

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI**

**POLİSOMNOGRAFİ İŞARETLERİ KULLANILARAK
YAPAY SİNİR AĞLARI VE UYARLAMALI SİNİRSEL
BULANIK MANTIK SİSTEMİ İLE UYKU VE UYKU
APNESİNİN SKORLANMASI**

**Hazırlayan
Osman AYDOĞAN**

**Danışman
Prof.Dr. Kerim GÜNEY**

Doktora Tezi

**Haziran 2023
KAYSERİ**



**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI**

**POLİSOMNOGRAFİ İŞARETLERİ KULLANILARAK
YAPAY SİNİR AĞLARI VE UYARLAMALI SİNİRSEL
BULANIK MANTIK SİSTEMİ İLE UYKU VE UYKU
APNESİNİN SKORLANMASI**

**Hazırlayan
Osman AYDOĞAN**

**Danışman
Prof.Dr. Kerim GÜNEY**

Doktora Tezi

**Haziran 2023
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Osman AYDOĞAN

“Polisomnografi İşaretleri Kullanılarak Yapay Sinir Ağları ve Uyarlamalı Sinirsel Bulanık Mantık Sistemi İle Uyku ve Uyku Apnesinin Skorlanması” adlı Doktora tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

Hazırlayan

Osman AYDOĞAN

Danışman

Prof. Dr. Kerim GÜNEY

Elektrik-Elektronik Mühendisliği ABD Başkanı

Prof. Dr. Ferhat DALDABAN

TEŞEKKÜR

Bu tezde ve buna baęlı olarak yaptığım dięer alıřmalarda, engin bilgi ve tecrubesini hibir zaman esirgemeyen ve bugnlere gelmemde byk katkı sahibi olan sayın hocam Prof. Dr. Kerim GNEY’e teřekkrlerimi sunarım. Tez izleme komitemde bulunarak alıřmalarımı kıymetli fikirleri ile ynlendiren hocalarım Prof. Dr. Necmi TAřPINAR’a ve Prof. Dr. řaban ZER’e ayrıca teřekkr ederim.

alıřmalarım sresince vermiř olduęu deęerli destek ve tavsiyelerinden dolayı sayın Prof. Dr. Mahmut Kemal KIYMIK’a, Prof. Dr. Deniz TUNCEL’e ve Dr. ęr. yesi Ali ter’e teřekkr ederim.

Bu srete bana sabır gstererek yardımcı olan aile mensuplarım bařta babam Abdurrahman, annem Nazife ve eřim Hatice olmak zere ocuklarım Abdurrahman, Abdlkadir, Elif, Nazife, Abdullah ve řeyda’ya da teřekkr ederim.

Osman AYDOęAN

Haziran 2023, KAYSERİ

**POLİSOMNOGRAFİ İŞARETLERİ KULLANILARAK YAPAY SİNİR AĞLARI
VE UYARLAMALI SİNİRSEL BULANIK MANTIK SİSTEMİ İLE
UYKU VE UYKU APNESİNİN SKORLANMASI**

Osman AYDOĞAN

**Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Doktora Tezi, Haziran 2023
Danışman: Prof. Dr. Kerim GÜNEY**

ÖZET

Uyku bozuklukları, insanların hayat kalitesini doğrudan etkiler. Polisomnografi işaretlerine dayalı görsel uyku ve uyku apnesi skorlama, pahalı, karmaşık ve zaman alıcıdır. Bu sebepten dolayı uyku ve uyku apnesinin otomatik olarak skorlanmasına dayalı çok sayıda farklı metot literatürde sunulmuştur.

Bu tezde, polisomnografi (PSG) işaretleri kullanılarak uyku ve uyku apnesi skorlaması yapılmıştır. Uyku skorlaması, elektroensefalogram (EEG), elektrookülogram (EOG) ve elektromiyogram (EMG) işaretleri kullanılarak yapay sinir ağları ile gerçekleştirilmiştir. Uyku skorlaması ile uyanıklık, hızlı ve hızlı olmayan göz hareketi evreleri belirlenmiştir. Uyku apnesi, solunum işaretleri kullanılarak skorlama algoritması, yapay sinir ağları ve uyarlamalı sinirsel bulanık mantık sistemi ile skorlanmıştır. Uyku apnesi skorlaması ile bir hastanın uyku apnesi olduğu zaman dilimleri belirlenmiştir. Görsel skorlama kuralları kullanılarak bir skorlama algoritması oluşturulmuştur.

Bu tezde elde edilen uyku ve uyku apnesi skorlama sonuçları literatürdeki mevcut metotların sonuçları ile karşılaştırılmıştır. Yapay sinir ağları ve uyarlamalı sinirsel bulanık mantık sistemi sonuçlarının literatürdeki sonuçlarla iyi bir uyumluluk içerisinde olduğu gözlemlenmiştir.

Anahtar Kelimeler: Polisomnografi işaretleri, uyku skorlama, uyku apnesi skorlama, skorlama algoritması, yapay sinir ağları, uyarlamalı sinirsel bulanık mantık sistemi.

**SLEEP AND SLEEP APNEA SCORING WITH ARTIFICIAL NEURAL
NETWORKS AND ADAPTIVE-NETWORK-BASED FUZZY INFERENCE
SYSTEMS USING POLYSOMNOGRAPHY SIGNALS**

Osman AYDOĞAN

Erciyes University, Graduate School of Natural and Applied Sciences

PhD Thesis, June 2023

Supervisor: Prof. Dr. Kerim GÜNEY

ABSTRACT

Sleep disorders directly influence the quality of life of human beings. Manual visual sleep and sleep apnea scoring on the base of polysomnography signals are expensive, complex, and time-consuming. For this reason, many different methods based on automatic scoring of sleep and sleep apnea have been presented in the literature.

In this thesis, sleep and sleep apnea scoring were achieved by using polysomnography (PSG) signals. Sleep scoring was performed with artificial neural network (ANN) using electroencephalogram (EEG), electrooculogram (EOG), and electromyogram (EMG) signals. Wakefulness, rapid eye movement (REM), and non-rapid eye movement (NREM) stages were determined by sleep scoring. Sleep apnea was scored with a scoring algorithm, ANN and adaptive-network-based fuzzy inference system (ANFIS) using respiratory signals. With sleep apnea scoring, the time intervals when a patient has sleep apnea were determined. Visual scoring rules were used for producing a scoring algorithm.

The sleep and sleep apnea scoring results obtained in this thesis were compared with the results of the methods available in the literature. It was observed that the results of ANN and ANFIS are in good agreement with the results in the literature.

Keywords: Polisomnographic signals, sleep scoring, sleep apnea scoring, scoring algorithm, artificial neural networks, adaptive-network-based fuzzy inference systems.

