından kullanılmasıyla ulaşılan optimum CPAP seviyeleri tahmin sonuçlarını, Çizelge 7.18.b ÖS_1-2, ÖS_1-3 ve ÖS_1-4'e ait Sarmal Alt Küme Değerlendirme yöntemi ile seçilen özellikleri ve bu özelliklerin farklı yöntemler tarafından kullanılmasıyla ulaşılan optimum CPAP seviyeleri tahmin sonuçlarını ve Çizelge 7.18.c ÖS_2-3, ÖS_2-3-4 ve ÖS_1-2-3-4'ün Sarmal Alt Küme Değerlendirme yöntemi ile seçilen özelliklerini ve bu özelliklerin farklı yöntemler tarafından kullanılması sonucunda elde edilen optimum CPAP seviyeleri tahmin sonuçlarını göstermektedir. Her bir özellik setinin seçilmiş özelliklerinin kullanılması sonucunda CPAP seviye tahminlerine ait elde edilen maksimum test performansları çizelge 7.18.a, 7.18.b ve 7.18.c'de farklı yazı renkleri ile belirtilmiştir.

Çizelge 7.18.a. ÖS1,ÖS2,ÖS3 ve ÖS4'ün Sarmal Alt Küme Değerlendirme ile seçilen özelliklerinin farklı yöntemlerle kullanılması sonucunda ürettiği CPAP tahmin sonuçları

Özellik Seti	Sarmal Alt Küme-Yöntem	Seçilen Özellikler	Eğitim			Test		
			r	p<	r ²	r	p<	r ²
ÖS1	SLR	ÖS1_3	0.49	0.001	0.24	0.67	0.001	0.45
	ANN	ÖS1_3	0.49	0.001	0.24	0.69	0.001	0.48
	SVM (PolyKernel)	ÖS1_3	0.53	0.001	0.28	0.69	0.001	0.48
	SVM (RBFKernel)	ÖS1_3	0.50	0.001	0.25	0.64	0.001	0.41
	kNN	ÖS1_1, ÖS1_3	0.47	0.001	0.22	0.50	0.005	0.25
	RF	ÖS1_1, ÖS1_3	0.48	0.001	0.23	0.60	0.001	0.36
ÖS2	MLR	ÖS2_1, ÖS2_7, ÖS2_8, ÖS2_9, ÖS2_13, ÖS2_14, ÖS2_18, ÖS2_21, ÖS2_22, ÖS2_27, ÖS2_29, ÖS2_30, ÖS2_33, ÖS2_34, ÖS2_35	0.62	0.001	0.38	0.68	0.001	0.46
	ANN	ÖS2_6, ÖS2_7, ÖS2_8, ÖS2_12, ÖS2_14, ÖS2_18, ÖS2_22, ÖS2_29, ÖS2_34	0.65	0.001	0.42	0.69	0.001	0.48
	SVM (PolyKernel)	ÖS2_4, ÖS2_8, ÖS2_9, ÖS2_14, ÖS2_18, ÖS2_24, ÖS2_26, ÖS2_29, ÖS2_34	0.73	0.001	0.53	0.69	0.001	0.48
	SVM (RBFKernel)	ÖS2_2, ÖS2_5, ÖS2_8, ÖS2_18, ÖS2_29, ÖS2_33, ÖS2_34	0.67	0.001	0.45	0.63	0.001	0.40
	kNN	ÖS2_3, ÖS2_6, ÖS2_9, ÖS2_13	0.63	0.001	0.40	0.65	0.001	0.42
	RF	ÖS2_3, ÖS2_5, ÖS2_9, ÖS2_10, ÖS2_11, ÖS2_13, ÖS2_16	0.68	0.001	0.46	0.61	0.001	0.37
ÖS3	MLR	ÖS3_1, ÖS3_7, ÖS3_11, ÖS3_20, ÖS3_24, ÖS3_33	0.45	0.05	0.20	0.55	0.005	0.30
	ANN	ÖS3_2, ÖS3_3, ÖS3_4, ÖS3_5, ÖS3_11, ÖS3_16, ÖS3_19, ÖS3_24, ÖS3_30, ÖS3_33	0.45	0.05	0.20	0.59	0.001	0.35
	SVM (PolyKernel)	ÖS3_3, ÖS3_11, ÖS3_14, ÖS3_16, ÖS3_31, ÖS3_36	0.52	0.001	0.27	0.71	0.001	0.50
	SVM (RBFKernel)	ÖS3_2, ÖS3_3, ÖS3_11, ÖS3_12, ÖS3_13, ÖS3_14, ÖS3_20, ÖS3_31, ÖS3_33, ÖS3_35	0.49	0.001	0.24	0.63	0.001	0.40
	kNN	ÖS3_10, ÖS3_18, ÖS3_24, ÖS3_25, ÖS3_26, ÖS3_27, ÖS3_30	0.63	0.001	0.40	0.55	0.005	0.30
	RF	ÖS3_5, ÖS3_25, ÖS3_27	0.56	0.001	0.31	0.59	0.001	0.35
ÖS4	MLR	ÖS4_4, ÖS4_6, ÖS4_7, ÖS4_10, ÖS4_12, ÖS4_14, ÖS4_17, ÖS4_18, ÖS4_22, ÖS4_23	0.57	0.001	0.32	0.79	0.001	0.62
	ANN	ÖS4_12, ÖS4_15, ÖS4_17, ÖS4_22, ÖS4_23	0.63	0.001	0.40	0.78	0.001	0.61
	SVM (PolyKernel)	ÖS4_6, ÖS4_13, ÖS4_15, ÖS4_17, ÖS4_18, ÖS4_22, ÖS4_23	0.60	0.001	0.36	0.80	0.001	0.64
	SVM (RBFKernel)	ÖS4_6, ÖS4_17, ÖS4_18, ÖS4_22, ÖS4_23	0.55	0.001	0.30	0.79	0.001	0.62
	kNN	ÖS4_7, ÖS4_8, ÖS4_14, ÖS4_17, ÖS4_18, ÖS4_19, ÖS4_20, ÖS4_21, ÖS4_22, ÖS4_23	0.68	0.001	0.46	0.80	0.001	0.64
	RF	ÖS4_7, ÖS4_9, ÖS4_17, ÖS4_22	0.64	0.001	0.41	0.75	0.001	0.56

Çizelge 7.18.b. ÖS_1-2,ÖS_1-3 ve ÖS_1-4'ün Sarmal Alt Küme Değerlendirme ile seçilen özelliklerinin farklı yöntemlerle kullanılması sonucunda ürettiği CPAP tahmin sonuçları

Özellik Seti	Sarmal Alt Küme-Yöntem	Seçilen Özellikler	Eğitim			Test		
			r	p<	r ²	r	p<	r ²
ÖS_1-2	MLR	ÖS1_3, ÖS2_5, ÖS2_8,ÖS2_18, ÖS2_21,ÖS2_22,ÖS2_24, ÖS2_27,ÖS2_29,ÖS2_30, ÖS2_34, ÖS2_38	0.71	0.001	0.50	0.85	0.001	0.72
	ANN	ÖS1_3, ÖS2_5, ÖS2_8,ÖS2_18, ÖS2_22,ÖS2_29,ÖS2_33, ÖS2_34, ÖS2_36,ÖS2_38	0.70	0.001	0.49	0.84	0.001	0.71
	SVM (PolyKernel)	ÖS1_1,ÖS1_3,ÖS2_5,ÖS2_6, ÖS2_7,ÖS2_8,ÖS2_13,ÖS2_18, ÖS2_22,ÖS2_23,ÖS2_27, ÖS2_29,ÖS2_34, ÖS2_38	0.76	0.001	0.58	0.86	0.001	0.74
	SVM (RBFKernel)	ÖS1_3,ÖS2_8,ÖS2_18,ÖS2_22, ÖS2_29,ÖS2_33,ÖS2_34, ÖS2_37	0.70	0.001	0.49	0.78	0.001	0.61
	kNN	ÖS2_2, ÖS2_3, ÖS2_8,ÖS2_10, ÖS2_17	0.69	0.001	0.48	0.65	0.001	0.42
	RF	ÖS1_1,ÖS2_9,S2_10,ÖS2_13, ÖS2_16, ÖS2_37	0.70	0.001	0.49	0.64	0.001	0.41
	ÖS_1-3	MLR	ÖS1_3,ÖS3_24, ÖS3_29, ÖS3_30, ÖS3_32	0.55	0.001	0.30	0.79	0.001
ANN		ÖS1_1,ÖS1_3,ÖS3_22,ÖS3_25, ÖS3_30, ÖS3_33	0.63	0.001	0.40	0.74	0.001	0.55
SVM (PolyKernel)		ÖS1_1, ÖS1_2, ÖS1_3,ÖS3_1, ÖS3_3, ÖS3_6,ÖS3_8, ÖS3_14, ÖS3_25	0.69	0.001	0.48	0.72	0.001	0.52
SVM (RBFKernel)		ÖS1_2,ÖS1_3,ÖS3_14,ÖS3_15, ÖS3_18,ÖS3_24,ÖS3_27, ÖS3_29, ÖS3_30,ÖS3_32	0.66	0.001	0.44	0.80	0.001	0.64
kNN		ÖS1_3, ÖS3_10, ÖS3_12, ÖS3_23, ÖS3_25	0.62	0.001	0.38	0.53	0.005	0.28
	RF	ÖS1_3, ÖS3_5, ÖS3_8,ÖS3_23, ÖS3_25, ÖS3_29	0.66	0.001	0.44	0.80	0.001	0.64
ÖS_1-4	MLR	ÖS1_3,ÖS4_2,ÖS4_18,ÖS4_19, ÖS4_20, ÖS4_22,ÖS4_23	0.64	0.001	0.41	0.80	0.001	0.64
	ANN	ÖS1_3,ÖS4_8,ÖS4_14,ÖS4_19, ÖS4_20, ÖS4_22,ÖS4_23	0.81	0.001	0.66	0.75	0.001	0.56
	SVM (PolyKernel)	ÖS1_1,ÖS1_3,ÖS4_19,ÖS4_20, ÖS4_22, ÖS4_23	0.84	0.001	0.71	0.81	0.001	0.66
	SVM (RBFKernel)	ÖS1_1,ÖS1_3,ÖS4_18,ÖS4_19, ÖS4_22, ÖS4_23	0.66	0.001	0.44	0.81	0.001	0.66
	kNN	ÖS1_3, ÖS4_4, ÖS4_6,ÖS4_7, ÖS4_10,ÖS4_12,ÖS4_17, ÖS4_18,ÖS4_19,ÖS4_22, ÖS4_23	0.77	0.001	0.59	0.75	0.001	0.56
RF	ÖS1_1,ÖS1_2,ÖS4_6,ÖS4_7, ÖS4_9,ÖS4_17,ÖS4_22, ÖS4_23	0.67	0.001	0.45	0.71	0.001	0.50	

Çizelge 7.18.c. ÖS_2-3,ÖS_2-3-4 ve ÖS_1-2-3-4'ün Sarmal Alt Küme Değerlendirme ile seçilen özelliklerinin farklı yöntemlerle kullanılması sonucunda ürettiği CPAP tahmin sonuçları

Özellik Seti	Sarmal Alt Küme-Yöntem Seçilen Özellikler	Eğitim			Test			
		r	p<	r ²	r	p<	r ²	
ÖS_2-3	MLR	ÖS2_4,ÖS2_8,ÖS2_22,ÖS2_27, ÖS2_30,ÖS2_38,ÖS3_6, ÖS3_18, ÖS3_27,ÖS3_32	0.64	0.001	0.41	0.70	0.001	0.49
	ANN	ÖS2_2,ÖS2_8,ÖS2_16,ÖS2_25, ÖS2_33, ÖS3_14,ÖS3_24	0.73	0.001	0.53	0.71	0.001	0.50
	SVM (PolyKernel)	ÖS2_4,ÖS2_8,ÖS2_14,ÖS2_18, ÖS2_24,ÖS2_29,ÖS2_34, ÖS3_6, ÖS3_15,ÖS3_26	0.75	0.001	0.56	0.66	0.001	0.44
	SVM (RBFKernel)	ÖS2_2,ÖS2_4,ÖS2_5,ÖS2_8, ÖS2_26,ÖS3_18, ÖS3_25	0.72	0.001	0.52	0.68	0.001	0.46
	kNN	ÖS2_2,ÖS2_8,ÖS2_13,ÖS2_15, ÖS2_27,ÖS3_14,ÖS3_18, ÖS3_25	0.76	0.001	0.58	0.74	0.001	0.55
	RF	ÖS2_9,ÖS2_10, ÖS2_13,ÖS3_24, ÖS3_32	0.74	0.001	0.55	0.81	0.001	0.66
ÖS_2-3-4	MLR	ÖS2_4, ÖS2_8, ÖS2_18,ÖS3_1, ÖS3_11,ÖS3_26,ÖS3_37, ÖS4_1,ÖS4_2,ÖS4_18, ÖS4_22	0.79	0.001	0.62	0.74	0.001	0.55
	ANN	ÖS2_4,ÖS2_8,ÖS2_14,ÖS2_19, ÖS2_24,ÖS2_27,ÖS3_18, ÖS3_26, ÖS4_3,ÖS4_4, ÖS4_7, ÖS4_17,ÖS4_22	0.80	0.001	0.64	0.80	0.001	0.80
	SVM (PolyKernel)	ÖS2_31,ÖS2_38,ÖS3_6,ÖS3_9, ÖS3_14,ÖS3_25,ÖS4_1,ÖS4_19, ÖS4_22,ÖS4_23	0.85	0.001	0.72	0.87	0.001	0.76
	SVM (RBFKernel)	ÖS2_4, ÖS2_8, ÖS2_14,ÖS2_18, ÖS3_18,ÖS3_24,ÖS3_25, ÖS4_1, ÖS4_3,ÖS4_16, ÖS4_22, ÖS4_23	0.73	0.001	0.53	0.72	0.01	0.52
	kNN	ÖS2_2, ÖS2_4, ÖS2_13,ÖS2_17, ÖS2_28,ÖS2_39,ÖS3_24,ÖS3_25, ÖS4_10,ÖS4_18,ÖS4_22, ÖS4_23	0.79	0.001	0.62	0.72	0.01	0.52
	RF	ÖS2_13,ÖS2_17,ÖS2_18,ÖS3_24, ÖS4_7, ÖS4_17,ÖS4_22, ÖS4_23	0.74	0.001	0.55	0.80	0.001	0.64
ÖS_1-2-3-4	MLR	ÖS1_3,ÖS2_4,ÖS2_5,ÖS2_8, ÖS2_19,ÖS2_20,ÖS2_27,ÖS2_34, ÖS3_6,ÖS3_26,ÖS4_2,ÖS4_3, ÖS4_17,ÖS4_18,ÖS4_19,ÖS4_22	0.77	0.001	0.59	0.85	0.001	0.72
	ANN	ÖS2_4, ÖS2_8, ÖS2_18,ÖS3_26, ÖS4_4, ÖS4_7,ÖS4_8, ÖS4_10, ÖS4_22	0.75	0.001	0.56	0.80	0.001	0.64
	SVM (PolyKernel)	ÖS1_3,ÖS2_14, ÖS2_26,ÖS2_38, ÖS3_3, ÖS3_6, ÖS4_2, ÖS4_19, ÖS4_22,ÖS4_23	0.83	0.001	0.69	0.89	0.001	0.79
	SVM (RBFKernel)	ÖS1_3, ÖS2_5, ÖS2_8,ÖS2_13, ÖS2_34, ÖS2_36,ÖS3_31, ÖS4_2, ÖS4_8,ÖS4_18, ÖS4_19, ÖS4_22, ÖS4_23	0.73	0.001	0.53	0.84	0.001	0.71
	kNN	ÖS1_1, ÖS2_13, ÖS2_26,ÖS3_32, ÖS4_16, ÖS4_22,ÖS4_23	0.76	0.001	0.58	0.78	0.001	0.61
	RF	ÖS2_2, ÖS2_13, ÖS2_24,ÖS2_28, ÖS3_18, ÖS3_24,ÖS3_25, ÖS4_7, ÖS4_11,ÖS4_22, ÖS4_23	0.74	0.001	0.55	0.79	0.001	0.62

Çizelge 7.18.a, 7.18.b ve 7.18.c’de görülen özellik setlerinin maksimum performanslarını üreten özellikler ve yöntemler kullanılarak CPAP tahmin modelleri geliştirilmiştir.

Model-31: Sarmal Alt Küme Değerlendirme yöntemi ANN ve PolyKernel fonksiyonlu SVM yöntemleri ile birlikte kullanıldığında, ÖS1 için 1 etkin özellik seçilmiş ve en yüksek test performansları üretilmiştir. İki yöntem de eşit test performansı sağlamasına rağmen PolyKernel fonksiyonlu SVM yöntemi daha yüksek eğitim performansı üretmiştir. Bu nedenle, Model-31, seçilen etkin özellik ve PolyKernel fonksiyonlu SVM yöntemi ile geliştirilmiştir. Bu model ile eğitim r değeri 0.53, r^2 değeri 0.28 ve test r değeri 0.69, r^2 değeri 0.48 olarak elde edilmiştir. Eğitim ve test p değerleri de 0.001’den küçük bulunarak istatistiksel anlamlılığı ifade etmiştir. Model-31 ile gerçekleştirilen tahmin sonucunda, hastaların %86.25’inin tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. Yalnızca 1 parametre ile Model-31 aynı özellik setinden türetilmiş 3’er parametrelilik Model-1 ve Model-11’e göre eğitim bakımından yüksek, test performansı bakımından daha az parametre ile eşit performans göstermiştir. Ayrıca Model-31 aynı özellik setinden geliştirilen 2 parametrelilik Model-21’e göre de aynı şekilde eğitim performansı bakımından yüksek, test performansı bakımından daha az parametre ile eşit performans göstermiştir.

Model-32: Sarmal Alt Küme Değerlendirme yöntemi ANN ve PolyKernel fonksiyonlu SVM yöntemleri ile birlikte kullanıldığında ÖS2’ye ait 9’ar etkin özellik seçilmiş ve en yüksek performanslar üretilmiştir. İki yöntemle de eşit test performansı elde edilmesine rağmen PolyKernel fonksiyonlu SVM yöntemi ile daha yüksek eğitim performansı üretilmiştir. Böylelikle Model-32, ÖS2’nin seçilen 9 etkin özelliği ve PolyKernel fonksiyonlu SVM yöntemi ile geliştirilmiştir. Bu model ile eğitimde r ve r^2 değerleri sırasıyla 0.73 ve 0.53 olarak, testte r ve r^2 değerleri sırasıyla 0.69 ve 0.48 olarak hesaplanmıştır. Hem eğitimde hem de testte p değerleri de 0.001’den küçük bulunarak istatistiksel anlamlılığı ifade etmiştir. Model-32 ile hastaların %87.50’sinin CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olacak şekilde tahmin edilmiştir. 9 tahmin parametrelilik Model-32, aynı özellik setinden oluşturulmuş 39 parametrelilik Model-2, 3 parametrelilik Model-12 ve 3 parametrelilik Model-22’ye göre daha yüksek performans ortaya koymuştur.

Model-33: Sarmal Alt Küme Değerlendirme yöntemi PolyKernel fonksiyonlu SVM yöntemi ile birlikte kullanıldığında ÖS3’e ait 6 etkin özellik seçilmiş ve ÖS3 için

en yüksek test performansı sağlanmıştır. Böylelikle Model-33, seçilen 6 etkin özellik ve PolyKernel fonksiyonlu SVM yöntemi ile oluşturulmuştur. Bu model eğitimde r değerini 0.52, r^2 değerini 0.27 olarak ve testte r değerini 0.71, r^2 değerini 0.50 olarak hesaplamıştır. Model ayrıca hem eğitimde hem de testte p değerlerini de 0.001'den küçük olarak hesap etmiştir. Model-33 ile hastaların %88.75'inin CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olacak şekilde tahmin edilmiştir. 6 tahmin parametrelili Model-33, aynı ÖS3'ten elde edilmiş 37 parametrelili Model-3, 1 parametrelili Model-13 ve 5 parametrelili Model-23'e göre daha yüksek performans ortaya koymuştur.

Model-34: Sarmal Alt Küme Değerlendirme yöntemi PolyKernel fonksiyonlu SVM ve kNN yöntemleri ile birlikte kullanıldığında ÖS4 için en yüksek test performansları sağlanmıştır. kNN yöntemi SVM'ye göre daha yüksek eğitim performansı sağladığı için Model-34, seçilen 10 etkin özellik ve kNN yöntemi ile geliştirilmiştir. Bu model eğitim r değerini 0.68, r^2 değerini 0.46 olarak, test r değerini 0.80, r^2 değerini 0.64 olarak, eğitim ve test p değerlerini de 0.001'den küçük olarak hesaplamıştır. Model-34 ile hastaların %90'ında tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. 10 özelliği tahmin parametresi olarak kullanan Model-34, ÖS4'ten üretilmiş 25 parametrelili Model-4, 3 parametrelili Model-14 ve 6 parametrelili Model-24'e göre daha yüksek performans ortaya koymuştur.

Model-35: Sarmal Alt Küme Değerlendirme yöntemi PolyKernel fonksiyonlu SVM yöntemi ile birlikte kullanıldığında ÖS_1-2'ye ait 14 etkin özellik seçilmiş ve ÖS_1-2 için en yüksek performans üretilmiştir. Böylelikle seçilen 14 etkin özellik ve PolyKernel fonksiyonlu SVM yöntemi ile Model-35 oluşturulmuştur. Bu model ile eğitim r değeri 0.76 ve r^2 değeri 0.58 olarak, test r değeri 0.86 ve r^2 değeri 0.74 olarak elde edilmiştir. p değerleri ise 0.001'den küçük olarak hesaplamıştır. Model-35 ile hastaların %93.75'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. 14 tahmin parametrelili Model-35, aynı özellik setinden üretilmiş 42 parametrelili Model-5, 3 parametrelili Model-15 ve 4 parametrelili Model-25'e göre daha yüksek performans ortaya koymuştur.

Model-36: Sarmal Alt Küme Değerlendirme yöntemi RBFKernel fonksiyonlu SVM yöntemi ve RF yöntemi ile birlikte kullanıldığında ÖS_1-3'e ait sırasıyla 10 ve 6 etkin özellik seçilmiş ve ÖS_1-3 için en yüksek test performansları üretilmiştir. Her iki yöntem de eğitim ve test için aynı sonuçları üretmesine rağmen, Sarmal Alt Küme

Değerlendirme yöntemi RF ile kullanıldığında 6 yani daha az özellik seçildiği için Model-36, 6 etkin özellik ve RF yöntemi ile oluşturulmuştur. Model-36 ile eğitim r değeri 0.66, r^2 değeri 0.44 olarak ve test r değeri 0.80, r^2 değeri 0.64 olarak elde edilmiştir. Hem eğitim hem de test için p değerleri 0.001'den küçük olarak hesaplanmıştır. Model-36 ile hastaların %86.25'inde tahmin edilen CPAP seviyeleri, referans optimum seviyelerin ± 3 cmH₂O aralığında olmuştur. 6 özelliğin tahmin parametresi olduğu Model-36, ÖS_1-3'ten oluşturulan 40 parametrelili Model-6 ve 3 parametrelili Model-16'ya göre daha yüksek performans ortaya koymuştur. Model-36, 15 parametrelili Model-26'ya göre ise eğitim performansı bakımından düşük, test performansı bakımından oldukça yüksek performans sağlamıştır.

Model-37: Sarmal Alt Küme Değerlendirme yöntemi PolyKernel ve RBF fonksiyonlu SVM yöntemleri ile birlikte kullanıldığında ÖS_1-4'e ait 6'şar etkin özellik seçilmiş ve ÖS_1-4 için en yüksek test performansları üretilmiştir. Her iki fonksiyona sahip SVM yöntemi eşit test performansı üretse de, PolyKernel fonksiyonlu SVM daha yüksek eğitim performansı sağlamıştır. Bu nedenle Model-37 ÖS_1-4'e ait 6 etkin özellik ve PolyKernel fonksiyonlu SVM yöntemi ile geliştirilmiştir. Model-37 ile eğitim r değeri 0.84, r^2 değeri 0.71, test r değeri 0.81, r^2 değeri 0.66 olarak elde edilmiştir. p değerleri 0.001'den küçük bulunmuştur. Model-37 ile hastaların %91.25'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. 6 özelliğin tahmin parametresi olduğu Model-37, ÖS_1-4'ten oluşturulan 28 parametrelili Model-7'den ve 6 parametrelili Model-27'den daha yüksek performans üretmiştir. Model-37, aynı özellik setinden geliştirilmiş 4 özelliği parametre olarak kullanan Model-17 ile kıyaslandığında ise Model-37 eğitim performansı bakımından daha yüksek, test performansı bakımından daha düşük performans sağlamıştır.

Model-38: Sarmal Alt Küme Değerlendirme yöntemi RF algoritması ile birlikte kullanıldığında ÖS_2-3'e ait 5 etkin özellik seçilmiş ve ÖS_2-3 için en yüksek test performansı sağlanmıştır. Böylelikle Model-38, ÖS_2-3'e ait 5 etkin özellik ve RF algoritması ile geliştirilmiştir. Model-38 ile eğitim r değeri 0.74, r^2 değeri 0.50 olarak bulunurken, test r değeri 0.81, r^2 değeri 0.66 olarak elde edilmiştir. Hem eğitim hem test için p değerleri 0.001'den küçük olarak hesaplanmıştır. Model-38 ile hastaların %91.25'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. 5 özelliğin tahmin parametresi olduğu Model-38, ÖS_2-3'e ait daha önce oluşturulmuş 76 parametrelili Model-8, 2 parametrelili Model-18 ve 4 parametrelili Model-28'den daha yüksek performans elde etmiştir.

Model-39: Sarmal Alt Küme Değerlendirme yöntemi PolyKernel fonksiyonlu SVM yöntemi ile birlikte kullanıldığında ÖS_2-3-4'e ait 10 etkin özellik seçilmiş ve en yüksek performans üretilmiştir. Bu nedenle, Model-39, ÖS_2-3-4'e ait 10 etkin özellik ve PolyKernel fonksiyonlu SVM yöntemi ile geliştirilmiştir. Model-39 ile eğitim r değeri 0.85, r^2 değeri 0.72, test r değeri 0.87, r^2 değeri 0.76, eğitim ve test p değerleri de 0.001'den küçük olarak bulunmuştur. Model-39 ile hastaların %95'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. 10 özelliğin tahmin parametresi olarak kullanıldığı Model-39, ÖS_2-3-4'ten daha önce oluşturulan 101 parametrelili Model-9, 7 parametrelili Model-19 ve 5 parametrelili Model-29'dan daha yüksek performans sağlamıştır.

Model-40: Sarmal Alt Küme Değerlendirme yöntemi PolyKernel fonksiyonlu SVM yöntemi ile birlikte kullanıldığında, ÖS_1-2-3-4'e ait 10 etkin özellik seçilmiş ve bu set için en yüksek performans üretilmiştir. Böylece Model 40, ÖS_1-2-3-4'e ait 10 etkin özellik ve PolyKernel fonksiyonlu SVM yöntemi ile oluşturulmuştur. Model-40 kullanılarak eğitim r değeri 0.83, r^2 değeri 0.69, test r değeri 0.89, r^2 değeri 0.79 olarak elde edilmiştir. Hem eğitimde hem testte p değerleri 0.001'den küçük olarak bulunmuştur. Model-40 ile gerçekleştirilen tahminlerde, hastaların %92.5'inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. 10 özelliğin tahmin parametresi olarak kullanıldığı Model-40, ÖS_1-2-3-4'ten daha önce oluşturulan 104 parametrelili Model-10, 6 parametrelili Model-20 ve 6 parametrelili Model-30'a göre daha yüksek performans sağlamıştır.

Model-31,...,Model-40'ın oluşturulmasında kullanılan öğrenme parametreleri Çizelge 7.19'da gösterilmiştir.

Çizelge 7.19 Model-31,..., Model-40 için öğrenme parametreleri

Model	Yöntem	Parametreler
Model-31	SVM	Fonksiyon: PolyKernel, c=0.7
Model-32	SVM	Fonksiyon: PolyKernel, c=1
Model-33	SVM	Fonksiyon: PolyKernel, c=0.8
Model-34	kNN	k=4
Model-35	SVM	Fonksiyon: PolyKernel, c=0.7
Model-36	RF	Ağaç sayısı:22
Model-37	SVM	Fonksiyon: 2. Dereceden PolyKernel, c=14.2
Model-38	RF	Ağaç sayısı:100
Model-39	SVM	Fonksiyon: 2. Dereceden PolyKernel, c=4.9
Model-40	SVM	Fonksiyon: 2. Dereceden PolyKernel, c=1.2


* c: ceza parametresi

Çizelge 7.20, tüm işlemlerin sonucunda tez çalışması kapsamında geliştirilen 40 adet CPAP tahmin modelini ve bu modellerle gerçekleştirilen optimum CPAP seviyelerinin tahmin sonuçlarını özetlemektedir.


Çizelge 7.20 Tez çalışmasında geliştirilen tahmin modelleri ve CPAP seviyelerini tahmin sonuçları

Model	Özellik Seti ve Sayısı	Yöntem	Eğitim			Test			±3 Aralığı
			r	p	r ²	r	p	r ²	
Model-1	ÖS1, 3 özellik	ANN	0.41	0.005	0.17	0.69	0.001	0.48	%83.75
Model-2	ÖS2, 39 özellik	ANN	0.47	0.001	0.22	0.48	0.005	0.23	%43.75
Model-3	ÖS3, 37 özellik	SVM (RBF)	0.45	0.005	0.20	0.45	0.005	0.20	%82.5
Model-4	ÖS4, 25 özellik	SVM (RBF)	0.50	0.001	0.25	0.79	0.001	0.62	%80
Model-5	ÖS_1-2, 42 özellik	ANN	0.54	0.001	0.29	0.71	0.001	0.50	%81.25
Model-6	ÖS_1-3, 40 özellik	SVM (Poly)	0.59	0.001	0.35	0.64	0.001	0.41	%83.75
Model-7	ÖS_1-4, 28 özellik	SVM (RBF)	0.54	0.001	0.29	0.78	0.001	0.61	%86.25
Model-8	ÖS_2-3, 76 özellik	SVM (RBF)	0.40	0.05	0.16	0.63	0.001	0.40	%85
Model-9	ÖS_2-3-4, 101 özellik	SVM (Poly)	0.50	0.001	0.25	0.71	0.001	0.50	%81.25
Model-10	ÖS_1-2-3-4, 104 özellik	SVM (Poly)	0.52	0.001	0.27	0.73	0.001	0.53	%85
Model-11	ÖS1, 3 özellik	ANN	0.41	0.005	0.17	0.69	0.001	0.48	%83.75
Model-12	ÖS2, 3 özellik	SVM (Poly)	0.68	0.001	0.46	0.55	0.005	0.30	%83.75
Model-13	ÖS3, 1 özellik	SVM (RBF)	0.40	0.005	0.16	0.61	0.001	0.37	%85
Model-14	ÖS4, 3 özellik	kNN	0.63	0.001	0.40	0.79	0.001	0.62	%85
Model-15	ÖS_1-2, 3 özellik	S-MLR	0.70	0.001	0.49	0.71	0.001	0.50	%85
Model-16	ÖS_1-3, 3 özellik	SVM (Poly)	0.60	0.001	0.36	0.76	0.001	0.58	%83.75
Model-17	ÖS_1-4, 4 özellik	S-MLR	0.77	0.001	0.59	0.83	0.001	0.69	%90
Model-18	ÖS_2-3, 2 özellik	kNN	0.64	0.001	0.41	0.67	0.001	0.45	%88.75
Model-19	ÖS_2-3-4, 7 özellik	S-MLR	0.82	0.001	0.67	0.82	0.001	0.67	%90
Model-20	ÖS_1-2-3-4, 6 özellik	S-MLR	0.75	0.001	0.56	0.85	0.001	0.72	%91.25
Model-21	ÖS1, 2 özellik	SVM (Poly)	0.52	0.001	0.27	0.69	0.001	0.48	%83.75
Model-22	ÖS2, 3 özellik	kNN	0.72	0.001	0.52	0.64	0.001	0.41	%81.25
Model-23	ÖS3, 5 özellik	SVM (RBF)	0.46	0.001	0.21	0.56	0.005	0.31	%85
Model-24	ÖS4, 6 özellik	SVM (Poly)	0.56	0.001	0.31	0.64	0.001	0.41	%86.25
Model-25	ÖS_1-2, 4 özellik	SVM (RBF)	0.65	0.001	0.42	0.60	0.001	0.36	%90
Model-26	ÖS_1-3, 15 özellik	ANN	0.67	0.001	0.45	0.57	0.001	0.32	%78.75
Model-27	ÖS_1-4, 6 özellik	SVM (Poly)	0.58	0.001	0.34	0.65	0.001	0.42	%85
Model-28	ÖS_2-3, 4 özellik	SVM (Poly)	0.70	0.001	0.49	0.60	0.001	0.36	%87.5
Model-29	ÖS_2-3-4, 5 özellik	ANN	0.66	0.01	0.44	0.61	0.001	0.37	%85
Model-30	ÖS_1-2-3-4, 6 özellik	SVM (Poly)	0.74	0.001	0.55	0.76	0.001	0.58	%86.25
Model-31	ÖS1, 1 özellik	SVM (Poly)	0.53	0.001	0.28	0.69	0.001	0.48	%86.25
Model-32	ÖS2, 9 özellik	SVM (Poly)	0.73	0.001	0.53	0.69	0.001	0.48	%87.5
Model-33	ÖS3, 6 özellik	SVM (Poly)	0.52	0.001	0.27	0.71	0.001	0.50	%88.75
Model-34	ÖS4, 10 özellik	kNN	0.68	0.001	0.46	0.80	0.001	0.64	%90
Model-35	ÖS_1-2, 14 özellik	SVM (Poly)	0.76	0.001	0.58	0.86	0.001	0.74	%93.75
Model-36	ÖS_1-3, 6 özellik	RF	0.66	0.001	0.44	0.80	0.001	0.64	%86.25
Model-37	ÖS_1-4, 6 özellik	SVM (Poly)	0.84	0.001	0.71	0.81	0.001	0.66	%91.25
Model-38	ÖS_2-3, 5 özellik	RF	0.74	0.001	0.55	0.81	0.001	0.66	%91.25
Model-39	ÖS_2-3-4, 10 özellik	SVM (Poly)	0.85	0.001	0.72	0.87	0.001	0.76	%95
Model-40	ÖS_1-2-3-4, 10 özellik	SVM (Poly)	0.83	0.001	0.69	0.89	0.001	0.79	%92.5


Modellerin CPAP seviye tahminlerine ait test sonuç grafikleri Şekil 7.2 ve Şekil 7.3 gösterilmiştir. r katsayısının 0.8'e ve r^2 katsayısının 0.64'e eşit ve bu değerlerden daha büyük olduğu modeller Şekil 7.2 ve Şekil 7.3'de yeşil renk ile belirtilmiştir. Şekil 7.4 ise CPAP terapisi gerektiren tüm hastalar dikkate alındığında tahmin edilen seviyelerin referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olduğu hasta yüzdesini göstermektedir. Şekil 7.4'teki yeşil renk ± 3 cmH₂O aralığında %90 ve daha fazla hastaya denk CPAP seviye tahminlerini gerçekleştiren modelleri belirtmektedir.