İÇİNDEKİLER

POLİSOMNOGRAFİ İŞARETLERİ KULLANILARAK YAPAY SİNİR AĞLARI VE UYARLAMALI SİNİRSEL BULANIK MANTIK SİSTEMİ İLE UYKU VE UYKU APNESİNİN SKORLANMASI

BİLİMSEL ETİĞE UYGUNLUK	ii
YÖNERGEYE UYGUNLUK.....	iii
KABUL VE ONAY	iv
TEŞEKKÜR.....	v
ÖZET.....	vi
ABSTRACT.....	vii
İÇİNDEKİLER	viii
KISALTMALAR	xii
SİMGELER.....	xiv
TABLolar LİSTESİ.....	xvi
ŞEKİLLER LİSTESİ	xviii
GİRİŞ.....	1

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR ARAŞTIRMASI

1.1. Giriş	2
1.2. Uyku Fizyolojisi.....	2
1.3. Uyku Apnesi.....	3
1.4. Polisomnografi İşaretleri	4
1.5. Uyku Skorlama İle İlgili Yapılan Çalışmalar	5
1.6. Uyku Apnesi Skorlama İle İlgili Yapılan Çalışmalar	6
1.7. Tezin Amacı	8

2. BÖLÜM

POLİSOMNOGRAFİ İŞARETLERİ

2.1. Giriş	11
2.2. Elektroensefalogram İşaretleri	11
2.2.1. Uyanıklık ve Uykunun Farklı Evrelerinde EEG Değişimleri	16
2.3. Elektrokülogram İşaretleri	17
2.4. Elektromiyogram İşaretleri.....	19
2.5. Solunum Basıncı İşaretleri	21
2.6. Solunum Çabası İşaretleri.....	23
2.7. Oksijen Saturasyonu İşaretleri	25

3. BÖLÜM

UYKU VE UYKU APNESİ SKORLAMA YÖNTEMLERİ

3.1. Giriş	29
3.2. Algoritmik Yöntemler.....	29
3.3. Yapay Sinir Ağları	30
3.3.1. Bağlantı Ağırlıklarının Optimizasyonu.....	32
3.3.2. Eğitim Verilerinin Hazırlanması	33
3.3.3. Katman Sayısının Seçimi	33
3.3.4. Sinir Hücrelerinin Sayısının Seçimi.....	33
3.3.5. Transfer Fonksiyonunun Seçimi.....	33
3.3.6. Yapay Sinir Ağı Öğrenme Algoritmasının Seçimi	34
3.3.7. Yapay Sinir Ağının Gerçekleştirilmesi.....	35
3.4. Uyarlamalı Sinirsel Bulanık Mantık Sistemi.....	35
3.5. Morfolojik Filtreler	38

4. BÖLÜM

UYKU VE UYKU APNESİ SKORLAMA

4.1. Giriş	39
4.2. Yapay Sinir Ağları İle Uyku Skorlama	39
4.2.1. Uyku Skorlama İçin Kullanılan Polisomnografi İşaretleri ve İşaret Özellikleri	40
4.2.2. Polisomnografi İşaretlerinin Özelliklerinin Çıkarılması.....	41
4.2.3. Uyku Skorlama Başarısının Hesaplanması.....	44
4.2.4. Uyku Skorlama İçin Yapay Sinir Ağı Parametrelerinin Seçimi.....	45
4.2.5. Sinir Hücrelerinin Sayısının Seçimi.....	45
4.2.6. Uyku Skorlamak İçin Yapay Sinir Ağlarının Gerçekleştirilmesi.....	46
4.2.7. Yapay Sinir Ağları İle yapılan Uyku Skorlamasının Sonuçları.....	49
4.2.8. Yapay Sinir Ağları İle Yapılan Uyku Skorlamasının Değerlendirilmesi	51
4.3. Uyku Apnesinin Skorlanması	51
4.3.1. Uyku Apnesini Skorlamak İçin Kullanılan PSG İşaretleri ve İşaret Özellikleri	53
4.3.2. Polisomnografi İşaretlerinin Özelliklerinin Çıkarılması.....	54
4.3.3. Uyku Apnesi Skorlama Başarısının Hesaplanması.....	55
4.4. Algoritmik Yöntemle Uyku Apnesinin Skorlanması	55
4.4.1. Algoritmik Skorlama Kuralları	56
4.4.2. Uyku Apnesini Skorlamak için Algoritmanın Gerçekleştirilmesi	56
4.4.3. Skorlama Algoritması İle Yapılan Uyku Apnesi Skorlamasının Sonuçları.....	57
4.4.4. Skorlama Algoritması İle Yapılan Uyku Apnesi Skorlamasının Değerlendirilmesi	58

4.5. Yapay Sinir Ağları İle Uyku Apnesinin Skorlanması.....	60
4.5.1. Sinir Hücrelerinin Sayısının Seçimi.....	60
4.5.2. Yapay Sinir Ağları İle Uyku Apnesini Skolama	61
4.5.3. Yapay Sinir Ağları İle Yapılan Uyku Apnesi Skolamasının Sonuçları	63
4.6. Uyarlamalı Sinirsel Bulanık Mantık Sistemi ile Uyku Apnesinin Skollanması	66
4.6.1. Kullanılan İşaretler ve İşaret Özellikleri	67
4.6.2. Üyelik Fonksiyonlarının Seçimi	67
4.6.3. Uyarlamalı Sinirsel Bulanık Mantık Sistemi İle Uyku Apnesi Skolamasının Gerçekleştirilmesi	68
4.6.4. Uyarlamalı Sinirsel Bulanık Mantık Sistemi İle Yapılan Uyku Apnesi Skolamasının Sonuçları	68
4.7. Uyku Apnesi Skolama Çalışmasının Değerlendirilmesi	71