Şekil 7.2. 40 adet CPAP tahmin modelinin test r katsayı sonuçlarına ait grafik



Şekil 7.3. 40 adet CPAP tahmin modelinin test r^2 katsayı sonuçlarına ait grafik



Şekil 7.4. 40 adet CPAP tahmin modelinin ± 3 cmH₂O aralığındaki tahmin yüzdesi grafiği

Çizelge 7.20’de görüldüğü gibi 40 adet CPAP tahmin modelinden 36 tanesi farklı yapay zeka teknikleri ile geliştirilmiş ve yalnızca 4 tanesi doğrusal regresyon analiz yöntemlerinden biri olan S-MLR analizi ile oluşturulmuştur. Çizelge 12, 14, 16, 18’deki sonuçlardan ve Çizelge 20’deki model sonuçlarından da anlaşılacağı üzere birçok yapay zeka yöntemi genellikle doğrusal regresyon analizlerinden üstün performans sağlamıştır. Farklı fonksiyonlara (PolyKernel, RBFKernel) sahip SVM yöntemi ise geliştirilen modellerden 24’ünü oluşturduğu için tahmin işleminde en başarılı yöntem olmuştur.

Çizelge 7.20’de gösterilen test ölçüt değerleri incelendiğinde, tahmin edilen CPAP seviyeleri ile referans optimum CPAP seviyeleri arasında yüksek ilişki ($0.6 \leq r < 0.8$) sağlayan 25 model ve çok yüksek ilişki ($r \geq 0.8$) ortaya koyan 10 model olduğu görülmektedir. Çizelge 7.20, Şekil 7.2 ve Şekil 7.3’de görüldüğü üzere çok yüksek ilişkinin elde edildiği modeller, Model-17, Model-19, Model-20, Model-34, Model-35, Model-36, Model-37, Model-38, Model-39 ve Model-40’dır. Bu modellerin 3 tanesi S-MLR analizi kullanılarak, 7 tanesi ise farklı yapay zeka yöntemleri kullanılarak geliştirilmiştir. Bu durumda çok yüksek ilişki ortaya koyan modellerde de yapay zeka yöntemlerinin, özellikle de 4 tahmin modelinin geliştirilmesini sağlayan SVM yönteminin üstünlük gösterdiği açıktır. Ayrıca çok yüksek ilişki sağlayan 10 modelin özelliklerinin belirlenme süreçleri göz önüne alınırsa söylenebilir ki; 10 modelin 7’sinde tahmin parametresi olarak kullanılan özellikler Sarmal Alt Küme Değerlendirme özellik seçim yöntemi ile belirlenmiştir. Yani bu yöntem özellik seçiminde üstün başarıya sahip olmuştur. 10 modelin geriye kalan 3’ünde ise parametre olarak kullanılan özellikler S-MLR analizi sırasında ortaya çıkmıştır. Korelasyon Tabanlı Alt Küme Değerlendirme yöntemiyle seçilen özelliklerin kullanılmasıyla tahmin edilen ve referans optimum CPAP seviyeleri arasında yüksek ilişkiler bulunabilse de, bu özellikler ile çok yüksek ilişkilerin bulunması sağlanamamıştır. Çizelge 7.20 ve Şekil 7.4 göstermektedir ki, çok yüksek ilişki ortaya koyan 10 modelin 9’unun gerçekleştirdiği tahmin ile hastaların en az %90’ında tahmin edilen CPAP seviyeleri referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. Şekil 7.4’e göre bu başarıyı sağlayan bir diğer model ise tahmin edilen ve referans optimum seviyeler arasında yüksek ilişki ortaya koyan Model-25 olmuştur.

Tahmin edilen ve uzmanlar tarafından belirlenen referans optimum CPAP seviyeleri arasında çok yüksek ilişki ortaya koyan 10 modelin detayları aşağıda verildiği gibidir:

Model-17; Kullanılan yöntem: S-MLR analizi

Tahmin parametresi olarak kullanılan özellikler :

ÖS1_3: BMI

ÖS4_19: Desaturasyon düşme eğimi

ÖS4_22: Hiperpne örüntülerinin sayısı

ÖS4_23: Apneik atak başlangıcı ile apneik atak sonucunda oluşan hiperpne örüntülerinin maksimum değeri arasındaki ortalama aç

Hastaların; %90'nında referans optimum seviyelerin ± 3 aralığında tahmin

%83.75'inde referans optimum seviyelerin ± 2 aralığında tahmin

%56.25'inde referans optimum seviyelerin ± 1 aralığında tahmin

Referans Optimum CPAP seviyelerinin ortalama değeri: 10.4

Tahmin edilen CPAP seviyelerinin ortalama değeri: 10.2

Model-19; Kullanılan yöntem: S-MLR analizi

Tahmin parametresi olarak kullanılan özellikler :

ÖS2_4: Hava akımı Ar-Parametre özelliği

ÖS2_8: Hava akımı mutlak ortanca değeri

ÖS3_26: Hava akımı CTM25 değeri

ÖS3_37: Oksimetri LZK değeri

ÖS4_2: Ortalama apneik atak süresi

ÖS4_18: Apneler arası ortalama süre

ÖS4_22: Hiperpne örüntülerinin sayısı

Hastaların; %90'nında referans optimum seviyelerin ± 3 aralığında tahmin

%77.5'inde referans optimum seviyelerin ± 2 aralığında tahmin

%63.75'inde referans optimum seviyelerin ± 1 aralığında tahmin

Referans Optimum CPAP seviyelerinin ortalama değeri: 10.4

Tahmin edilen CPAP seviyelerinin ortalama değeri: 10.3

Model-20; Kullanılan yöntem: S-MLR analizi

Tahmin parametresi olarak kullanılan özellikler :

ÖS1_3: BMI

ÖS2_8: Hava akımı mutlak ortanca değeri

ÖS2_18: Oksimetri baskın frekans

ÖS2_34: ODIS5

ÖS4_22: Hiperpne örüntülerinin sayısı

ÖS4_23: Apneik atak başlangıcı ile apneik atak sonucunda oluşan hiperpne örüntülerinin maksimum değeri arasındaki ortalama aç

Hastaların; %91.25'inde referans optimum seviyelerin ± 3 aralığında tahmin

%77.5'inde referans optimum seviyelerin ± 2 aralığında tahmin

%57.5'inde referans optimum seviyelerin ± 1 aralığında tahmin

Referans Optimum CPAP seviyelerinin ortalama değeri: 10.4

Tahmin edilen CPAP seviyelerinin ortalama değeri: 10.3

Model-34; Kullanılan yöntem: PolyKernel Fonksiyonlu SVM

Tahmin parametresi olarak kullanılan özellikler :

- ÖS4_4: Uyku boyunca hastanın apneik atakta kaldığı süre oranı
- ÖS4_6: Maksimum desaturasyon süresi
- ÖS4_7: Uyku boyunca hastanın desaturasyonda kaldığı süre oranı
- ÖS4_10: Uyku boyunca hastanın apneik atakta ve desaturasyonda kaldığı süre
- ÖS4_12: Desaturasyon başlangıcı ile desaturasyon süresince oksimetri'nin minimum olduğu değer arasındaki ortalama genlik
- ÖS4_14: Desaturasyon süresince oksimetrimin minimum olduğu değer ile desaturasyon bitişi arasındaki ortalama genlik
- ÖS4_17: Apneik atak bitişinden desaturasyon süresince oksimetri sinyal değerinin minimum olduğu ana kadar geçen ortalama süre
- ÖS4_18: Apneler arası ortalama süre
- ÖS4_22: Hiperpne örüntülerinin sayısı
- ÖS4_23: Apneik atak başlangıcı ile apneik atak sonucunda oluşan hiperpne örüntülerinin maksimum değeri arasındaki ortalama aç

*Hastaların; %91.25'inde referans optimum seviyelerin ± 3 aralığında tahmin
%77.5'inde referans optimum seviyelerin ± 2 aralığında tahmin
%57.5'inde referans optimum seviyelerin ± 1 aralığında tahmin*

Referans Optimum CPAP seviyelerinin ortalama değeri: 10.4

Tahmin edilen CPAP seviyelerinin ortalama değeri: 10

Model-35; Kullanılan yöntem: kNN

Tahmin parametresi olarak kullanılan özellikler :

- ÖS1_1: Yaş
- ÖS1_3: BMI
- ÖS2_5: Hava akımı mutlak minimum
- ÖS2_6: Hava akımı maksimum
- ÖS2_7: Hava akımı mutlak ortalama
- ÖS2_8: Hava akımı mutlak ortanca
- ÖS2_13: Hava akımı Hjorth parametreleri hareketlilik (mobility)
- ÖS2_18: Oksimetri baskın frekans
- ÖS2_22: Maksimum oksimetri değeri
- ÖS2_23: Ortalama oksimetri değeri
- ÖS2_27: Oksimetri sinyali basıklık değeri
- ÖS2_29: Oksimetri Hjorth parametreleri karmaşıklık(complexity)
- ÖS2_34: ODIS5
- ÖS2_38: 90 değerinin altında kalan saat başına oksimetri değerlerinin sayısı

*Hastaların; %93.75'inde referans optimum seviyelerin ± 3 aralığında tahmin
%83.75'inde referans optimum seviyelerin ± 2 aralığında tahmin
%57.5'inde referans optimum seviyelerin ± 1 aralığında tahmin*

Referans Optimum CPAP seviyelerinin ortalama değeri: 10.4

Tahmin edilen CPAP seviyelerinin ortalama değeri: 10.1

Model-36; Kullanılan yöntem: RF

Tahmin parametresi olarak kullanılan özellikler :

ÖS1_3: BMI

ÖS3_5: Hava akımı maksimum tekillik üsteli

ÖS3_8: Hava akımı çokfraktallı spektrumun maksimum değerine karşılık gelen tekillik üsteli

ÖS3_23: Hava akımı çokfraktallı spektrumdaki düşey mesafe

ÖS3_25: Hava akımı örnek entropi (H_ÖrEn)

ÖS3_29: Hava akımı CTM100 değeri (H_CT100)

Hastaların; %86.25'inde referans optimum seviyelerin ± 3 aralığında tahmin

%80'inde referans optimum seviyelerin ± 2 aralığında tahmin

%50'sinde referans optimum seviyelerin ± 1 aralığında tahmin

Referans Optimum CPAP seviyelerinin ortalama değeri: 10.4

Tahmin edilen CPAP seviyelerinin ortalama değeri: 10.5

Model-37; Kullanılan yöntem: PolyKernel Fonksiyonlu SVM

Tahmin parametresi olarak kullanılan özellikler :

ÖS1_1: Yaş

ÖS1_3: BMI

ÖS4_19: Desaturasyon düşme eğimi

ÖS4_20: Desaturasyon yükselme eğimi

ÖS4_22: Hiperpne örüntülerinin sayısı

ÖS4_23: Apneik atak başlangıcı ile apneik atak sonucunda oluşan hiperpne örüntülerinin maksimum değeri arasındaki ortalama aç

Hastaların; %91.25'inde referans optimum seviyelerin ± 3 aralığında tahmin

%81.25'inde referans optimum seviyelerin ± 2 aralığında tahmin

%61.25'inde referans optimum seviyelerin ± 1 aralığında tahmin

Referans Optimum CPAP seviyelerinin ortalama değeri: 10.4

Tahmin edilen CPAP seviyelerinin ortalama değeri: 10.38

Model-38; Kullanılan yöntem: RF

Tahmin parametresi olarak kullanılan özellikler :

ÖS2_9: Hava akımı standart sapma

ÖS2_10: Hava akımı varyans

ÖS2_13: Hava akımı Hjorth parametreleri hareketlilik (mobility)

ÖS3_24: Hava akımı yaklaşık entropi (H_YakEn)

ÖS3_32: Oksimetri örnek entropi (O_ÖrEn)

Hastaların; %91.25'inde referans optimum seviyelerin ± 3 aralığında tahmin

%77.5'inde referans optimum seviyelerin ± 2 aralığında tahmin

%53.75'inde referans optimum seviyelerin ± 1 aralığında tahmin

Referans Optimum CPAP seviyelerinin ortalama değeri: 10.4

Tahmin edilen CPAP seviyelerinin ortalama değeri: 10.3

Model-39; Kullanılan yöntem: PolyKernel Fonksiyonlu SVM

Tahmin parametresi olarak kullanılan özellikler :

ÖS2_31: ODIS2

ÖS2_38: 90 değerinin altında kalan saat başına oksimetri değerlerinin sayısı

ÖS3_6: Hava akımı minimum tekillik üsteli

ÖS3_9: Hava akımı çokfraktallı spektrum asimetrik indeks değeri

ÖS3_14: Hava akımı çokfraktallı spektrumun çarpıklık değeri

ÖS3_25: Hava akımı örnek entropi (H_ÖrEn)

ÖS4_1: AHI

ÖS4_19: Desaturasyon düşme eğimi

ÖS4_22: Hiperpne örüntülerinin sayısı

ÖS4_23: Apneik atak başlangıcı ile apneik atak sonucunda oluşan hiperpne örüntülerinin maksimum değeri arasındaki ortalama aç

Hastaların; %95'inde referans optimum seviyelerin ± 3 aralığında tahmin

%85'inde referans optimum seviyelerin ± 2 aralığında tahmin

%63.75'inde referans optimum seviyelerin ± 1 aralığında tahmin

Referans Optimum CPAP seviyelerinin ortalama değeri: 10.4

Tahmin edilen CPAP seviyelerinin ortalama değeri: 10.3

Model-40; Kullanılan yöntem: PolyKernel Fonksiyonlu SVM

Tahmin parametresi olarak kullanılan özellikler :

ÖS1_3: BMI

ÖS2_14: Hava akımı Hjorth parametreleri karmaşıklık(complexity)

ÖS2_26: Oksimetri sinyali çarpıklık değeri

ÖS2_38: 90 değerinin altında kalan saat başına oksimetri değerlerinin sayısı

ÖS3_3: Hava akımı minimum Hurst üstel değeri

ÖS3_6: Hava akımı minimum tekillik üsteli

ÖS4_2: Ortalama apneik atak süresi

ÖS4_19: Desaturasyon düşme eğimi

ÖS4_22: Hiperpne örüntülerinin sayısı

ÖS4_23: Apneik atak başlangıcı ile apneik atak sonucunda oluşan hiperpne örüntülerinin maksimum değeri arasındaki ortalama aç

Hastaların; %92.5'inde referans optimum seviyelerin ± 3 aralığında tahmin

%87.5'inde referans optimum seviyelerin ± 2 aralığında tahmin

%66.25'inde referans optimum seviyelerin ± 1 aralığında tahmin

Referans Optimum CPAP seviyelerinin ortalama değeri: 10.4

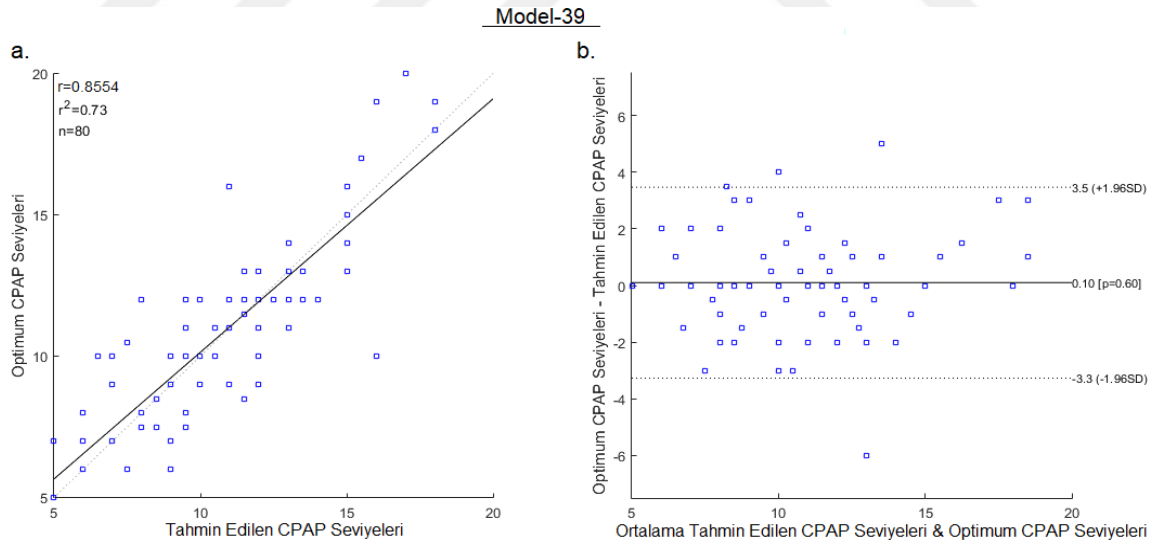
Tahmin edilen CPAP seviyelerinin ortalama değeri: 10.34

En iyi performans gösteren 10 model incelendiğinde parametre olarak en sık tercih edilen özelliklerin 7 modelde kullanılan apneik atak sonlarında oluşabilen **hiperpne örüntü sayıları**, 6 modelde kullanılan **atak başlangıçlarından hiperpne örüntülerinin maksimum değerlerine olan ortalama aç değeri** ve 6 modelde kullanılan **hastalara ait BMI değerleri** olduğu görülmüştür. Modellere göre ayrıca *hava*

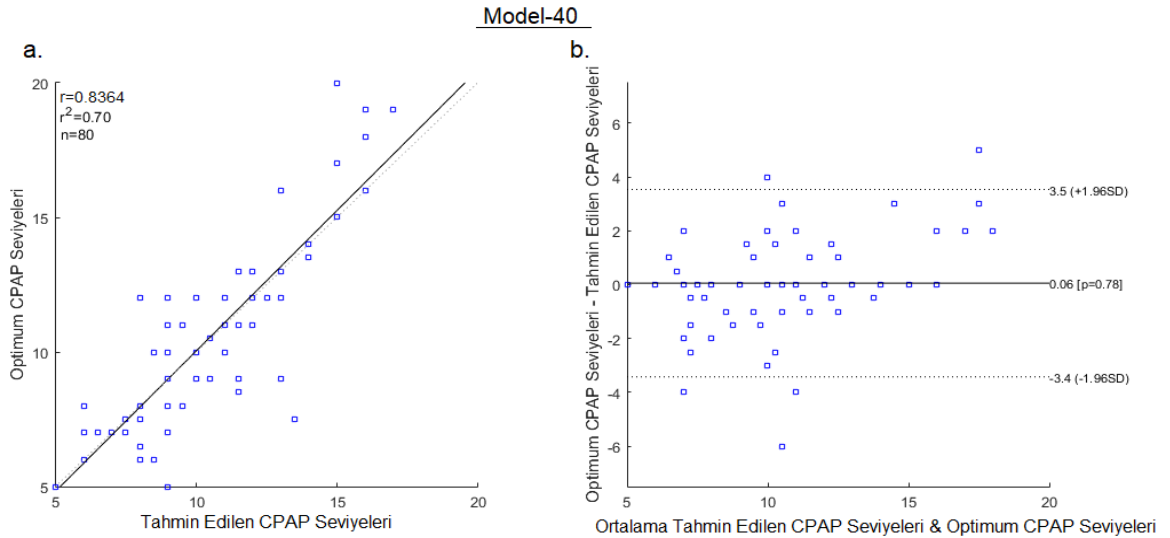
akımı mutlak ortanca değerlerinin, hava akımı CTM özelliklerinin, hava akımı Hjorth parametre değerlerinin, hava akımı minimum tekillik üstellerinin, hava akımı çokfraktallı spektrumun çeşitli özelliklerinin, hava akımı ve oksimetri entropi değerlerinin, desaturasyon düşme eğimlerinin, 90 değerinin altında kalan saat başına oksimetri sinyal değerlerinin sayısının, oksimetri baskın frekans değerlerinin, oksimetri bazal değerinin %5'inin altındaki saat başına oksimetri değerlerinin sayısının (ODIS5) da optimum CPAP seviyeleri üzerinde oldukça büyük etkiye sahip olduğu söylenebilmektedir.

Çizelge 7.20, Şekil 7.2, Şekil 7.3 ve Şekil 7.4'ten de anlaşılacağı üzere tez çalışması kapsamında optimum CPAP seviyelerinin tahmini için oluşturulan tüm modeller içerisinde en yüksek performansları Model-39 ve Model-40 sağlamıştır. Şekil 7.5 ve Şekil 7.6 sırasıyla 80 hastaya ait Model-39 ve Model-40 kullanılarak tahmin edilen CPAP seviyeleri ile referans olarak kullanılan uzmanların belirlediği optimum CPAP seviyeleri arasındaki dağılım ve Bland-Altman grafiklerini göstermektedir.

Şekil 7.5 ve Şekil 7.6'daki grafiklerde de tahmin edilen ve referans optimum CPAP seviyeleri arasındaki çok yüksek ilişki ve mutlak ortalama farklar açıkça gözlenmektedir.



Şekil 7.5. Model-39 ile 80 hastaya ait tahmin edilen ve referans optimum CPAP seviyeleri arasındaki **a.** dağılım grafiği, **b.** Bland-Altman grafiği



Şekil 7.6. Model-40 ile 80 hastaya ait tahmin edilen ve referans optimum CPAP seviyeleri arasındaki **a.** dağılım grafiği, **b.** Bland-Altman grafiği

Literatürde optimum CPAP seviyelerinin tahmini için farklı parametreleri kullanan birçok tahmin formülü geliştirilmiştir. Formüllerin çoğu, tahmin parametreleri olarak hastalara ait NC, BMI ve AHI değerlerini içermektedir. Bu durum göz önünde bulundurularak, çalışma kapsamında daha önce oluşturulan modeller ile gerçekleştirilen CPAP tahminleri haricinde, yalnızca literatürde sık kullanılan parametreler ile de 80 hastanın optimum CPAP seviyeleri tahmin edilmiştir. Ancak tez çalışmasına dahil edilen hastaların büyük bir kısmının NC ölçümleri eksiktir. Bu nedenle literatürde en sık kullanılan 2 parametre olan BMI ve AHI değerleri kullanılarak OSAS hastalarının optimum CPAP seviyeleri tahmin edilmiştir. Tahmin için yine MLR, ANN, PolyKernel fonksiyonlu SVM, RBFKernel fonksiyonlu SVM, kNN ve RF yöntemlerinden faydalanılmıştır. Ayrıca, BMI ve AHI değerlerini parametre olarak kullanan Choi ve ark. (2010) tarafından ve Lin ve ark. (2003) tarafından geliştirilen Denklem 7.5 ve Denklem 7.6'daki formüller ile de hastaların CPAP seviyeleri tahmin edilmiştir.

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 0.681 + (0.205 \times \text{BMI}) + (0.040 \times \text{AHI}) \quad (7.5)$$

$$\text{CPAP Seviyesi (cmH}_2\text{O)} = 0.52 + (0.174 \times \text{BMI}) + (0.042 \times \text{AHI}) \quad (7.6)$$

Çizelge 7.21, BMI ve AHI değerleri ile çalışmada MLR, ANN, SVM, kNN ve RF yöntemleri ile gerçekleştirilen eğitim ve test CPAP seviyelerinin tahmin sonuçlarını göstermektedir. Bu çizelge ayrıca Choi ve ark. (2010) ve Lin ve ark. (2003) tarafından önerilen formüller ile gerçekleştirilen CPAP seviyesi tahmin sonuçlarını da

içermektedir. Bu formüller de eğitim ve test için belirlenen hastalarda ayrı ayrı kullanılarak eğitim ve test CPAP seviyelerinin tahmin sonuçları elde edilmiştir.

Çizelge 7.21 BMI ve AHI özellikleri ile CPAP seviyelerinin tahmin sonuçları

Özellikler	Yöntem	Eğitim			Test		
		r	p <	r ²	r	p <	r ²
BMI ve AHI	MLR	0.45	0.005	0.20	0.72	0.001	0.52
	ANN (öo:0.01, m:0.8, İterasyon: 1100, Gizli katman nöron sayısı: 2)	0.59	0.001	0.35	0.75	0.001	0.56
	SVM (PolyKernel, c=0.4)	0.52	0.001	0.27	0.72	0.001	0.52
	SVM (RBFKernel, c=20)	0.52	0.001	0.27	0.72	0.001	0.53
	kNN (k=4)	0.50	0.001	0.25	0.65	0.001	0.42
	RF (Ağaç sayısı=100)	0.39	0.005	0.15	0.68	0.001	0.46
	Choi ve ark. (2010) formülü (Denklem 7.5)	0.53	0.001	0.28	0.70	0.001	0.49
	Lin ve ark. (2003) formülü (Denklem 7.6)	0.48	0.001	0.23	0.71	0.001	0.50

*öo: öğrenme oranı, m:momentum, c: ceza parametresi

Çizelge 7.21’de görüldüğü üzere literatürde en sık tercih edilen BMI ve AHI özelliklerinin parametre olarak kullanıldığı optimum CPAP seviye tahmininde en yüksek performans ANN yöntemi ile sağlanmıştır. Bu 2 özellik ve ANN yöntemi ile gerçekleştirilen tahminde eğitim r ve r² değerleri sırasıyla 0.59 ve 0.35 olarak, test için r ve r² değerleri sırasıyla 0.75 ve 0.56 olarak bulunmuştur. Bu tahmin sonucunda, hastaların %85’inde tahmin edilen CPAP seviyeleri referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur.

Çalışmadaki hastalara ait BMI ve AHI değerleri, Choi ve ark. (2010) ile Lin ve ark. (2003) tarafından geliştirilen formüllerle kullanıldığında ise ANN’e göre düşük performanslar elde edilmiştir. Choi ve ark. (2010)’nın ürettiği formül ile hastaların %78.75’inde, Lin ve ark. (2003)’nin geliştirdiği formül ile hastaların %75’inde tahmin edilen CPAP seviyeleri, referans optimum CPAP seviyelerinin ± 3 aralığında olmuştur.

Çalışmada daha önce geliştirilen 40 modelin eğitim ve test performansları yalnızca BMI ve AHI kullanılarak gerçekleştirilen en yüksek CPAP seviye tahmin performansı ile karşılaştırıldığında, 13 modelin (3 parametrelili *Model-14*, 3 parametrelili *Model-16*, 4 parametrelili *Model-17*, 7 parametrelili *Model-19*, 6 parametrelili *Model-20*, 6 parametrelili *Model-30*, 10 parametrelili *Model-34*, 14 parametrelili *Model-35*, 6 parametrelili *Model-36*, 6 parametrelili *Model-37*, 5 parametrelili *Model-38*, 10 parametrelili *Model-39*, 10 parametrelili *Model-40*) hem eğitimde hem de testte daha yüksek performans sağladığı görülmüştür. Bu modellerin 4’ü (*Model-14*, *Model-19*, *Model-34*, *Model-38*) parametre olarak BMI ve AHI değerlerini içermezken, 8 tanesi (*Model-16*, *Model-17*,

Model-20, Model-30, Model-35, Model-36, Model-37, Model-40) hava akımı ve oksimetri sinyali, apneik atak ve desaturasyon özellikleri ile birlikte BMI değerlerini de parametre olarak kullanmaktadır. Geri kalan 1 model (*Model-39*) ise sinyal, atak ve desaturasyon özellikleri ile birlikte AHI değerlerini de tahmin parametresi olarak kullanmaktadır.

Çizelge 7.22 farklı popülasyonlara ait OSAS hastalarının optimum CPAP seviyelerini belirlemek amacıyla gerçekleştirilen literatür çalışmalarını ve sonuçlarını özetlemektedir. Çizelge 7.22’de görüldüğü üzere günümüze kadar gerçekleştirilen çalışmaların çoğu benzer özellikleri, çoğunlukla da BMI, NC ve AHI değerlerini tahmin parametresi olarak tercih etmişlerdir. Bu çalışmalardan bazıları ODI, ortalama ve en düşük oksimetri değerleri gibi birkaç oksimetre indeks değerini parametre olarak kullanmıştır. Yaş ve cinsiyet gibi demografik bilgiler az sayıdaki çalışmada kullanılmıştır. Bir veya iki çalışmada, sefalometrik ve kraniyofasiyal özellikler gibi farklı tahmin parametrelerinden faydalanılmıştır. Bu parametreler gözlemlendiğinde, AHI ve oksimetri indeksleri dışında, BMI, NC gibi belirli parametrelerin her popülasyonda değişiklik gösterebileceği ve farklı ırklardaki tahminler için farklı katsayılar gerektireceği söylenebilmektedir. Ayrıca sefalometrik ve kraniyofasiyal özellikler gibi bazı parametreler, klinik ortamda ölçülmek için özel ekipman gerektirmektedir. Bu nedenle pratikte kullanımı oldukça zordur. Çizelge 7.22, hiçbir çalışmada hava akımı sinyallerinin herhangi bir özelliğinin kullanılmadığını ve oksimetri sinyalinin sadece birkaç özelliğinin bazı çalışmalarda kullanıldığını, farklı özelliklerinin değerlendirilmeye alınmadığını göstermektedir.

Çizelge 7.22’de yer alan çalışmalar incelendiğinde görülmektedir ki, çalışmaların beşinde araştırmacılar geliştirdikleri formüllerin sonucunda tahmin ettikleri CPAP seviyeleri ile uzmanların belirlediği referans optimum CPAP seviyeleri arasında yüksek ilişki ($0.6 \leq r < 0.8$) bulmuşlardır. Miljeteig ve Hoffstein (1993) ve El Solh ve ark. (2007) tarafından gerçekleştirilen iki çalışmada ise bu ilişkinin çok daha yüksek ($r \geq 0.8$) olduğu Çizelge 7.22’de görülmektedir. Ayrıca Çizelge 7.22’ye göre literatür çalışmalarının yalnızca 2 tanesi tahmin için ANN ve RF yapay zeka yöntemlerinden faydalanmış, diğerleri ise çoklu doğrusal regresyon analizini tercih etmişlerdir. Çizelge 7.22’deki sonuçlar gözlemlendiğinde, parametreler arasındaki doğrusal olmayan ilişkileri de inceleyen yapay zeka yöntemlerini kullanılan çalışmaların (El Solh ve ark., 2007; Kim ve Yang, 2018), doğrusal regresyonu tercih eden çalışmaların çoğuna göre daha yüksek performans sağladığı söylenebilmektedir.