5. BÖLÜM

TARTIŞMA, SONUÇ VE ÖNERİLER

KAYNAKLAR	77
ÖZGEÇMİŞ.....	88

KISALTMALAR

AASM	: Amerikan Uyku Tıbbı Akademisi (American Academy of Sleep Medicine)
AHI	: Apne Hipopne İndeksi
ANFIS	: Uyarlamalı Sinirsel Bulanık Mantık Sistemi (Adaptive-Network-Based Fuzzy Inference System)
ANN	: Artificial Neural Network
ark.	: arkadaşları
BFGS	: Broyden–Fletcher–Goldfarb–Shanno (BFGS) algoritması
BSS	: Kör Kaynak Ayırıştırma (Blind Source Separation)
C4	: Başın merkezi bölgesinden kaydedilen EEG işareti
CPAP	: Devamlı Pozitif Havayolu Basıncı (Continuous Positive Airway Pressure)
CSA	: Merkezi Uyku Apnesi (Central Sleep Apnea)
ÇÇDD	: Çok Çözünürlüklü Dalgacık Dönüşümü
DC	: Sabit Değer
DD	: Dalgacık Dönüşümü (Wavelet Transform, WT)
DN	: Doğru Negatif
DP	: Doğru Pozitif
E1	: EOG işareti
E2	: EOG işareti
EEG	: Elektroensefelogram
EKG	: Elektrokardiyogram (Electrocardiogram, ECG)
EMD	: Ampirik Mod Ayırma (Empirical Mode Decomposition)
EMG	: Elektromiyogram
EOG	: Elektrookülogram
F4	: Başın ön bölgesinden kaydedilen EEG işareti
FD	: Fourier Dönüşümü (Fourier Transform, FT)
FFT	: Hızlı Fourier Dönüşüm (Fast Fourier Transform)
FIS	: Bulanık Çıkarım Sistemi (Fuzzy Inference System)
HMM	: Gizli Markov Modeli (Hidden Markov Model)
KAHD	: Kalp Atış Hızı Değişkenliği (Heart Rate Variability, HRV)

KNN	: K-En Yakın Komşuluk Algoritması (K-Nearest Neighbor Classification Algorithm)
LDA	: Doğrusal Diskriminant Analizi (Linear Discriminant Analysis)
LR	: Lojistik Regresyon (Logistic Regression)
LS-SVM	: En Küçük Kareler Destek Vektör Makineleri (Least-Squares Support Vector Machine)
MA	: Hareketli Ortalama (Moving Average)
MC-SVM	: Çok Sınıflı En Küçük Kareler Destek Vektör Makineleri (Multiclass Least Squares Support Vector Machines, MC-LS-SVM)
MLR	: Çoklu Doğrusal Regresyon (Multiple Linear Regression)
MSE	: Ortalama Karesel Hata (Mean Squared Error)
NIG	: Normal Ters Gauss Dağılımı (Normal Inverse Gaussian)
NREM	: Yavaş Dalga Uykusu (Non-Rapid Eye Movement)
O2	: Başın arka bölgesinden kaydedilen EEG işareti
O ₂ Sat	: Arteriyel Kanda Ölçülen Oksijen Saturasyonu
ODI2	: Oksijen Saturasyonunun %2 Azalması (2% Oxygen Desaturation Index)
ODI3	: Oksijen Saturasyonunun %3 Azalması (3% Oxygen Desaturation Index)
ODI4	: Oksijen Saturasyonunun %4 Azalması (4% Oxygen Desaturation Index)
PPG	: Fotopletismografi (Photoplethysmography)
PSG	: Polisomnografi
REM	: Hızlı Göz Hareketi Uykusu (Rapid Eye Movement)
rms	: Etkin Değer
SaO ₂	: Arteriyel Kanda Ölçülen Oksijen Saturasyonu
sEMG	: Yüzey EMG işaretleri
SSA	: Tekil Spektrum Analizi (Singular spectrum analysis)
Std.	: Standart
STFT	: Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform)
SVM	: Destek Vektör Makineleri (Support Vector Machines)
TQWT	: Ayarlanabilir Q Faktörlü Dalgacık Dönüşümü (Tunable-Q Factor Wavelet Transform)
TUA	: Tıkalıcı Uyku Apnesi (Obstructive Sleep Apnea, OSA)

YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağı, Yapay Sinir Ağları

SİMGELER

$\oplus$	: Morfolojik dönüşümde genişleme işlemi
$\ominus$	: Morfolojik dönüşümde aşınma işlemi
$\bullet$	: Morfolojik dönüşümde kapanma işlemi
$\circ$	: Morfolojik dönüşümde açılma işlemi
β	: Sinir hücresi eşik değeri
μ	: Sayısal işaretin ortalama değeri
μ_a	: Sayısal işaretin mutlak değerlerinin ortalaması
σ	: Sayısal işaretin standart sapması
A_1, A_2	: ANFIS’de bulanık küme fonksiyonları
B_1, B_2	: ANFIS’de bulanık küme fonksiyonları
DN	: Doğru negatif
DP	: Doğru pozitif
d_i	: YSA çıkışında olması istenen değer
e	: YSA çıkışında oluşan toplam hata
E	: Sayısal işaretin enerjisi
f	: Morfolojik dönüşümde F kümesinde tanımlı fonksiyon
f	: Sinir hücresi transfer fonksiyonu
f_1, f_2	: Uyarlamalı sinirsel bulanık mantık sistemi üyelik fonksiyonları
Hz	: Hertz, frekans birimi
k	: Morfolojik dönüşümde K kümesinde tanımlı yapı elemanı
max	: En büyük değer fonksiyonu
min	: En küçük değer fonksiyonu
m	: YSA giriş verilerinin sayısı
n	: Sinir hücresi giriş verilerinin sayısı
N	: Sayısal işaretin örnek sayısı
η	: YSA’nın öğrenme katsayısı

O_i	: YSA çıkışları
P	: Sayısal işaretin gücü
p_1, p_2	: Uyarlamalı sinirsel bulanık mantık sistemi parametreleri
q_1, q_2	: Uyarlamalı sinirsel bulanık mantık sistemi parametreleri
r_1, r_2	: Uyarlamalı sinirsel bulanık mantık sistemi eşik değerleri
s	: Saniye, zaman birimi
t	: YSA'nın iterasyon sayısı
V	: Volt, genlik değeri
w_i	: YSA ve ANFIS'in bağlantı ağırlıkları
w_i^t	: t . iterasyondaki bağlantı ağırlığı
w_i^{t+1}	: $(t + 1)$. iterasyondaki bağlantı ağırlığı
$\bar{w}_i$	: Uyarlamalı sinirsel bulanık mantık sistemi normalize edilmiş üyelik fonksiyonu ağırlıkları
$x \in F$	: Morfolojik dönüşümde F kümesinde tanımlı x elemanı
x_1, x_2	: Uyarlamalı sinirsel bulanık mantık sistemi giriş verileri
x	: Sayısal işaret dizisi
x_i	: YSA ve ANFIS'de giriş verileri
x_i	: Sayısal işaret dizisinin her bir elemanı
$\bar{x}_j$	: Normalize edilmiş sayısal işaret dizisi
x_{rms}	: Sayısal işaretin etkin (rms) değeri
y	: Sinir hücresi çıkışı
YN	: Yanlış negatif
YP	: Yanlış pozitif
$z \in K$	: Morfolojik dönüşümde K kümesinde tanımlı z elemanı

TABLOLAR LİSTESİ

Tablo 2.1. Şekil 2.2’de verilen EEG işaretinin ve alt bandlarının frekans aralıkları ve genlikleri.....	16
Tablo 2.2. Şekil 2.7’de görülen EOG işaretlerinin genlik değerleri.....	19
Tablo 2.3. Bir hastanın uyanık halde, REM ve NREM3 uykusunda EMG işaretinin özellikleri.....	20
Tablo 2.4. Bir hastanın bir zaman dilimindeki solunum işareti ile bu zaman dilimindeki normal solunum ve uyku apnesi zamanlarındaki işaret özellikleri.	23
Tablo 2.5. Bir hastanın bir zaman dilimindeki solunum işareti ile bu zaman dilimindeki normal solunum ve hipopne zamanlarındaki işaret özellikleri.....	23
Tablo 2.6. Bir hastanın bir zaman dilimindeki solunum çabası işareti ile bu zaman dilimindeki normal solunum ve uyku apnesi zamanlarındaki işaret özellikleri.	25
Tablo 2.7. Bir hastanın bir zaman dilimindeki solunum çabası işareti ile bu zaman dilimindeki normal solunum ve hipopne zamanlarındaki işaret özellikleri.	26
Tablo 2.8. Bir hastanın belirli bir zaman dilimindeki oksijen saturasyonu işaretinin, bu zaman dilimindeki normal solunum ve uyku apnesi zamanlarındaki işaret özellikleri.....	28
Tablo 2.9. Bir hastanın belirli bir zaman dilimindeki oksijen saturasyonu işaretinin, bu zaman dilimindeki normal solunum ve hipopne zamanlarındaki işaret özellikleri.....	28
Tablo 4.1. Uyku skoru için YSA’nın eğitiminde kullanılan verilerde hastalara ait AHİ ve epok sayıları.	42
Tablo 4.2. Uyku skorlaması için test grubu hastalara ait AHİ ve epok sayıları.	43
Tablo 4.3. Değerlendirme tablosu.	45
Tablo 4.4. Uyku seviyelerini belirlemek için kullanılan bütün YSA modellerinin Levenberg-Marquardt ile eğitilmesi durumunda hesaplanan öğrenme ve test başarıları.....	47
Tablo 4.5. Birinci grup denemelerde en iyi başarı ortalamasını veren YSA modeli diğer 11 farklı öğrenme algoritması ile eğitildiğinde elde edilen ortalama test başarıları.....	48

Tablo 4.6. Öğrenme algoritmalarının ortalama test başarıları.....	49
Tablo 4.7. Eğitim grubu hastalara ait verilerin uyku skorlaması başarı ortalamaları....	50
Tablo 4.8. Test grubu hastalara ait verilerin uyku skorlaması başarı ortalamaları.....	52
Tablo 4.9. Literatürde yapılan araştırmalara göre uyku seviyelerinin skorlanması için yapılan çalışmalarda elde edilen başarı oranları.	53
Tablo 4.10. Skorlama algoritması ile yapılan uyku apnesi skorlamasının başarı oranları.	58
Tablo 4.11. Levenberg-Marquardt öğrenme algoritması kullanılarak seçilen en iyi YSA modelinin farklı öğrenme algoritmaları ile eğitilmesi durumunda elde edilen ortalama test başarıları.	63
Tablo 4.12. Levenberg-Marquardt algoritması ile eğitilen YSA ile bulunan uyku apnesi skorlamasının başarı oranları.	64
Tablo 4.13. ANFIS ile yapılan uyku apnesi skorlamasında elde edilen başarı oranları..	69
Tablo 4.14. Bu tez çalışmasında ve literatürde yapılan araştırmalara göre uyku apnesinin skorlanması için yapılan çalışmalar, kullanılan yöntemler ve başarı oranları.	72

ŞEKİLLER LİSTESİ

Şekil 2.1.	AASM kurallarına göre EEG problemlerinin yerleştirilmesi için (a) tavsiye edilen ve (b) kabul edilebilir ölçüm noktaları.	13
Şekil 2.2.	Uyanık haldeki bir kişinin (a) EEG işareti ve (b) EEG işaretinin frekans spektrumu.	13
Şekil 2.3.	Uyanık haldeki bir kişinin EEG işaretinin (a) Delta bandı ve (b) Teta bandı.	14
Şekil 2.4.	Uyanık haldeki bir kişinin EEG işaretinin (a) Alfa bandı ve (b) Beta bandı.	14
Şekil 2.5.	Parlak ışıktaki gözlerin açılıp kapanmasının alfa dalgaları üzerindeki etkisi.	15
Şekil 2.6.	Uyanıklık ve uykunun farklı evrelerinde EEG işaretinin karakteristik görüntüsü.	17
Şekil 2.7.	Bir kişinin (a) uyanık halde, (b) REM ve (c) NREM3 uykusu dönemlerinde EOG işaretleri.	18
Şekil 2.8.	Bir hastanın (a) uyanık halde, (b) REM ve (c) NREM3 uykusunda EMG işaretinin görünümü.	20
Şekil 2.9.	Bir hastanın uyku apnesi zaman dilimindeki solunum işareti ve uyku apnesi gösterimi.	22
Şekil 2.10.	Bir hastanın hipopne zaman dilimindeki solunum işareti ve hipopne gösterimi.	22
Şekil 2.11.	Bir hastanın uyku apnesi zaman dilimindeki solunum çabası ve uyku apnesi gösterimi.	24
Şekil 2.12.	Bir hastanın hipopne zaman dilimindeki solunum çabası ve hipopne gösterimi.	25
Şekil 2.13.	Bir hastanın uyku apnesi zaman dilimindeki oksijen saturasyonu ve uyku apnesi gösterimi.	27
Şekil 2.14.	Bir hastanın hipopne zaman dilimindeki oksijen saturasyonu ve hipopne gösterimi.	27
Şekil 3.1.	YSA sinir hücresi modeli (Perceptron).	31
Şekil 3.2.	Üç girişli, üç katmanlı ve iki çıkışlı sinir ağı modeli.	31

Şekil 3.3. Yapay sinir ağlarında kullanılan (a) Simetrik sigmoid, (b) Logaritmik sigmoid, (c) Eşik aktivasyon ve (d) Doğrusal aktivasyon transfer fonksiyonları.....	34
Şekil 3.4. İki girişli ve iki kurallı Sugeno tipi bulanık mantık modelinin örnek üyelik fonksiyonları.....	37
Şekil 3.5. İki girişli ve iki kurallı Sugeno tipi bulanık çıkarıma eşdeğer ANFIS mimarisi.	37
Şekil 4.1. Eğitim için kullanılan verilerden 2 sıra numaralı hastanın uyku hipnogramı.	44
Şekil 4.2. Skorlama algoritması ile yapılan uyku apnesi skarlama. (a) Solunum işareti, (b) Görsel skarlama ve (c) Algoritmik skarlama.	59
Şekil 4.3. YSA ile uyku apnesi skarlama. (a) Solunum İşareti, (b) YSA çıkışı ve (c) Morfolojik filtre çıkışı.	65
Şekil 4.4. YSA ile uyku apnesi skarlama. (a) Görsel skarlama, (b) YSA çıkışının skarlama ve (c) Morfolojik filtre çıkışının skarlama.	66
Şekil 4.5. ANFIS ile uyku apnesi skarlama. (a) Solunum işareti, (b) ANFIS çıkışı ve (c) Morfolojik filtre çıkışı.	70
Şekil 4.6. ANFIS ile uyku apnesi skarlama. (a) Görsel skarlama, (b) ANFIS çıkışının skarlama ve (c) Morfolojik filtre çıkışının skarlama.	71