Çizelge 7.22 Optimum CPAP seviyelerinin tahmini için gerçekleştirilen literatür çalışmaları

Araştırmacılar	Popülasyon	Kullanılan Parametreler	Yöntem	Performans Değerlendirmesi
El Solh ve ark. (2007)	ABD	Yaş, Cinsiyeti BMI, NC ve AHI	ANN	$r = 0.85, p < 0.001, r^2 = 0.72$ Hastaların % 92'si için tahmin edilen basınç, referans optimum basıncın ± 3 cmH ₂ O aralığında olmuştur.
Basoglu ve Tasbakan (2012)	Türk	NC and ODI	MLR	$r = 0.651, p < 0.001, r^2 = 0.423$ Hastaların % 96 'sı için tahmin edilen basınç, referans optimum basıncın ± 3 cmH ₂ O, %80'i için ± 2 cmH ₂ O aralıklarında olmuştur.
Schiza ve ark. (2011)	Yunan	Cinsiyet, AHI, BMI, Sigara içme geçmişi	MLR	Erkekler için: $r = 0.374, p < 0.0001, r^2 = 0.14$ Kadınlar için: $r = 0.369, p < 0.0001, r^2 = 0.136$
Choi ve ark. (2010)	Kore	BMI ve AHI	S-MLR	$r = 0.648, p < 0.001, r^2 = 0.42$
Akashiba ve ark. (2001)	Japonya	Ortalama oksimetri ve Sefalometrik değişkenler	S-MLR	$r = 0.758, r^2 = 0.575$
Miljeteig ve Hoffstein (1993)	Kafkas	BMI, NC ve AHI	MLR	$r = 0.87, r^2 = 0.76$
Lin ve ark. (2003)	Tayvan	BMI ve AHI	MLR	$r = 0.53, r^2 = 0.28$ Hastaların % 73'ü için tahmin edilen basınç, referans optimum basıncın ± 2 cmH ₂ O aralığında olmuştur.
Ebben ve ark. (2017)	ABD	AHI, minimum oksimetri ve NC	MLR	Oronazal maske kullananlar için: $r = 0.61, p < 0.001, r^2 = 0.37$ Nazal maske kullananlar için: $r = 0.35, p < 0.001, r^2 = 0.12$
Sadeghniaat-Haghighi (2018)	İran	BMI, NC, RDI, en düşük ve ortalama oksimetri değerleri	MLR	Yeni formül geliştirilmemiş daha önce farklı araştırmacılar tarafından oluşturulan 4 farklı formül İran halkı için kullanılmıştır. 4 formül arasında en yüksek elde edilen r değeri 0.30, r ² değeri 0.09 olmuştur.
Yong ve ark. (2018)	Malezya	Cinsiyet, ESS ve en düşük oksimetri değeri	MLR	Sınıf içi korelasyon katsayısı: 0.51 Formüllerin , 6 cmH ₂ O'nun altında ve 18 cmH ₂ O'nun üzerinde CPAP basıncına ihtiyaç duyan hastalar için kötü performans sergilediği belirtilmiştir.
Kim ve Yang (2018)	Kore	BMI, AHI, ODI ve Ortalama oksimetri	RF	$r = 0.78, r^2 = 0.6084$
Cunha ve ark. (2020)	Brezilya	Mandibular uzunluk, Atlas-çene mesafesi ve Mallampati sınıflandırması	MLR	Titrasyon işlemi ile üretilen basınçların ortalaması 8.6 cmH ₂ O, önerilen formül ile edinilen basınçların ortalaması 8.9 cmH ₂ O olarak belirtilmiş ve ortalama değerlerin birbirine oldukça yakın olduğu vurgulanmıştır. Herhangi bir korelasyon katsayısı belirtilmemiştir.
Chong ve ark. (2020)	Singapur	Yaş, BMI, bademcik/geniz eti ve durumu, down sendromu durumu	MLR	$r = 0.5603, p < 0.001, r^2 = 0.314$
Wahab ve Ahmed (2017)	Mısır	NC uzunluğunun boya oranı ve minimum oksimetri değeri	MLR	Herhangi istatistiksel ölçüt belirtilmemiştir. Tahmin formüllerinin CPAP ve APAP terapileri için bir alternatif olabileceği ifade edilmiştir.

Sonuç olarak, bu tez çalışmasında, farklı özellikler ve yöntemler kullanılarak CPAP tahmini için 40 farklı model tasarlanmıştır. Modellerin test başarıları dikkate alındığında bu modellerin 25'i, tahmin edilen CPAP seviyeleri ile uzmanlar tarafından belirlenen referans optimum CPAP seviyeleri arasında yüksek bir ilişki ortaya koymuştur ($0.6 \leq r < 0.8$). 10 model ise tahmin edilen ve referans optimum CPAP seviyeleri arasındaki ilişkileri çok yüksek ($r \geq 0.8$) olarak tanımlamıştır. Geliştirilen 40 modelin 10'u sayesinde hastaların en az %90'ı için gerçekleştirilen CPAP seviye tahminleri referans optimum CPAP seviyelerinin ± 3 cmH₂O aralığında olmuştur. Çalışma kapsamında en yüksek başarılar Model-39 ve Model-40 ile sağlanmıştır. Model-39, eğitim aşamasındaki tahmin edilen ve referans optimum CPAP seviyeleri arasındaki ilişkiyi tanımlayan r ve r^2 değerlerinin sırasıyla 0.85 ve 0.72, test aşamasındaki ilişkiyi belirten r ve r^2 değerlerinin sırasıyla 0.87 ve 0.76 olarak elde edilmesini sağlamıştır. Model-39, hastaların %95'i için tahmin edilen basınç seviyelerini referans optimum basınçların ± 3 cmH₂O aralığında bulurken, hastaların %85'i için referans basınç seviyelerinin ± 2 cmH₂O aralığında bulmuştur. Model-40 ile eğitim r değeri 0.83 ve r^2 değeri 0.69 olarak, test r değeri 0.89 ve r^2 değeri 0.79 olarak elde edilmiştir. Bu modelin icrası sonucunda hastaların %92.5'inde tahmin edilen basınçlar referans optimum seviyelerin ± 3 aralığında, %87.5'inde referans optimum seviyelerin ± 2 aralığında olmuştur. Her iki modelin performansı da Çizelge 7.22'de verilen literatür çalışmalarına göre daha yüksektir.

Günümüze kadar Türk popülasyonuna ait yalnızca bir çalışma Basoglu ve Tasbakan (2012) tarafından geliştirilmiş ve tahmin edilen ile referans optimum CPAP seviyeleri arasındaki ilişki 0.65 korelasyon (r) katsayı değeri ile belirtilmiştir. Gerçekleştirilen bu tez çalışması da Türk hastaları içermektedir ve tahmin için geliştirilen modellerin birçoğu Basoglu ve Tasbakan (2012) tarafından gerçekleştirilen çalışmaya göre r katsayısı bakımından daha yüksek başarı üretmiştir.

Bu tez çalışmasında, literatürdeki çalışmalarda göz önünde bulundurulmayan fakat OSAS tanı ve CPAP tedavi sürecinde uzmanlar için klinikte temel teşkil eden ve farklı popülasyonlar için değişikliğe uğramayacak hava akımı ve oksimetri polisomnografi sinyal özellikleri ile apneik atak ve desaturasyon özellikleri optimum CPAP seviyelerinin tahmini için incelemeye alınmıştır. Ayrıca bu tez çalışması kapsamındaki tahmin işlemleri literatürde sıklıkla kullanılan regresyon analizinin yanı sıra farklı yapay zeka yöntemleri kullanılarak da gerçekleştirilmiştir. Elde edilen sonuçlara göre söylenebilir ki; bu tez çalışmasında optimum CPAP seviyelerinin

tahmini için geliştirilen birçok model literatür çalışmalarında üretilen tahmin formüllerine göre üstün performans ortaya koymuştur.

8. SONUÇLAR VE ÖNERİLER

8.1. Sonuçlar

Bu tez çalışmasında ilk aşamada, çeşitli şikayetler ile Konya Necmettin Erbakan Üniversitesi, Meram Tıp Fakültesi, Göğüs Hastalıkları Anabilim Dalı, Uyku Kliniğine başvuran 145 kişinin OSAS hastası olup olmadığı ve CPAP terapisi ile gerçekleştirilen tedaviye ihtiyaç duyup duymadığı belirlenmiştir. Ardından, CPAP terapisi ile tedavi gerektiren hastalar için, CPAP cihazlarıyla hastaların üst solunum yollarına iletilecek olan tedavi edici optimum basınç seviyeleri tahmin edilerek CPAP tahmin modelleri geliştirilmiştir.

Çalışmada öncelikle uyku kliniğine başvuran hastaların uyku sırasındaki polisomnografi sinyalleri laboratuvarında gerçekleştirilen PSG tetkiki ile kaydedilmiştir. Ardından çalışmanın amacına uygun olarak, tüm polisomnografi kayıtları içerisinde 100 Hz örnekleme frekanslı nazal kanül hava akımı ve 1 Hz örnekleme frekanslı oksimetri sinyalleri değerlendirmeye alınmıştır. Hava akımı sinyalleri, üzerinde çalışılmak üzere band-geçiren filtreden geçirilerek adaptif bir şekilde normalize edilmiştir. Oksimetre sinyalleri ise gürültü olarak tanımlanan oksimetri sinyal değerlerinden arındırılmıştır.

Tez çalışmasında ilk olarak çalışmaya dahil edilen 145 kişinin OSAS hastası olup olmadığı ve standart tedavi yöntemi olan CPAP terapisi ile tedaviyi gerektirip gerektirmediği 2 farklı yaklaşım kullanılarak belirlenmiştir. Bu durumların belirlenmesi AHI alt grupları ile doğrudan ilişkilidir. Bu nedenle 2 yaklaşım da kişilerin AHI alt gruplarının tanımlanmasını içermektedir. Her 2 yaklaşımda da 145 kişinin rastgele ayrıştırılmış %60'ı eğitim için, %40'ı da test için değerlendirmeye alınmıştır. Birinci yaklaşım Doğrusal Olmayan Analiz Yaklaşımıdır. Bu yaklaşımda, uykudaki solunum bozukluklarının gece boyunca kaydedilen sinyalleri etkileyebileceği ve bu nedenle sinyallerin doğrusal olmayan dinamikler sergileyebileceği, varyasyonlara, ani piklere ve geçişlere sahip olabileceği göz önünde bulundurularak, MDFA yöntemi ile kişilerin hava akımı sinyallerine ait 23 doğrusal olmayan özellik çıkarılmıştır. Çıkarılan özellikler arasından AHI alt grupları üzerinde daha fazla etkiye sahip özellikler *Bilgi*

Kazancı Özellik Değerlendirme, Korelasyon Özellik Değerlendirme, OneR Özellik Değerlendirme, Korelasyon Tabanlı Alt Küme Değerlendirme ve Sarmal Alt Küme Değerlendirme özellik seçme yöntemleri ile belirlenmiştir. Sarmal Alt Küme Değerlendirme özellik seçme yönteminin seçtiği 6 özelliğin RF sınıflandırıcısı ile kullanılmasıyla, kişilerin 3 farklı AHI alt grubundan (AHI<5 (sağlıklı birey, tedavi gerektirmez), $5 \leq \text{AHI} < 15$ (OSAS hastası, CPAP tedavisi için ek bilgiler doğrultusunda uzman görüşüne ihtiyaç var), $15 \leq \text{AHI}$ (OSAS hastası ve CPAP tedavisi gerektirmekte)) birine dahil edilmesi sürecinde en yüksek başarıya ulaşılmıştır. MDFA yöntemi ile hava akımı sinyallerinden çıkarılan ve etkin olarak seçilen 6 özellik ve RF yöntemi ile farklı AHI alt gruplarının tanımlanmasında %87.36 eğitim sınıflandırma doğruluğu, 0.77 eğitim kappa değeri ve % 89.66 test sınıflandırma doğruluğu, 0.84 test kappa değeri elde edilmiştir. $15 \leq \text{AHI}$ alt grubu için %100 test duyarlılık, %81.25 test özgüllük ve %81.25 test kesinlik ölçütleri, $5 \leq \text{AHI} < 15$ alt grubu ve AHI<5 alt gruplarının her ikisi içinde %81.25 test duyarlılık, %100 test özgüllük ve %100 test kesinlik ölçütleri elde edilmiştir. Ayrıca 145 kişi içerisindeki OSAS hastaları, normal sağlıklı bireylerden %93.10 doğruluk, %96.43 duyarlılık, %81.82 özgüllük ve %94.73 kesinlik değerleri ile ayırt edilmiştir. Doğrusal Olmayan Analiz Yaklaşımı sonucunda 145 kişinin 86'sı için CPAP terapisi gerektiriyor sonucuna ulaşılmıştır. Uyku uzmanlarının görüşüne göre bu hastaların 77'si için bu sonuç doğru iken, 9'u için aslında gerekli olmayan bir tedavi yaklaşım tarafından gerekli görülmüştür. Ayrıca CPAP terapisi ile tedavi edilmesi gerekli olan 3 hasta için ise bu yaklaşım sonucunda "tedavi gerekmiyor" kararı yanlış verilmiştir. Yani bu yaklaşım ile tüm kişilerin CPAP terapi gerekliliğinin belirlenmesinde %91.72 doğruluk, %96.25 duyarlılık, %86.15 özgüllük ve %89.53 kesinlik sağlanmıştır. İkinci yaklaşım ise Kural Tabanlı Algoritma Yaklaşımıdır. Bu ikinci yaklaşımda uyku uzmanlarının laboratuvarlarda klasik olarak yaptığı gibi, kişilerin gece boyunca geçirdikleri apneik atak sayısına göre AHI hesabına dayanan OSAS teşhisi ve CPAP terapi tedavisinin gerekliliği belirlenmeye çalışılmıştır. Tez çalışmasına dahil edilen 145 kişiye ait filtrelenmiş ve normalize edilmiş hava akımı ve gürültülerinden arındırılmış oksimetri sinyalleri kullanılarak hastaların gece boyunca geçirmiş oldukları apneik ataklar, AASM (2012)'ye ve belirli kurallara dayalı olarak geliştirilen algoritma ile otomatik olarak tespit edilmiştir. Ayrıca algoritmada ataklara eşlik eden oksijen desaturasyonlarının varlığı araştırılmış ve oluşan desaturasyonlar belirlenmiştir. İkinci yaklaşım sonucunda, apneik atakların tespitinde eğitim duyarlılık

ölçütü %94.70, kesinlik ölçütü %98.99 ve test duyarlılık ölçütü %94.25, kesinlik ölçütü %99.08 olarak elde edilmiştir. Tespit edilen ataklara göre, tüm kişilerin uykudaki saati başına atak sayısı olarak AHI değerleri hesaplanmış ve bu değerlere göre 145 kişi 3 farklı AHI alt grubundan ($AHI < 5$, $5 \leq AHI < 15$, $15 \leq AHI$) birine dahil edilmiştir. Hesaplanan AHI değerleri ile klinikte uzmanlar tarafından belirlenen referans AHI değerleri arasında çok güçlü bir ilişki bulunmuştur ($r=0.99$, $r^2=0.99$, $p<0.0001$). Kişilerin 3 farklı AHI alt grubuna ayrıştırılmasında %96.55 doğruluğa ulaşılmıştır. Kişilerin OSAS hastası olup olmadıklarının saptanmasında %98.62 doğruluk, %98.21 duyarlılık, %100 özgüllük ve %100 kesinlik değerleri elde edilmiştir. Kliniğe göre belirlenen 33 sağlıklı birey ikinci yaklaşım tarafından da sağlıklı olarak bulunmuştur. Bu yaklaşım ile 112 OSAS hastasının 110'u OSAS hastası olarak doğru bulunmuşken, 2'si ise sağlıklı olarak yanlış değerlendirilmiştir. Klinikteki uzmanlar tarafından CPAP terapisi ile tedavisi gerekli görülen 80 hasta, bu yaklaşım ile de CPAP terapisi ile tedavi edilmesi gereklidir olarak değerlendirilmiştir. Böylelikle ikinci yaklaşım sayesinde CPAP terapisi ile tedavi gerekliliğinin belirlenmesinde %100 doğruluk, %100 duyarlılık, %100 özgüllük ve %100 kesinlik ölçütlerine ulaşılmıştır. Klinikte gerçekleştirilen prosedürlere bağlı olarak önerilen Kural Tabanlı Algoritma Yaklaşımında, Doğrusal Olmayan Analiz Yaklaşımına göre daha yüksek performans elde edilmiştir. Hem OSAS hastaları hem de CPAP terapisi ile tedavi gerektiren hastalar daha yüksek doğrulukla tanımlanmıştır. CPAP seviye tahminleri yapılacak olan hastalar, ikinci yaklaşım sonucunda "CPAP terapisi ile tedavi edilmesi gereklidir" olarak belirlenen 80 hasta olmuştur.