GİRİŞ

İnsan hayatının en önemli amaçlarından birisi de sağlıklı yaşamaktır. Bu nedenle sağlıklı yaşamak için yapılan çalışmalar her zaman önemli olmuştur. Biyomedikal işaret işleme yöntemlerinin gelişmesi ile bu konuda yapılan çalışmalar yeni bir boyut kazanmıştır. PSG işaretlerinin kaydedilmesi noninvaziv bir yöntemdir. Bu tez çalışmasında PSG işaretlerinin işlenmesi ve uyku apnesi hastalarında teşhis ve tedavi planlaması için uyku ve uyku apnesi skorlaması yapılmıştır.

Tezin birinci bölümünde uyku ve uyku apnesi hakkında genel bilgiler verilmiştir. Ayrıca PSG işaretlerinin ön işleme yöntemleri, işaret özelliklerinin çıkarılması, skorlama yöntemleri, yapılan skorlamaların doğruluğunun test edilmesi konularında yapılan çalışmalar hakkında literatür bilgileri sunulmuştur.

İkinci bölümde her bir uyku seviyesinde PSG işaretlerinin özellikleri, hipopne ve uyku apnesi durumlarında PSG işaretlerinde görülen değişimler gösterilmiştir. Bu değişimler, skorlama kuralları ile değerlendirilerek işaretlerin skorlanmasında kullanılmaktadır.

Üçüncü bölümde yapay sinir ağları ve uyarlamalı sinirsel bulanık mantık sistemi ve bu yöntemlerin uyku ve uyku apnesinin skorlanmasında kullanımı açıklanmıştır. Ayrıca morfolojik işlemler hakkında bilgi verilmiştir.

Dördüncü bölümde PSG işaretleri kullanılarak YSA ile uyku skorlaması yapılmıştır. Farklı YSA modelleri ve farklı öğrenme yöntemleri ile denemeler yapılmış ve bu denemelerin sonuçları açıklanmıştır. Uyku apnesi ise görsel skorlama kuralları ile uyumlu bir skorlama algoritması, YSA ve ANFIS kullanılarak skorlanmış ve her bir skorlama yönteminin sonuçları ayrı ayrı verilmiştir.

Beşinci bölümde yapılan bütün skorlama çalışmaları değerlendirilmiştir.

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR ARAŞTIRMASI

1.1. Giriş

Bu bölümde uyku, uyku apnesi ve PSG işaretleri hakkında genel ve tanımlayıcı bilgiler verilmiştir. Ayrıca uyku ve uyku apnesinin skorlanması için kullanılan işaretler, önizleme, işaret özelliklerinin çıkarılması, skorlama yöntemleri ve doğruluk testleri hakkında literatür özeti sunulmuştur.

1.2. Uyku Fizyolojisi

İnsanın bir günlük yaşam döngüsü uyanıklık ve uyku hali olarak isimlendirilir [1]. Kişi, uyanıklık halinde etrafında olan olayların farkında iken uyku esnasında bu olayların farkında değildir. Uyku, kişinin ses, ışık ve benzeri fiziki uyarılarla uyanabileceği bir bilinçsizlik durumu olarak tanımlanmaktadır [2]. Uyku, sağlıklı bir yetişkin için ortalama 7-8 saattir. Uyku, bir bütün zaman dilimi olmayıp, birbirini izleyen iki farklı dönemden oluşur. Uykunun birinci döneminde beyin dalgaları çok yavaşlamaktadır. Bu döneme yavaş dalga uykusu (NREM uykusu) denir. Uykunun ikinci döneminde ise gözlerde hızlı hareketler oluşmaktadır. Bu döneme hızlı göz hareketi uykusu (REM uykusu) denir.

Gece uykusunun büyük bir kısmı yavaş dalga uykusu tipinde geçer. Bu uyku, saatler süren uyanıklık sonrası uykunun ilk saatlerindeki derin ve dinlendirici tipteki bölümüdür. Bu dönemde vücut hareketleri azalmış ve vücut kasları gevşemiş olduğundan sakin bir uyku dönemidir. Kan basıncı, metabolizma ve solunum hızında %10 ile %30 arasında azalma görülür [2].

Normal bir gecede 5 ile 30 dakika arasında değişen REM uykusu dönemleri, uyku boyunca periyodik olarak ortaya çıkar. REM uykusu dönemleri yetişkinlerde uyku süresinin %20'si ile %25'i arasındadır ve ortalama 90 dakikada bir tekrarlanır [1, 2]. Bu uyku dönemi sakin bir dönem değil, insan beyninin aktif olduğu bir dönemdir. Kişi çok

uykulu ise, REM uyku dilimlerinin süreleri kısalır hatta ortadan kalkar. Diğer taraftan, kişi gece boyunca gittikçe daha fazla dinlenmiş olacağından REM uykusunun dilimleri giderek uzar. Beyin REM uykusu döneminde yüksek bir etkinliğe sahip olduğundan, beyin metabolizmasında %20 oranında artma gözlenir. Bu dönemde kaydedilen EEG dalgaları, uyanık kişinin EEG dalgalarına benzer [2].

1.3. Uyku Apnesi

Günlük hayatın önemli bir parçası olan uyku, bir dinlenme ve yenilenme zamanıdır. Ancak zamanla vücudu yıpranan ve sağlığı bozulan insanların uyku esnasında dinlenmeleri zorlaşmakta hatta dinlenememektedirler. Bu durumun önemli sebeplerinden birisi de bazı kişilerde uyku esnasında görülen nörolojik aktivite bozukluklarına veya boğazda bulunan kaslarının gevşemesine bağlı olarak solunumun ya azalması ya da tamamen durmasıdır. Solunumun en az 10 saniye boyunca en az %70 azalması hipopne, en az %90 azalması veya durması ise uyku apnesi olarak tanımlanmaktadır [3]. Uyku apnesinin meydana geliş şekline göre üç farklı türü vardır [3-7].