CPAP terapisi ile tedavi edilmesi gerekli olan hastaların belirlenmesinin ardından, bu hastalara ait optimum tedavi edici CPAP seviyelerinin tahmin edilmesi amacıyla doğrusal regresyon analizleri (SLR, MLR veya S-MLR) ve farklı yapay zeka yöntemleri (ANN, SVM, NB, kNN ve RF) ile CPAP tahmin modelleri geliştirilmiştir. Bu amaçla öncelikle 4 farklı özellik seti oluşturulmuştur. ÖS1, tedavi edici basınçları tahmin edilecek olan 80 hastaya ait demografik ve antropometrik özelliklerden olan yaş, cinsiyet ve BMI bilgilerini içermektedir. ÖS2, 80 hastanın hava akımı ve oksimetri sinyallerine ait güç spektrum ve istatistiksel özelliklerden oluşmaktadır. Bu özellik setinin 39 özelliği bulunmaktadır. ÖS3'ü oluşturan özellikler ise 80 hastanın hava akımı ve oksimetri sinyallerine ait doğrusal olmayan özelliklerdir. Bu özellik seti hava akımı sinyallerine ait MDFA yöntemi ile elde edilen özellikleri, hava akımı ve oksimetri sinyallerine ait entropi özelliklerini, CTM özelliklerini ve LZK özelliklerini

içermektedir. ÖS3'ün özellik sayısı 37'dir. ÖS4, CPAP terapisi ile tedavi edilmesi gereken 80 OSAS hastasının gece boyunca uyku sırasında geçirmiş oldukları ve tez çalışması kapsamında tespit edilen apneik ataklarına ve desaturasyonlarına ait 25 özellikten oluşmaktadır. 4 özellik seti tasarlandıktan sonra ÖS1 ve ÖS2 birleştirilerek *ÖS_1-2*, ÖS1 ve ÖS3 birleştirilerek *ÖS_1-3*, ÖS1 ve ÖS4 birleştirilerek *ÖS_1-4*, ÖS2 ve ÖS3 birleştirilerek *ÖS_2-3*, ÖS2, ÖS3 ve ÖS4 birleştirilerek *ÖS_2-3-4* ve tüm setler birleştirilerek *ÖS_1-2-3-4* oluşturulmuştur. Böylece toplamda 10 özellik seti elde edilmiştir. 80 hasta yaklaşık %60'ı eğitim ve %40'ı test olacak şekilde rastgele ayrıştırıldıktan sonra, hastaların optimum CPAP seviyelerinin tahmini için; elde edilen 10 özellik setindeki tüm özellikler, bu setlerden S-MLR analizine göre belirlenen özellikler, Korelasyon Alt Küme Değerlendirme yöntemi ve Sarmal Alt Küme Değerlendirme yöntemi ile seçilen özellikler sırasıyla tahmin parametresi olarak SLR MLR veya S-MLR analizi, ANN, PolyKernel fonksiyonlu SVM, RBFKernel fonksiyonlu SVM, kNN ve RF yöntemleri tarafından kullanılmıştır. Gerçekleştirilen tahmin işlemleri sonucunda, en yüksek performansları sağlayan özelliklerden ve yöntemlerden oluşan 40 adet CPAP tahmin modeli geliştirilmiştir. Geliştirilen 40 CPAP tahmin modelinin 36 tanesinin oluşumunda farklı yapay zeka teknikleri kullanılmış ve yalnızca 4 tanesinin oluşumunda doğrusal regresyon analiz yöntemlerinden biri olan S-MLR analizinden faydalanılmıştır. Farklı fonksiyonlara (PolyKernel, RBFKernel) sahip SVM yöntemi ise geliştirilen modellerden 24'ünü oluşturarak tahmin işleminde en başarılı yöntem olmuştur. Oluşturulan 40 modelin test sonuçlarına göre, tez çalışması kapsamında geliştirilen 25 model tahmin edilen CPAP seviyeleri ve uyku laboratuvarında uzmanlar tarafından titrasyon işlemiyle belirlenen referans optimum CPAP seviyeleri arasında yüksek ilişki ortaya koymuştur ($0.6 \leq r < 0.8$; $0.36 \leq r^2 < 0.64$). Test başarılarına göre 10 model ise tahmin edilen ve referans optimum CPAP seviyeleri arasındaki ilişkileri çok yüksek ($r \geq 0.8$; $r^2 \geq 0.64$) olarak tanımlamıştır. Bu 10 modelin 7 tanesi farklı yapay zeka yöntemleri, 3 tanesi de S-MLR analizi kullanılarak oluşturulmuştur. Böylelikle CPAP seviyeleri arasında çok yüksek ilişki ortaya koyan modellerde de yapay zeka yöntemlerinin üstünlük sağladığı açıkça görülmüştür. CPAP seviyeleri arasında çok yüksek ilişki ortaya koyan 10 modelde tahmin parametresi olarak en çok tercih edilen özellikler, 7 modelde kullanılan apneik atak sonlarında oluşabilen hiperpne örüntü sayıları, 6 modelde kullanılan atak başlangıçlarından hiperpne örüntülerinin maksimum değerlerine olan ortalama açı değerleri ve 6 modelde kullanılan hastalara ait BMI değerleri olmuştur. Ayrıca 10 modelin tahmin parametreleri

incelendiğinde görülmüştür ki, hava akımı mutlak ortanca değerleri, hava akımı CTM özellikleri, hava akımı Hjorth parametre değerleri, hava akımı minimum tekillik üsteli, hava akımı çokfraktallı spektrumun çeşitli özellikleri, hava akımı ve oksimetri entropi değerleri, desaturasyon düşme eğimleri, 90 değerinin altında kalan saat başına oksimetri sinyal değerlerinin sayısı, oksimetri baskın frekans değerleri, oksimetri bazal değerinin %5'inin altındaki saat başına oksimetri değerlerinin sayısı (ODIS5) da optimum CPAP seviyeleri üzerinde oldukça etkili olmuştur. Literatür çalışmalarına göre tahmin parametresi olarak en çok tercih edilen BMI ve AHI değerleri kullanılarak da MLR analizi ve yapay zeka yöntemleri ile 80 hastanın CPAP seviye tahminleri gerçekleştirilmiştir. Bu şekilde en yüksek tahmin performansı ANN yöntemi ile elde edilmiş ve bu performans 40 modelin eğitim ve test performansları ile karşılaştırılmıştır. Karşılaştırma sonunda, 40 modelin 13'ünün hem eğitim hem test performansı bakımından BMI ve AHI kullanılarak ANN ile gerçekleştirilen tahmine göre daha yüksek başarı sağladığı görülmüştür.

Gerçekleştirilen tez çalışması kapsamında oluşturulan CPAP tahmin modellerinin tahmin sonuçları değerlendirildiğinde, literatür çalışmalarına göre genellikle daha yüksek sonuçlar elde edildiği söylenebilmektedir.

Bu tez çalışması, polisomnografi nazal kanül hava akımı ve oksimetri sinyal özellikleri, apneik atak ve desaturasyon özellikleri ile OSAS hastalarının tedavi edici optimum CPAP seviyeleri arasındaki ilişkiyi inceleyen ve bu özellikleri tahmin için parametre olarak kullanan ilk çalışma olmuştur. Elde edilen sonuçlara göre bu tez çalışması, hava akımı ve oksimetri polisomnografi sinyallerinin ve OSAS hastalarının geçirmiş oldukları atak ve desaturasyon özelliklerinin optimum basınçlar üzerinde büyük etkileri olduğunu ortaya koymuştur. Bu özelliklerin optimum CPAP seviyelerinin tahmininde geliştirici, iyileştirici ve performans artırıcı etkiye sahip olduğunu göstermiştir. Tez çalışması geliştirilen yeni CPAP tahmin modellerini ve modellerde kullanılan yeni tahmin parametrelerini literatüre kazandırmıştır. Çalışma ayrıca, yapay zeka yöntemlerinin tahmin parametresi olarak kullanılan özellikler arasındaki doğrusal ve doğrusal olmayan ilişkileri daha iyi açıkladığını ve bu sayede optimum CPAP seviyelerinin tahmininde literatürde çoğunlukla tercih edilen doğrusal regresyon analizlerine göre genellikle daha başarılı sonuçlar ürettiğini göstermiştir.

Çalışmada önerilen yeni tahmin parametreleri ve yapay zeka yöntemleri kullanılarak geliştirilen modellerin 10'u sayesinde hastaların en az %90'ında tahmin edilen CPAP seviyeleri uzmanların belirlediği referans optimum CPAP seviyelerinin ± 3

cmH₂O aralığında olmuştur. Böylelikle tez çalışması amacına ulaşmıştır. Tez çalışmasında geliştirilen modellerin uyku laboratuvarlarında kullanılması ve en fazla ± 3 cmH₂O aralığında gerçekleştirilen basınç tahminleri ile, hem manuel titrasyonun sebep olduğu çoklu basınç değişiklikleri büyük oranda azaltılmış hem de tahmin edilen basınç seviyeleri ile başlatılan manuel titrasyon sürecinde gerekli olan optimum CPAP seviyelerine daha kısa sürede ulaşılmış olunacaktır. Böylelikle de optimum basıncın belirlenmesinde yetersiz zaman riski en aza indirgenecektir. Ayrıca daha kısa süren titrasyon süreci tanı ve tedavi için yarı gece (split-night) prosedürünün daha rahat uygulanmasını da mümkün kılacaktır. Tüm bu durumlar göz önüne alındığında söylenebilir ki, gerçekleştirilen tez çalışması sayesinde manuel titrasyon başarısının iyileştirilmesine ve süreden tasarruf sağlanmasına katkı sağlanmıştır.

8.2. Öneriler

OSAS kişilerin uykuda belirli sıklıkta solunumlarının durması sonucu ortaya çıkan bir solunum bozukluğu rahatsızlığıdır. Kişilere uyku laboratuvarlarında geçirdikleri bir gece sonucunda PSG tetkiki ile OSAS teşhisi konulmaktadır. CPAP terapisi, bu rahatsızlığın en bilinen, en etkili ve kesin tedavi yöntemidir. CPAP cihazları ile gerçekleştirilen tedavide, OSAS hastalarına devamlı olarak sabit bir hava basıncı uygulanmakta, böylelikle hastaların uyku boyunca üst solunum yollarının açık kalması sağlanarak solunum durmaları engellenmektedir. CPAP terapisi ile tedavide kullanılacak olan sabit hava basıncının seviyesi oldukça önemlidir. Yüksek seviyede basınç uykudaki üst hava yolu tıkanıklığını ortadan kaldırırsa da, hastada ağız ve burun kuruluğu gibi sıkıntılara neden olabilir ve hastalar tedaviyi yarıda bırakabilir. Basınç seviyesinin gerekli görülenden düşük olması ise, yetersiz tedavi ve istenmeyen maske kaçaklarına sebebiyet verebilir. Bu nedenlerden dolayı, CPAP terapisi ile tedavide uygulanacak basınç seviyesi, apneik ataklar, horlama, uyanayazma gibi tüm uyku düzensizliklerini ortadan kaldırmak için optimum düzeyde olmalıdır. OSAS teşhisi konulmuş hastalara uygulanacak tedavideki CPAP basınç seviyesi, kişilerin uyku laboratuvarlarında geçirdikleri ikinci bir gecede klasik manuel titrasyon yöntemi ile uyku uzmanları tarafından belirlenir. Ancak, titrasyon ile etkili basıncın belirlenmesi süreci çoklu basınç değişikliklerini beraberinde getirmektedir. Ayrıca, manuel titrasyon yoğun emek gerektiren, pahalı, zaman alıcı ve oldukça yorucu bir süreçtir. Dünyada ve ülkemizde uyku bozuklukları ile ilgili yeterli düzeyde çalışma yapabilecek laboratuvar

sayısı da oldukça sınırlıdır. Bu nedenle, kişilerin hem OSAS teşhisi hem de tedavi edici CPAP titrasyonu için 2 gecesini laboratuvarında geçirmesi uzun bekleme listelerine yol açar. Bu durum da OSAS sendromundan etkilenen diğer hastaların tanı ve tedavisini geciktirir. Tüm bunlara ek olarak, hastaların klinik ortamlara uyum sağlayamamaları uyku uyumayı güçleştirebilir ve titrasyon süresinin yetersiz olmasına yol açarak etkili tedavi edici basıncın doğru bir şekilde belirlenmesini engelleyebilir.

Gerçekleştirilen tez çalışması kapsamında, kliniklerde optimum CPAP seviyelerinin belirlenmesi amacıyla gerçekleştirilen klasik manuel titrasyon yöntemine alternatif çözümler getirilmiştir. Kişilerin OSAS teşhisinin konulabilmesi için uyku laboratuvarında geçirdikleri gece boyunca kaydedilen polisomnografi sinyalleri, kişilerin gece boyunca geçirmiş oldukları apneik atakları, oksijen desaturasyonları ve hastalara ait demografik ve antropometrik bilgileri kullanılarak CPAP Tahmin Modelleri geliştirilmiştir.

Çalışmada modellerin geliştirilebilmesi amacıyla polisomnografi sinyallerinden olan nazal kanul hava akımı ve oksimetri sinyallerinden çeşitli yöntemlerle, güç spektrum özellikleri, istatistiksel özellikler ve doğrusal olmayan özellikler çıkarılmıştır. Bu sinyaller aracılığı ile kişilerin gece boyunca geçirmiş oldukları apneik ataklar ve oksijen desaturasyonları tespit edilmiş ve tespit edilen atak ve desaturasyonlara ait de çeşitli özellikler elde edilmiştir. Elde edilen tüm özellikler ve çeşitli tekniklerle daha etkin olduğu belirlenen özellikler CPAP tahmini için tahmin parametresi olarak kullanılmış ve doğrusal regresyon analizleri, ANN, SVM, kNN ve RF yöntemleri ile 40 farklı CPAP tahmin modeli oluşturulmuştur. Modellerin elde edilen sonuçları, literatürde daha önce kullanılmamış olan ve bu tez çalışmasında çıkarılan özelliklerin, CPAP tahmininde etkili olduğunu ve bu özelliklerin CPAP seviyelerinin tahmini için doğrusal regresyon ve farklı yapay zeka yöntemleri ile birlikte kullanılabileceğini göstermiştir. Bu bağlamda, çalışmada kullanılan hava akımı ve oksimetri sinyalleri gibi farklı polisomnografi sinyallerinden de (EEG, EOG, EKG vs.) çeşitli özellikler çıkarılarak, farklı sinyallerin optimum CPAP seviyeleri üzerindeki etkileri incelenebilir ve sinyallere ait özelliklerin tahmin parametresi olarak kullanılıp kullanılamayacağı belirlenebilir. Tahmin modellerinin oluşturulmasında Sınıflandırma ve Regresyon Ağaçları (Classification and Regression Trees-CART), Adaptif Sinir Ağı Tabanlı Bulanık Sistemler (Adaptive Neural-Fuzzy Inference Systems-ANFIS) gibi daha farklı yapay zeka yöntemleri kullanılarak modellerin tahmin başarıları geliştirilmeye çalışılabilir. Ayrıca hastaların tüm gece polisomnografi kayıtları veya tüm gece

geçirdikleri atak ve desaturasyonları yerine gecenin belirli bir bölümündeki veya belirli bir uyku evresindeki daha kısa süreye sahip kayıtlara ait özellikler, daha az sayıda tespit edilen ataklara ve desaturasyonlara ait özellikler kullanılarak da CPAP tahmin modelleri geliştirilebilir. Böylelikle uzun süreye sahip gecenin tümü yerine gecenin belirli bir periyoduna ait özelliklerin optimum CPAP seviyelerini hangi oranda açıklayabileceği ve seviyeleri tahmin için yeterli olup olmayacağı belirlenebilir.

Tahmin modellerinin geliştirilmesinde faydalanılan hasta sayısının önemli ölçüde yüksek olması CPAP tahmin modellerinin güvenilirliğini artırır. Bu nedenle OSAS'tan muzdarip ve CPAP terapisi ile tedavi edilmeyi gerektiren daha fazla hastanın çalışmalara dahil edilerek CPAP tahmin modellerinin geliştirilmesi model başarısını artırabilir. Daha fazla sayıdaki hastalar üzerinde test edilmiş yüksek doğruluklu modeller sayesinde, uyku laboratuvarlarındaki tedavi edici optimum basıncı belirleme sürecindeki çoklu basınç değişiklikleri tamamen ortadan kaldırılabilir ve hatta uyku laboratuvarlarında teşhis ve tedavi için gerekli görülen 2 gecelik süre tek geceye indirilebilir. Böylelikle zaman, mekan ve maliyetten tasarruf sağlanabilir.

KAYNAKLAR

- AASM, 2012, American Academy of Sleep Medicine, The AASM Manual for the Scoring of Sleep and Associated Events, Version v2.0, <https://aasm.org/clinical-resources/scoring-manual/>: [18 January 2019].
- Acharya, U., Sankaranarayanan, M., Nayak, J., Xiang, C. ve Tamura, T., 2008, Automatic identification of cardiac health using modeling techniques: A comparative study, *Information Sciences*, 178 (23), 4571-4582.
- Akar, S. A., Kara, S., Agambayev, S. ve Bilgiç, V., 2015, Major depresyonlu hastaların EEG sinyallerinin kaotik özneliklerle incelenmesi. Tıp Teknolojileri Ulusal Kongresi. Muğla, Türkiye, IEEE: 14-17.
- Akashiba, T., Kosaka, N., Yamamoto, H., Ito, D., Saito, O. ve Horie, T., 2001, Optimal continuous positive airway pressure in patients with obstructive sleep apnoea: role of craniofacial structure, *Respir Med*, 95 (5), 393-397.
- Akdoğan, B. B., 2010, Obstrüktif uyku apne sendromunda (OUAS) kalp hızı değişkenliği ile hastalık şiddeti arasındaki ilişki ve OUAS'lı hastalarda kalp hız değişkenliğinin kvh riski açısından önemi, Tıpta Uzmanlık Tezi, *Ankara Üniversitesi Ankara*, 10-12.
- Akhter, S., Abeyratne, U. R. ve Swarnkar, V., 2016, Characterization of REM/NREM sleep using breath sounds in OSA, *Biomedical Signal Processing and Control*, 25, 130-142.
- Akkoc, B., Arslan, A. ve Kok, H., 2017, Automatic gender determination from 3D digital maxillary tooth plaster models based on the random forest algorithm and discrete cosine transform, *Comput Methods Programs Biomed*, 143, 59-65.
- Akkoç, S. ve Elitaş, C., 2010, Yapay sinir ağları ve doğrusal ayırma analizi ile kredi derecelendirme. 14. Ulusal Finans Sempozyumu. Selçuk Üniversitesi İktisadi ve İdari Bilimler Fakültesi, Konya.
- Altman, N. S., 1991, An Introduction to kernel and nearest neighbor nonparametric regression, *The American Statistician*, 46 (3), 175-185.
- Alvarez, D., Hornero, R., Abasolo, D., del Campo, F. ve Zamarron, C., 2006, Nonlinear characteristics of blood oxygen saturation from nocturnal oximetry for obstructive sleep apnoea detection, *Physiol Meas*, 27 (4), 399-412.
- Alvarez, D., Hornero, R., Marcos, J. V. ve del Campo, F., 2010, Multivariate analysis of blood oxygen saturation recordings in obstructive sleep apnea diagnosis, *Ieee Transactions on Biomedical Engineering*, 57 (12), 2816-2824.
- Andrew, L. C. J., Richard, A. F., June, M. F., Madeleine, G.-D., Kristyna, M. H., Thomas, D. H., Stephen, J., Gihan, A. K., Michael, L., Gerald, R., R. Bart, S., Wolfgang, S.-N. ve Aaron, S., 1997, An American sleep disorders association review: The indications for polysomnography and related procedures, *Sleep*, 20 (6), 423-487.
- Artan, R. B. ve Yazgan, E., 2008, SEEG verilerinden yüksek dereceli istatistikler ve izgeler kullanarak epileptik atak tespiti, *İTÜ Dergisi D : Mühendislik*, 7 (6), 103-111.
- Ayas, N. T., Patel, S. R., Malhotra, A., Schulzer, M., Malhotra, M., Jung, D., Fleetham, J. ve White, D. P., 2004, Auto-Titrating Versus Standard Continuous Positive Airway Pressure for the Treatment of Obstructive Sleep Apnea: Results of a Meta-analysis, *Sleep*, 27 (2), 249-253.

- Aytaş, N., Afacan, E. ve İnanç, N., 2018, TDA kullanılarak doğrusal bir anten dizisi için sinyal ve gürültü alt uzayı ayrıştırması. 26. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı. Çeşme, İzmir, IEEE.
- Bağ, H. G. G., Karabulut, E. ve Alpar, C. R., 2010, 2x2 tablolarda gözlemciler/gözlemler arası uyumun değerlendirilmesi, *Hacettepe Diş Hekimliği Fakültesi Dergisi*, 34 (1-2), 46-52.
- Barbi, M., Chillemi, S., Garbo, A. D., Balocchi, R., Carpeggiani, C., Emdin, M., Michelassi, C. ve Santarcangelo, E., 1998, Predictability and nonlinearity of the heart rhythm, *Chaos, Solitons & Fractals*, 9 (3), 507-515.
- Basoglu, O. K. ve Tasbakan, M. S., 2012, Determination of new prediction formula for nasal continuous positive airway pressure in Turkish patients with obstructive sleep apnea syndrome, *Sleep Breath*, 16 (4), 1121-1127.
- Berry, R. B., Parish, J. M. ve Hartse, K. M., 2002, The use of auto-titrating continuous positive airway pressure for treatment of adult obstructive sleep apnea, *Sleep*, 25 (2), 148-173.
- Bose, R., Pratiher, S. ve Chatterjee, S., 2019, Detection of epileptic seizure employing a novel set of features extracted from multifractal spectrum of electroencephalogram signals, *IET Signal Processing* 13 (2), 157-164.
- Breiman, L., 2001, Random Forests, *Machine Learning*, 45, 5-32.
- Budak, H., 2018, Özellik seçim yöntemleri ve yeni bir yaklaşım, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22 (Özel), 21.
- Camacho, M., Riaz, M., Tahoori, A., Certal, V. ve Kushida, C. A., 2015, Mathematical Equations to Predict Positive Airway Pressures for Obstructive Sleep Apnea: A Systematic Review, *Sleep Disord*, 2015, 293868.
- Chattopadhyay, G. ve Chattopadhyay, S., 2014, Study on statistical aspects of monthly sunspot number time series and its long-range correlation through detrended fluctuation analysis, *Indian Journal of Physics*, 88 (11), 1135-1140.
- Chen, X., Solomon, I. C. ve Chon, K. H., 2005, Comparison of the use of approximate entropy and sample entropy: applications to neural respiratory signal, *Engineering in Medicine and Biology 27th Annual Conference*, Shanghai, China, 4212-4215.
- Choi, J. H., Kim, E. J., Kim, K. W., Choi, J., Kwon, S. Y., Lee, H. M., Kim, T. H., Lee, S. H., Shin, C. ve Lee, S. H., 2010, Optimal continuous positive airway pressure level in korean patients with obstructive sleep apnea syndrome, *Clin Exp Otorhinolaryngol*, 3 (4), 207-211.
- 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.
- Chong, H. S. J., Pugalenthi, A., Bajpai, R., O.H.Teoh, Cheng, Z. R., Tan, S. G., Lim, M., Tan, J., Goh, A., Tan, Y. H. ve Thomas, B., 2019 Predictive equation for optimal Continuous Positive Airway Pressure (CPAP) in children with Obstructive Sleep Apnoea (OSA). *European Respiratory Journal*, 54 (63).
- Chong, J., Bajpai, R., Teoh, O. H., Pugalenthi, A., Allen, J. C., Jr., Cheng, Z. R., Tan, S. G., Lim, M., Tan, J., Goh, A., Tan, Y. H. ve Thomas, B., 2020, Predictive equation for optimal continuous positive airway pressure in children with obstructive sleep apnoea, *ERJ Open Res*, 6 (2).
- Ciolek, M., Niedzwiecki, M., Sieklicki, S., Drozdowski, J. ve Siebert, J., 2015, Automated Detection of Sleep Apnea and Hypopnea Events Based on Robust

- Airflow Envelope Tracking in the Presence of Breathing Artifacts, *Ieee Journal of Biomedical and Health Informatics*, 19 (2), 418-429.
- CMS, 2005, CMS Manual system, www.cms.hhs.gov/Transmittals/Downloads/R35NCD.pdf: [25 Aralık 2019].
- Cohen, J., 1960, A coefficient of agreement for nominal scales, *Educational and Psychological Measurement*, 20, 37-46.
- Crespo, A., Álvarez, D., Gutiérrez-Tobal, G. C., Vaquerizo-Villar, F., Barroso-García, V., Alonso-Álvarez, M. L., Terán-Santos, J., Hornero, R. ve Campo, F. d., 2017, Multiscale entropy analysis of unattended oximetric recordings to assist in the screening of paediatric sleep apnoea at home, *Entropy*, 19 (6), 284.
- Cunha, T. C. A., Guimaraes, T. M., Almeida, F. R., Haddad, F. L. M., Godoy, L. B. M., Cunha, T. M., Silva, L. O., Tufik, S. ve Bittencourt, L., 2020, Using craniofacial characteristics to predict optimum airway pressure in obstructive sleep apnea treatment, *Braz J Otorhinolaryngol*, 86 (2), 174-179.
- d'Ortho, M.-P., Woehrle, H. ve Arzt, M., 2016, Current and Future Use of Adaptive Servo-Ventilation, *European Respiratory & Pulmonary Diseases*, 2 (1), 18-22.
- da Silva, E. L., Pereira, R., Reis, L. N., Pereira, V. L., Jr., Campos, L. A., Wessel, N. ve Baltatu, O. C., 2015, Heart rate detrended fluctuation indexes as estimate of obstructive sleep apnea severity, *Medicine (Baltimore)*, 94 (4), e516.
- Demir, A., Ursavaş, A., Aslan, A. T., Gülbay, B., Çiftçi, B., Çuhadaroğlu, Ç., Keyf, F., Firat, H., Yılmaz, M., Gerek, M., Köktürk, O., İtil, O., Karakoç, Ö., Başoğlu, Ö. K., Ersu, R., Ardiç, S., Öktem, S., Güven, S. F. ve Çiftçi, T. U., 2012, Türk Toraks Derneği Obstrüktif Uyku Apne Sendromu Tanı ve Tedavi Uzlaşısı Raporu, *İstanbul, Türk Toraks Derneği*, p. 1-66.
- Demircan, S., 2020, Ses sinyallerinden duygu tanıma için farklı yaklaşımlar, Doktora Tezi, *Lisansüstü Eğitim Enstitüsü, Konya Teknik Üniversitesi*, Konya.
- Demirhan, A., Kılıç, Y. A. ve İ. Güler, 2009, Tıpta yapay zeka uygulamaları. 5. Cerrahi Araştırma Kongresi. Ankara.
- Deng, Z., Poon, C., Arzeno, N. M. ve Katz, E. S., 2006, Heart Rate Variability in Pediatric Obstructive Sleep Apnea, *Proceedings of the 28th IEEE EMBS Annual International Conference*, New York City, USA, 3565-3568.
- Di Matteo, T., Aste, T. ve Dacorogna, M. M., 2003, Scaling behaviors in differently developed markets, *Physica A: Statistical Mechanics and its Applications*, 324 (1-2), 183-188.
- Ebben, M. R., Narizhnaya, M. ve Krieger, A. C., 2017, A new predictive model for continuous positive airway pressure in the treatment of obstructive sleep apnea, *Sleep Breath*, 21 (2), 435-442.
- El Solh, A., Akinnusi, M., Patel, A., Bhat, A. ve TenBrock, R., 2009, Predicting optimal CPAP by neural network reduces titration failure: a randomized study, *Sleep Breath*, 13 (4), 325-330.
- El Solh, A. A., Aldik, Z., Alnabhan, M. ve Grant, B., 2007, Predicting effective continuous positive airway pressure in sleep apnea using an artificial neural network, *Sleep Med*, 8 (5), 471-477.
- Engleman, H. M. ve Wild, M. R., 2003, Improving CPAP use by patients with the sleep apnoea/hypopnoea syndrome (SAHS), *Sleep Med Rev*, 7 (1), 81-99.
- Erdoğan, N. K., 2017, BİST100 Endeksinin Çokfraktallı Eğimden Arındırılmış Dalgalanma Analizi, *Journal of Current Researches on Business and Economics*, 7 (2), 555-564.
- Fitzpatrick, M. F., Alloway, C. E., Wakeford, T. M., MacLean, A. W., Munt, P. W. ve Day, A. G., 2003, Can patients with obstructive sleep apnea titrate their own

- continuous positive airway pressure?, *Am J Respir Crit Care Med*, 167 (5), 716-722.
- Gnanambal, S., Thangaraj, M., Meenatchi, V. T. ve Gayathri, V., 2018, Classification algorithms with attribute selection: an evaluation study using WEKA, *International Journal Advanced Networking and Applications*, 9 (6), 3640-3644.
- Gogus, F. Z. ve Tezel, G., 2019, Apneic Events Detection Using Different Features of Airflow Signals, *Mehran University Research Journal of Engineering and Technology*, 38 (1), 1-16.
- Golub, G. H. ve Reinsch, C., 1970, Singular value decomposition and least squares solutions, *Numerische Mathematik*, 14, 403-420.
- Göğüş, F. Z., 2015, Biyomedikal seslerin analizi ve sınıflandırılması, Yüksek Lisans, *Fen Bilimleri Enstitüsü, Selçuk Üniversitesi*, Konya.
- Göğüş, F. Z., Tezel, G., Özşen, S., Küçüktürk, S., Vatansav, H. ve Koca, Y., 2020, Identification of apnea-hypopnea index subgroups based on multifractal detrended fluctuation analysis and nasal cannula airflow signals, *Traitement du Signal*, 37 (2), 145-156.
- Gutierrez-Tobal, G. C., Alvarez, D., Marcos, J. V., del Campo, F. ve Hornero, R., 2013, Pattern recognition in airflow recordings to assist in the sleep apnoea-hypopnoea syndrome diagnosis, *Med Biol Eng Comput*, 51 (12), 1367-1380.
- Hall, M. A., 1999, Correlation-based feature selection for machine learning, Doktora Tezi, The University of Waikato.
- Hassanpour, H., Mesbah, M. ve Boashash, B., 2004, Time-frequency feature extraction of newborn EEG seizure using SVD-based techniques, *Eurasip Journal on Applied Signal Processing*, 2004 (16), 2544-2554.
- Holte, R. C., 1993, Very simple classification rules perform well on most commonly used datasets, *Machine Learning*, 11, 63-91.
- Hornero, R., Alvarez, D., Abasolo, D., del Campo, F. ve Zamarron, C., 2007, Utility of approximate entropy from overnight pulse oximetry data in the diagnosis of the obstructive sleep apnea syndrome, *IEEE Trans Biomed Eng*, 54 (1), 107-113.
- 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, *Comput Biol Med*, 88, 32-40.
- Huang, Y., Meng, S., Li, X. ve Fan, W., 2018, A classification method for wood vibration signals of Chinese musical instruments based on GMM and SVM, *Traitement du Signal*, 35 (2), 137-151.
- Iglewicz, B. ve Hoaglin, D. C., 1993, How to Detect and Handle Outliers, ASQC Quality Press, p.
- Ihlen, E. A., 2012, Introduction to multifractal detrended fluctuation analysis in matlab, *Front Physiol*, 3, 141.
- Jayasri, T. ve Hemalatha, M., 2013, Categorization of Respiratory Signal using ANN and SVM Based on Feature Extraction Algorithm, *Indian Journal of Science and Technology*, 6 (9), 5195-5200.
- Jiménez-García, J., Gutiérrez-Tobal, G. C., García, M., Kheirandish-Gozal, L., Martín-Montero, A., Álvarez, D., del Campo, F., Gozal, D. ve Hornero, R., 2020, Assessment of Airflow and Oximetry Signals to Detect Pediatric Sleep Apnea-Hypopnea Syndrome Using AdaBoost, *Entropy*, 22 (6), 670.
- Kaimakamis, E., Bratsas, C., Sichletidis, L., Karvounis, C. ve Maglaveras, N., 2009, Screening of patients with Obstructive Sleep Apnea Syndrome using C4.5 algorithm based on non linear analysis of respiratory signals during sleep. 2009

- Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Minneapolis, MN, USA, IEEE: 3465-3469.
- Kaimakamis, E., Tsara, V., Bratsas, C., Sichletidis, L., Karvounis, C. ve Maglaveras, N., 2016, Evaluation of a Decision Support System for Obstructive Sleep Apnea with Nonlinear Analysis of Respiratory Signals, *PLoS One*, 11 (3), e0150163.
- Kanbay, A., 2013, Genel Prensipler, Kayıt Yöntemleri, Kalibrasyon, *Solunum*, 15 (2), 10-13.
- Kantelhardt, J. W., Zschiegner, S. A., Koscielny-Bunde, E., Havlin, S., Bunde, A. ve Stanley, H. E., 2002, Multifractal detrended fluctuation analysis of nonstationary time series, *Physica A: Statistical Mechanics and its Applications*, 316, 87-114.
- Karabulut, R. ve Şeker, K., 2018, Belirlenmiş değişkenlerin vergi gelirleri üzerindeki etkisi: çoklu doğrusal regresyon analizi, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 23 (3), 795-816.
- Kayaalp, G. T., Güney, M. Ç. ve Cebeci, Z., 2015, Çoklu doğrusal regresyon modelinde değişken seçiminin zootekniye uygulanışı, *Çukurova Üniversitesi Ziraat Fakültesi Dergisi*, 30 (1), 1-8.
- Kilic, S., 2013, Linear regression analysis, *Journal of Mood Disorders*, 3 (2), 90.
- Kim, S. S. ve Yang, K. I., 2018, Predictive Model of Optimal Continuous Positive Airway Pressure for Obstructive Sleep Apnea Patients with Obesity by Using Machine Learning, *Journal of Sleep Medicine*, 15 (2), 48-54.
- Kohavi, R. ve John, G. H., 1997, Wrappers for feature subset selection, *Artificial Intelligence*, 273-324.
- Koley, B. L. ve Dey, D., 2013, Automatic detection of sleep apnea and hypopnea events from single channel measurement of respiration signal employing ensemble binary SVM classifiers, *Measurement*, 46 (7), 2082-2092.
- Köktürk, O., 1999, Uykunun izlenmesi. Polisomnografi., *Tüberküloz ve Toraks Dergisi*, 47, 499-511.
- Kulkas, A., Tiihonen, P., Eskola, K., Julkunen, P., Mervaala, E. ve Toyras, J., 2013, Novel parameters for evaluating severity of sleep disordered breathing and for supporting diagnosis of sleep apnea-hypopnea syndrome, *J Med Eng Technol*, 37 (2), 135-143.
- Kushida, C. A., Chediak, A., Berry, R. B., Brown, L. K., Gozal, D., Iber, C., Parthasarathy, S., Quan, S. F. ve Rowley, J. A., 2008, Clinical guidelines for the manual titration of positive airway pressure in patients with obstructive sleep apnea, *Journal of clinical sleep medicine: JCSM: official publication of the American Academy of Sleep Medicine*, 4 (5), 157-171.
- Külahlı, İ., 2012, Horlama ve uyku apne sendromu, <https://www.slideshare.net/mbolmez/osas-011v-12266500>: [10.09.2020].
- Lai, C.-C., Friedman, M., Lin, H.-C., Wang, P.-C., Hwang, M. S., Hsu, C.-M., Lin, M.-C. ve Chin, C.-H., 2015, Clinical Predictors of Effective Continuous Positive Airway Pressure in Patients With Obstructive Sleep Apnea/Hypopnea Syndrome, *Laryngoscope*, 125 (8), 1983-1987.
- Lashermes, B., Abry, P. ve Chainais, P., 2011, New Insights into the Estimation of Scaling Exponents, *International Journal of Wavelets, Multiresolution and Information Processing*, 02 (04), 497-523.
- Lee, G. H., Kim, M. J., Lee, E. M., Kim, C. S. ve Lee, S. A., 2013, Prediction of optimal CPAP pressure and validation of an equation for Asian patients with obstructive sleep apnea, *Respir Care*, 58 (5), 810-815.