Tıkalı uyku apnesi (TUA, Obstructive Sleep Apnea, OSA): En çok görülen ve üst solunum yollarının gevşemesinden kaynaklanan bu uyku apnesi tipinde, solunumun tamamen durmasına rağmen göğüs hareketlerinde solunum çabası görülmektedir.

Merkezi uyku apnesi (Central Sleep Apnea, CSA): Uyku apnesinin merkezi sinir sisteminden kaynaklanan bu tipinde solunumun tamamen durmasına rağmen solunum çabası yoktur.

Karmaşık uyku apnesi (Complex Sleep Apnea): Bu uyku apnesi, tıkalı uyku apnesinin ve merkezi uyku apnesinin bir arada görüldüğü durumdur. Bu uyku apnesi, merkezi uyku apnesi gibi görülür. Ancak solunum çabasının yokluğu, kısa zaman aralıkları ile yerini solunum çabasına bırakır [3-7].

Bir saat zaman diliminde ortalama uyku apnesinin sayısı Apne Hipopne İndeksi (AHI) olarak tanımlanır. Uyku apnesi skorlaması yapılan hastalar AHI'ne göre sınıflandırılır.

Bu sınıflandırmaya göre:

- a) Eğer $AHI < 5$ ise bu durum normaldir ve bu kişi uyku apnesi hastası değildir.
- b) Eğer $5 \leq AHI < 15$ ise hasta hafif seviyede uyku apnesidir.
- c) Eğer $15 \leq AHI < 30$ ise hasta orta seviyede uyku apnesidir.
- d) Eğer $AHI \geq 30$ ise hasta ağır seviyede uyku apnesi hastasıdır.

Doksandan fazla uyku bozukluğu olmasına rağmen bunların arasında en yaygın olanı uyku apnesidir [4]. Uyku apnesi üst solunum yolunda görülen ve insan sağlığını tehdit eden ciddi bir hastalıktır. Bu hastalık tedavi edilmezse başta kalp ve dolaşım sistemleri olmak üzere bütün insan vücudu için tehlikeli olmaktadır [3].

Uyku apnesinin teşhisi, hasta şikayetleri ve hasta yakınlarının gözlemleri ile tam donanımlı uyku laboratuvarı bulunan hastanelerde yapılmaktadır [3]. Hastadan alınan PSG işaretleri bir tıbbi uzman tarafından skorlanarak AHI hesaplanmaktadır. Bu incelemenin sonucuna göre hipopne veya uyku apnesi teşhisi konulursa ya tedavi planlanmakta ya da uyku esnasında solunuma yardımcı olmak için devamlı pozitif havayolu basıncı (Continuous Positive Airway Pressure, CPAP) cihazı önerilmektedir.

1.4. Polisomnografi İşaretleri

Uyku ve uyku apnesi ile ilgili çalışmaların birçoğu esasında sayısal hale dönüştürülen biyolojik işaretler ile yapılan işaret işleme çalışmalarıdır. Hastadan alınan biyolojik işaretler PSG cihazı ile kaydedilmektedir. Ortalama sekiz saatlik gece uykusunu hastane laboratuvarında geçiren hastadan, PSG cihazı ile 21 adet biyolojik işaret kaydedilmekte olup bu işaretlere PSG işaretleri denilmektedir. PSG cihazı ile EEG, EMG, EOG, elektrokardiyogram (EKG, electrocardiogram, ECG), solunum basıncı, solunum çabası, oksijen saturasyonu, sıcaklık ve vücut hareketleri ile ilgili biyolojik işaretler kaydedilmektedir. PSG işaretleri, uyku skorlamasında, apne/hipopne skorlamasında, huzursuz bacak sendromu ve benzeri uyku hastalıklarının teşhisinde kullanılmaktadır.

PSG işaretleri birçok biyolojik işaretten oluşur. Bu işaretlerin işlenmesi ile uyku [8], uyku apnesi [9, 10, 11], K-Kompleksi [12] ve uyku içciklerinin (sleep spindle) skorlanması [13, 14], kalp atış hızı değişkenliğinin (KAHD, Heart Rate Variability, HRV) hesaplanması [15] gibi çalışmalar yapılmıştır.

1.5. Uyku Skorlama İle İlgili Yapılan Çalışmalar

PSG işaretleri ile uyku skorlama kuralları Amerikan Uyku Tıbbı Akademisi (American Academy of Sleep Medicine, AASM) tarafından belirlenmiştir [16, 17, 18]. Uyku skorlaması için yapılan çalışmalarda uyku seviyelerinin en temel belirleyicisi olan EEG işareti kullanılırken [19-24] bazı çalışmalarda EEG ve solunum işareti birlikte kullanılmıştır [21]. Uyku apnesi hastalarında uyku skorlaması için yapılan diğer bir çalışmada ise fotopletizmografiden (photoplethysmography, PPG) elde edilen KAHD kullanılmıştır [25].

Uyku skorlanması için kullanılan işaretlerde görülen artefaktlarının giderilmesi, istenmeyen frekansların ve sabit eğilimlerin temizlenmesi için sayısal filtreleme, regresyon, dalgacık dönüşümü (DD, Wavelet Transform, WT), kör kaynak ayırıştırma (Blind Source Separation, BSS) ve hareketli ortalama (Moving Average, MA) gibi bir dizi ön işlem kullanılmıştır [22, 25]. Ayrıca işaretler, zaman ve frekans özelliklerini elde etmek amacıyla DD veya ayarlanabilir Q faktörlü dalgacık dönüşümü (Tunable-Q Factor Wavelet Transform, TQWT) gibi yöntemlerle alt bandlarına ayrılmıştır [19, 20].

Uyku skorlama, uyku esnasında kaydedilen EEG işaretinin özelliklerinin yaklaşık sabit kaldığı zaman dilimlerine ayrılarak işaretlenmesidir. Biyolojik işaretlerin kullanılma şekline göre ya bütün frekans bandının ya da alt bandlarına ayrılarak her bir frekans bandının ortalama (mean), etkin değer (rms), enerji, güç, varyans (variance), standart sapma, çarpıklık (skewness), basıklık (kurtosis) ve orta değer (median) gibi zaman ve frekans özellikleri hesaplanır. Bu özellikler kullanılarak destek vektör makineleri (Support Vector Machines, SVM) [22, 25], çok sınıflı destek vektör makineleri (Multiclass Support Vector Machines, MC-SVM) [21], çok sınıflı en küçük kareler destek vektör makineleri (Multiclass Least Squares Support Vector Machines, MC-LS-SVM) [19], K-En Yakın Komşuluk Algoritması (K-Nearest Neighbor Classification Algorithm, KNN) [22, 25], doğrusal diskriminant analizi (Linear Discriminant Analysis, LDA) [22], adaptif destekleme (adaptive boosting) [20, 26] ve YSA [22-24] gibi yöntemler ile uyku skorlaması yapılmıştır.