- Lee, H., Park, J., Kim, H. ve Lee, K. J., 2016, New Rule-Based Algorithm for Real-Time Detecting Sleep Apnea and Hypopnea Events Using a Nasal Pressure Signal, *J Med Syst*, 40 (12), 282.
- Lee, S. ve Hayes, M. H., 2004, Properties of the singular value decomposition for efficient data clustering, *Ieee Signal Processing Letters*, 11 (11), 862-866.
- Li, Q., Xie, W. ve Huang, J., 2015, Multifractal spectrum features based classification method for aircraft. IET International Radar Conference. Hangzhou, China, IEEE.
- Lin, I. F., Chuang, M. L., Liao, Y. F., H., C. N. ve Li, H. Y., 2003, Predicting Effective Continuous Positive Airway Pressure in Taiwanese Patients With Obstructive Sleep Apnea Syndrome, *Journal of the Formosan Medical Association*, 102 (4), 215-221.
- Loredo, J. S., Berry, C., Nelesen, R. A. ve Dimsdale, J. E., 2007, Prediction of continuous positive airway pressure in obstructive sleep apnea, *Sleep Breath*, 11 (1), 45-51.
- Luo, J., Xiao, S., Qiu, Z., Song, N. ve Luo, Y., 2013, Comparison of manual versus automatic continuous positive airway pressure titration and the development of a predictive equation for therapeutic continuous positive airway pressure in Chinese patients with obstructive sleep apnoea, *Respirology*, 18 (3), 528-533.
- Ma, Y., Shi, W., Peng, C. K. ve Yang, A. C., 2018, Nonlinear dynamical analysis of sleep electroencephalography using fractal and entropy approaches, *Sleep Med Rev*, 37, 85-93.
- Malalur, C., 2018, Sleep apnea, <https://www.slideshare.net/ChaithanyaMalalur/sleep-apnea-90124974>: [10.09.2020].
- Márton, L. F., Brassai, S. T., Bakó, L. ve Losonczi, L., 2014, Detrended Fluctuation Analysis of EEG Signals, *Procedia Technology*, 12, 125-132.
- Miljeteig, H. ve Hoffstein, V., 1993, Determinants of Continuous Positive Airway Pressure Level for Treatment of Obstructive Sleep Apnea, *American Review of Respiratory Disease*, 147 (6), 1526-1530.
- Moret-Bonillo, V., Alvarez-Estevez, D., Fernandez-Leal, A. ve Hernandez-Pereira, E., 2014, Intelligent approach for analysis of respiratory signals and oxygen saturation in the sleep apnea/hypopnea syndrome, *Open Med Inform J*, 8, 1-19.
- Nakano, H., Tanigawao, T., Furukawa, T. ve Nishima, S., 2007, Automatic detection of sleep-disordered breathing from a single-channel airflow record, *European Respiratory Journal*, 29 (4), 728-736.
- Otero, A., Felix, P. ve Alvarez, M. R., 2011, Algorithms for the analysis of polysomnographic recordings with customizable criteria, *Expert Systems with Applications*, 38 (8), 10133-10146.
- Otero, A., Felix, P., Presedo, J. ve Zamarron, C., 2012, An evaluation of indexes as support tools in the diagnosis of sleep apnea, *Ann Biomed Eng*, 40 (8), 1825-1834.
- Özercan, S., 2018, Obstrüktif uyku apne sendromlu (OSAS) hastalarda serum nesfatin-1 düzeyinin OSAS şiddeti ile ilişkisi, Tıpta Uzmanlık Tezi, *T.C. Sağlık Bilimleri Üniversitesi*, Ankara.
- Peng, C. K., Havlin, S., Stanley, H. E. ve Goldberger, A. K., 1995, Quantification of scaling exponents and crossover phenomena in nonstationary heartbeat time series, *Chaos*, 5 (1), 82-87.
- Rostig, S., Kantelhardt, J. W., Penzel, T., Cassel, W., Peter, J. H., Vogelmeier, C., Becker, H. F. ve Jerrentrup, A., 2005, Nonrandom variability of respiration during sleep in healthy humans, *Sleep*, 28 (4), 411-417.

- Rowley, J. A., Tarbichi, A. G. ve Badr, M. S., 2005, The use of a predicted CPAP equation improves CPAP titration success, *Sleep Breath*, 9 (1), 26-32.
- Sadeghniaat-Haghighi, K., 2018, Using prediction formulas for continuous positive airway pressure in obstructive sleep apnea syndrome, *Journal of Sleep Sciences*, 3 (3-4), 75-79.
- Salisbury, J. I. ve Sun, Y., 2007, Rapid screening test for sleep apnea using a nonlinear and nonstationary signal processing technique, *Med Eng Phys*, 29 (3), 336-343.
- Schiza, S. E., Bouloukaki, I., Mermigkis, C., Panagou, P., Tzanakis, N., Moniaki, V., Tzortzaki, E. ve Siafakas, N. M., 2011, Utility of formulas predicting the optimal nasal continuous positive airway pressure in a Greek population, *Sleep Breath*, 15 (3), 417-423.
- Schmidt, M., Foitzik, B., Wauer, R. R., Winkler, F. ve Schmalisch, G., 1998, Comparative investigations of algorithms for the detection of breaths in newborns with disturbed respiratory signals, *Computers and Biomedical Research*, 31 (6), 413-425.
- Series, F. ve Marc, I., 1997, Efficacy of Automatic Continuous Positive Airway Pressure Therapy That Uses an Estimated Required Pressure in the Treatment of the Obstructive Sleep Apnea Syndrome, *Annals of Internal Medicine*, 127 (8), 588-595.
- Sezgin, E. ve Çelik, Y., 2013, Veri madenciliğinde kayıp veriler için kullanılan yöntemlerin karşılaştırılması. Akademik Bilişim 2013 Konferansı. Akdeniz Üniversitesi, Antalya: 194-198.
- Stradling, J. R., Hardinge, M., Paxton, J. ve Smith, D. M., 2004, Relative accuracy of algorithm-based prescription of nasal CPAP in OSA, *Respir Med*, 98 (2), 152-154.
- Strohl, K. P. ve Redline, S., 1986, Nasal CPAP therapy, upper airway muscle activation and obstructive sleep apnea, *American Review of Respiratory Disease*, 134 (3), 555-558.
- Şentürk, S. ve Aşan, Z., 2007, Bulanık mantıkta korelasyon katsayısı; meteorolojik olaylarda bir uygulama, *Eskişehir Osmangazi Üniversitesi Müh. Mim. Fak. Dergisi* (1), 149-158.
- Tian, J. Y. ve Liu, J. Q., 2005, Apnea detection based on time delay neural network, *2005 27th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Vols 1-7*, 2571-2574.
- Topçu, Ç., Akgül, A., Bedeloğlu, M., Döğür, E. N., Sever, R., Özkan, Ö., Özkan, Ö., Uysal, H., Polat, Ö. ve Çolak, Ö. H., 2015, Yüz hareketlerinin sınıflandırılması için yüzey EMG işaretlerinin entropi analizi. 23. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı. Malatya, Türkiye: 1-4.
- Uzbaş, B., 2017, Sayısal dental modellerden otomatik cinsiyet tespiti, Doktora Tezi, *Fen Bilimleri Enstitüsü, Selçuk Üniversitesi, Konya*.
- Übeyli, E. D. ve Güler, İ., 2004, Spectral analysis of internal carotid arterial Doppler signals using FFT, AR, MA, and ARMA methods, *Computers in Biology and Medicine*, 34 (4), 293-306.
- Vapnik, V. N., 1999, An overview of statistical learning theory, *IEEE TRANSACTIONS ON NEURAL NETWORKS*, 10 (5), 988-999.
- Vaquerizo-Villar, F., Alvarez, D., Kheirandish-Goza, L., Gutiérrez-Tobal, G. C., Barroso-García, V., Crespo, A., Campo, F. d., Gozal, D. ve Hornero, R., 2018, Detrended fluctuation analysis of the oximetry signal to assist in paediatric sleep apnoea-hypopnoea syndrome diagnosis, *Physiological Measurement*, 39 (11).

- Wahab, A. N. ve Ahmed, Y. N., 2017, Optimal level of continuous positive airway pressure: Auto-CPAP titration versus predictive formulas, *Egyptian Journal of Chest Diseases and Tuberculosis*, 66 (2), 353-361.
- Xia, Y. D., Zhou, W. D., Li, C. C., Yuan, Q. ve Geng, S. J., 2015, Seizure detection approach using S-transform and singular value decomposition, *Epilepsy & Behavior*, 52, 187-193.
- Xie, B. L. ve Minn, H., 2012, Real-Time Sleep Apnea Detection by Classifier Combination, *Ieee Transactions on Information Technology in Biomedicine*, 16 (3), 469-477.
- Yamauchi, M., Tamaki, S., Yoshikawa, M., Ohnishi, Y., Nakano, H., Jacono, F. J., Loparo, K. A., Strohl, K. P. ve Kimura, H., 2011, Differences in breathing patterning during wakefulness in patients with mixed apnea-dominant vs obstructive-dominant sleep apnea, *Chest*, 140 (1), 54-61.
- Yentes, J. M., Hunt, N., Schmid, K. K., Kaipust, J. P., McGrath, D. ve Stergiou, N., 2013, The appropriate use of approximate entropy and sample entropy with short data sets, *Ann Biomed Eng*, 41 (2), 349-365.
- Yıldırım, P., 2015, Filter based feature selection methods for prediction of risks in hepatitis disease, *International Journal of Machine Learning and Computing*, 5 (4), 258-263.
- Yong, M. C., Shyang, K. S., Chan, S. K. ve Tie, S. T., 2018, A prediction equation of optimal cpap pressure for obstructive sleep apnea in Malaysia. *Respirology*, *Respirology*, 23 (2), 314.
- Yucelbas, C., Yucelbas, S., Ozsen, S., Tezel, G., Kuccukturk, S. ve Yosunkaya, S., 2018a, A novel system for automatic detection of K-complexes in sleep EEG, *Neural Computing & Applications*, 29 (8), 137-157.
- Yucelbas, S., Yucelbas, C., Tezel, G., Ozsen, S. ve Yosunkaya, S., 2018b, Automatic sleep staging based on SVD, VMD, HHT and morphological features of single-lead ECG signal, *Expert Systems with Applications*, 102, 193-206.
- Yücelbaş, C., 2017a, Online uyku izleme ve evreleme sistemi için sinyal bileşenlerinin çıkarımı, Doktora Tezi, *Fen Bilimleri Enstitüsü, Selçuk Üniversitesi*, Konya.
- Yücelbaş, Ş., 2017b, EKG parametrelerinin uyku evreleri ve OSAS ile ilişkisinin incelenmesi, Doktora Tezi, *Fen Bilimleri Enstitüsü, Selçuk Üniversitesi*, Konya.
- Zhang, Y. J., Zhang, X. M., Yan, C. W., Liu, W. H., Yu, E. J. ve Luo, Y. X., 2014, Correlation study in respiration fluctuations during sleep stages, *Technology and Health Care*, 22 (6), 885-894.

EKLER**EK-1 Etik Kurul ONAYI**

T.C.
SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI

GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU KARARLARI

Toplantı Sayısı: 2017/17

Toplantı Tarihi : 11.10.2017

Karar Sayısı 2017/287 S.Ü. Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü öğretim üyesi Doç.Dr.Gülay TEZEL'in "OSAS Hastaları için CPAP Cihazlarındaki Optimum Basıncın Yapay Zekâ ile Tahmini" başlıklı araştırmasının değerlendirilme talebi ile ilgili 04.10.2017 tarihli dilekçesi ve ekleri görüşüldü.

Yapılan inceleme ve görüşmelerden sonra; Doç.Dr.Gülay TEZEL'in "OSAS Hastaları için CPAP Cihazlarındaki Optimum Basıncın Yapay Zekâ ile Tahmini" adlı araştırmasının kabulüne oy birliği ile karar verildi.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Fatma Zehra GÖĞÜŞ
Uyruğu : T.C.
Doğum Yeri ve Tarihi : Selçuklu / Konya 01.09.1990
Telefon : 0332 205 1544
Faks :
E-Posta : fzgogus@ktun.edu.tr

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Özel Lale Lisesi Meram/Konya	2007
Üniversite	: Selçuk Üniversitesi	2012
Yüksek Lisans	: Selçuk Üniversitesi	2015
Doktora	: Konya Teknik Üniversitesi	2020

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2012-2013	Nevşehir Hacı Bektaş Veli Üniversitesi	Arş. Gör.
2013-2018	Selçuk Üniversitesi	Arş. Gör.
2018-Halen	Konya Teknik Üniversitesi	Arş. Gör.

UZMANLIK ALANI

Makine Öğrenmesi
 Yapay Zeka
 Biyomedikal Örüntü Tanıma
 Biyomedikal Sinyal İşleme

YABANCI DİLLER

İngilizce

YAYINLAR

1. F. Z. Göğüş, G. Tezel, S. Özşen, S. Küçüktürk, H. Vatansev, Y. Koca, 2020, "Identification of Apnea-Hypopnea Index Subgroups Based on Multifractal Detrended Fluctuation Analysis and Nasal Cannula Airflow Signals", Traitement du Signal, Vol. 37, No. 2, pp. 145-156. <https://doi.org/10.18280/ts.370201> (Science Citation Index Expanded) (Doktora tezinden yapılmıştır)
2. Gizemnur Erol, Fatma Zehra Göğüş, Gülay Tezel, 2020, "Etkin EEG Özellikleri Çıkarılarak Arousal Tespiti, Avrupa Bilim ve Teknoloji Dergisi, Özel Sayı, 117-122. (TR-Dizin)

3. Y. Koca, S. Özşen, F. Z. Göğüş, G. Tezel, S. Küçüktürk, H. Vatansev, 2020, “Classification of Sleep Stages Using PSG Recording Signals”, European Journal of Science and Technology, Special Issue, pp. 315-321. **(TR-Dizin)**
4. F. Z. Göğüş, G. Tezel, 2019, “Apneic Events Detection Using Different Features of Airflow Signals”, Mehran University Research Journal of Engineering and Technology, Vol. 38, No. 1, pp. 1-16. **(Emerging Sources Citation Index)**
5. F. Z. Göğüş, G. Tezel, 2018, “Comparision of LPC Based Parametric Techniques for Respiratory Sounds Recognition”, International Journal of Signal Processing Systems Vol. 6 , No. 1, pp. 6-11.
6. F. Z. Göğüş, B. Karlık, G. Harman, 2016, “Identification of Pulmonary Disorders by Using Different Spectral Analysis Methods” International Journal of Computational Intelligence Systems, Vol. 9, No. 4, pp. 595-611. <http://dx.doi.org/10.1080/18756891.2016.1204110> **(Science Citation Index Expanded) (Yüksek Lisans tezinden yapılmıştır)**
7. F. Z. Göğüş, G. Tezel, “Heart Sounds Analysis by Using Linear Prediction Cepstral Coefficients”, International Conference on Engineering and Natural Sciences (ICENS 2016), Sarajevo, Bosnia and Herzegovina, 24-28 May 2016.
8. F. Z. Göğüş, B. Karlık, “Identification of Normal and Abnormal Heart Sounds Using Neural Network”, International Conference on Engineering and Natural Sciences (ICENS 2015), Skopje, Macedonia, 15-19 May 2015.
9. F. Z. Göğüş, B. Karlık, G. Harman, 2015, “Classification of Asthmatic Breath Sounds by Using Wavelet Transforms and Neural Networks”, International Journal of Signal Processing Systems Vol. 3 , No. 2, pp. 106-111. **(Yüksek Lisans tezinden yapılmıştır)**

PROJELER

119E127 Numaralı, Türk OSAS Hastalarında CPAP Değerini Etkileyen Polisomnografik Özelliklerin Belirlenmesi ve Optimum CPAP Değerinin Yapay Zeka ile Tahmini isimli TÜBİTAK 1001 Proje Bursiyerliği