Yapılan uyku skorlamasının başarısını göstermek için hassasiyet, seçicilik, pozitif tahmin değeri, negatif tahmin değeri, doğruluk (overall accuracy) ve f-skor gibi testler yapılmıştır. Uyku skorlama çalışmalarında, kullanılan biyolojik işaretlere ve

sınıflandırma yöntemlerine göre %70 ile %90 arasında değişen doğruluk oranları elde edilmiştir [19-25].

1.6. Uyku Apnesi Skorlama İle İlgili Yapılan Çalışmalar

PSG işaretleri kullanılarak görsel skorlama yöntemleri ile uykuda solunum bozukluklarının tanısının konulması altın standarttır [3]. Uyku apnesinin skorlanması için PSG işaretlerinin bütünü bir uzman tarafından görsel olarak incelenir.

Uyku apnesinin otomatik olarak skorlanması için yapılan çalışmalarda ya PSG işaretleri [4, 6, 7, 27-29] ya da tek kanal işaretler kullanılmıştır [26, 30, 31-48]. Solunum ve oksijen saturasyonu işaretleri, uyku apnesinin en belirleyici işaretleridir. Tek kanal işaret ile uyku apnesi skorlama çalışmalarında çoğunlukla ya solunum işareti ya da solunum işareti ve oksijen saturasyonu birlikte kullanılmıştır [30, 40]. Uyku apnesi esnasında solunum azaldığından veya durduğundan kanda oksijen saturasyonu azalmaktadır. Kandaki oksijen saturasyonunu kontrol ederek uyku apnesi hakkında tahminde bulunulabilir. Yapılan çalışmalarda, sadece oksijen saturasyonunun %3 azalması (3% Oxygen Desaturation Index, ODI3) uyku apnesi olarak değerlendirilmektedir [26, 45-48]. Solunum ve EEG işaretleri ile ilgili bir çalışmada, bu iki işaret arasında anlamlı istatistiki bağlantı bulunmuş ancak bağlantı fizyolojisi tam anlaşılamamıştır [49].

Tıkalı uyku apnesi esnasında hastada solunum çabası artmaktadır. Bunun sonucu olarak solunum ile ilgili göğüs ve karın hareketlerine bakılarak uyku apnesi skorlaması yapılabilmektedir [41, 42]. Aynı şekilde solunum çabası başladığından, hastanın solunum sesleri de skorlama için kullanılmıştır [43, 44].

Solunumun azalması veya durması halinde, kalbin çalışması etkilenmekte ve EKG işaretlerine yansımaktadır. Normal solunum ve uyku apnesi esnasında EKG işaretleri incelenerek farklar ortaya çıkarılmış ve uyku apnesi skorlama çalışmalarında kullanılmıştır [31-39].

Uyku apnesi, sadece yetişkinlerde değil aynı zamanda çocuklarda da görüldüğünden bu konuda da çalışmalar yapılmıştır [29, 30, 45]. Yetişkin kişiler için yapılan bazı çalışmalarda tek kanal işaret kullanılarak başarılı sonuçlar elde edilmesine rağmen bu yöntemlerin 15 yaş altı çocuklarda yeterince iyi sonuç vermemesi, çocuklar için yeni algoritmaların geliştirilmesini zorunlu kılmıştır [29].

Uyku apnesi ile ilgili yapılan diğer bazı çalışmalar ise ucuz, hasta konforunu artıran, uzaktan erişim sağlayan elektronik cihaz ve algoritma geliştirme çalışmalarıdır [26, 30, 31, 40-42, 44, 46]. Aslında, AASM tarafından yayımlanan raporlarda uyku apnesi hastalığına taşınabilir cihazlar ile teşhis konulması, yeterince çalışma yapılmadığı ve etkinliklerine dair yeterince delil olmadığı gerekçesi ile tavsiye edilmemektedir [46].

Uyku apnesi ile ilgili çalışmalarda, biyolojik işaretler bir ön işleme tabi tutulmakta ve skorlama için hazırlanmaktadır. Ön işlemede biyolojik işaretlerin filtrelenmesi, sabit (DC) değerlerin veya işaret olarak kabul edilemeyecek işaret dilimlerinin çıkarılmasının yanında (artefakt giderme) işaret genliklerinin farklarının azaltılması için normalizasyon işlemleri yapılmaktadır. Daha sonra işaretlerin zaman ve frekans özelliklerine bakmak için Fourier dönüşümü (FD, Fourier Transform, FT) [31, 32, 41, 47], altband kodlama için DD [4, 6, 7, 29, 42] ve TQWT [36, 37], olaylar arasındaki olasılıkları değerlendirmek için Gizli Markov Modeli (Hidden Markov Model, HMM) [33], olasılık dağılımlarını görmek için Normal Ters Gauss Dağılımı (Normal Inverse Gaussian, NIG) [37] ve istatistik analiz [46] yapıldığı görülmüştür.

İşaretler bir ön işleme tabi tutulduktan sonra işaret özellikleri çıkarılır. Skorlamanın başarısı, doğru sınıflandırıcıyı seçmekle birlikte doğru işaret özelliklerinin seçilmesine de bağlıdır. Skorlama işlemlerinde biyolojik işaretlerin genlik, en büyük değer, en küçük değer, ortalama, enerji, varyans, standard sapma, çarpıklık ve basıklık gibi zaman eksenli özellikleri [29, 30, 38, 47, 48], dalgacık katsayıları [7] ve frekans özellikleri [48] kullanılmıştır.

Tek kanal EKG ile uyku apnesi çalışmalarında QRS kompleksinin genliği, enerjisi, R-R aralıklarındaki farklar gibi zaman eksenine ait şekil (morfolojik) özellikleri [31, 34], KAHD [32, 39], EKG işaretinin ortalaması, varyans ve basıklık [38] gibi işaret özellikleri kullanılmıştır [25]. Ayrıca hesaplanan işaret özelliklerinin hangilerinin daha öncelikli ve skorlama işleminde daha ağırlıklı olduğunu belirlemek için SVM gibi yöntemlerin kullanıldığı görülmektedir [4].

Uyku ve uyku apnesi ile ilgili yapılan çalışmalarda nihai işlem işaretlerin skorlanması veya sınıflandırılmasıdır. Biyolojik yapı çok karmaşık bir sistem olduğundan, biyolojik işaretlerin sınıflandırılması için YSA [4, 6, 7, 26-29, 33, 35, 36, 43, 46, 47], HMM [33], SVM [29, 33-35], LDA [34, 44, 48], en küçük kareler destek vektör makineleri

(least-squares support vector machine, LS-SVM) [34], KNN [35, 48], Adaptive Boosting (AdaBoost, makine öğrenme algoritması) [37], Bootstrap Aggregating (Bagging, makine öğrenme algoritması) [38], çok katmanlı özel algoritmik yapılar [42], çoklu doğrusal regresyon (Multiple Linear Regression, MLR) [47] ve lojistik regresyon (Logistic Regression, LR) [29, 30, 48] gibi sınıflandırıcılar kullanılmaktadır. Skorlama başarısını ve doğruluğunu artırmak için bu yapılardan birkaç tanesinin bir arada kullanıldığı çalışmalar da yapılmıştır [29, 33-35, 47, 48].

Yapılan skorlama ve sınıflandırmanın doğruluğunun değerlendirilmesi için doğruluk testinin yapılması gerekmektedir. Bu maksatla altın standart olarak kabul edilen yöntemle yapılan skorlama ve önerilen model ile yapılan skorlama karşılaştırılır. Bu karşılaştırma için doğruluk [4, 6, 7, 27, 28, 31-35, 39, 45], seçicilik, hassasiyet, pozitif tahmin değeri, negatif tahmin değeri [29, 30, 32, 33, 36-38, 40, 43, 44, 48], f-skor [29] ve korelasyon [26, 41, 46, 47] gibi test yöntemleri kullanılmıştır.

1.7. Tezin Amacı

Bu tez çalışmasının amacı PSG işaretleri kullanılarak uyku ve uyku apnesinin skorlanmasıdır. PSG işaretleri Kahramanmaraş Sütçü İmam Üniversitesi Tıp Fakültesi uyku laboratuvarında kaydedilmiştir. Biyolojik işaretlerin değerlendirilerek bir sonuç elde edilmesi için önışleme, işaret işleme, işaret özelliklerinin çıkarılması, skorlanması, sınıflandırılması ve sonuçların değerlendirilmesi gibi birçok işlem sıra ile gerçekleştirilir. Her bir aşama kendi içinde sıralı veya eşzamanlı birçok alt işlem içerebilir.

Hem uyku hem de uyku apnesinin skorlanması, bir tıbbi uzmanın PSG işaretlerini görsel olarak incelemesi ile yapılmaktadır. Görsel skorlama karmaşık, pahalı ve zaman alıcı bir işlemdir [26, 30]. Bu incelemenin bilgisayar algoritmaları ile otomatik olarak yapılması hem yorgunluk ve aşırı uzmanlaşma gibi kişisel zafiyetlerden bağımsız hem çok daha hızlı hem de çok daha ucuz olmaktadır. Bu çalışmada biyolojik işaretlerin önışleme yöntemleri, özelliklerinin çıkarılması, skorlanması ve yapılan skorumanın doğruluk testleri anlatılmış ve PSG işaretleri ile uygulama yapılmıştır.

Gerçek dünyadan alınan biyolojik işaretlerde farklı kaynaklardan gelen gürültüler bulunduğundan işaretlerin önce bu gürültülerden arındırılması gerekmektedir. Bu maksatla ya istenmeyen frekansların temizlenmesi için filtreler kullanılmakta ya da

istatistiki yöntemlerle artefakt giderme işlemi yapılmaktadır. Bu tez çalışmasında her iki yöntemde bir arada kullanılmıştır.

Biyolojik işaretler ya zaman ekseninde ya da frekans ekseninde incelenirler. Bir işaretin zaman ekseninde morfolojik ve istatistik özelliklerine bakılırken, frekans ekseninde işaretin frekans ve güç dağılımlarına bakılmaktadır. İşaretler zaman ekseninde kaydedildiklerinden, morfolojik özelliklerine ve istatistiki dağılımlarına bakılırken herhangi bir dönüşüme gerek yoktur. Fakat frekans özellikleri ve güç dağılımlarının incelenmesinde, işaretin frekans eksenine dönüştürülmesi gerekir. Bu işlem Fourier dönüşümü ile yapılır. Fourier dönüşümü, çok fazla işlem gücü gerektirdiğinden hızlı Fourier dönüşümü (Fast Fourier Transform, FFT) geliştirilmiştir. Bir işaretin zaman ekseninde frekans özelliklerinin görülmesi zordur. Fakat frekans eksenine geçilince de zaman eksenindeki özellikleri kaybolmaktadır. Zaman ve frekans özelliklerini birlikte değerlendirebilmek için kısa zamanlı Fourier dönüşümü (Short Time Fourier Transform, STFT) ve Çok Çözünürlüklü Dalgacık Dönüşümü (ÇÇDD) geliştirilmiştir. Bu tez çalışmasında PSG işaretlerinin hem zaman hem frekans hem de morfolojik özelliklerine bakılmıştır.

Bir biyolojik işaretin zaman eksenindeki ani değeri çoğu durumda önemli değildir. Bu sebeple işaretlerin özelliklerinin yaklaşık sabit kaldığı bir zaman dilimindeki değerlerine bakılır. Bu değerler işaret özellikleri olarak isimlendirilir. İşaret özelliklerinin çıkarılması hem karar mekanizmasını kolaylaştırır hem de işlem yükünü önemli miktarda azaltır. Bu tez çalışmasında işaretin genliği, en büyük değer, en küçük değer, ortalama, standart sapma, etkin değer, işaret enerjisi, işaret gücü ile frekans ve güç dağılımlarına bakılmıştır. Literatürde çok sayıda işaret özelliğinin kullanıldığı görülmektedir [25].

İşaret işleme çalışmalarında en çok yapılan işlemlerden birisi işaretlerin skorlanmasıdır. İşaretlerin skorlanması veya sınıflandırılması için, kurallara dayalı algoritmik yöntemler, istatistik yöntemler veya yapay zekaya dayalı yöntemler kullanılmaktadır. Bu tez çalışmasında uyku skorlamak için YSA, uyku apnesi skorlamak için uzman deneyimine dayanan algoritmik bir yöntem, YSA ve ANFIS kullanılmıştır. Ayrıca YSA ve ANFIS'in çıkışlarında morfolojik işlemlerin kullanılması ile skorlama başarısı artırılmıştır.

Bu tez çalışmasında yapılan uyku ve uyku apnesi skorlama işlemlerinin başarısını göstermek için doğruluk testleri yapılmıştır. Elde edilen sonuçlar ile literatürde daha önce yapılan çalışmaların sonuçları karşılaştırılarak bu çalışmanın güvenilirliği ve doğruluğu gösterilmiştir.



2. BÖLÜM

POLİSOMNOGRAFİ İŞARETLERİ

2.1. Giriş

Uyku ve uyku apnesinin skorlanması için PSG işaretleri kullanılmaktadır. Skorlama yapabilmek için önce uyku ve uyku apnesi esnasında PSG işaretlerinde görülen değişimlerin bilinmesi gerekmektedir. Bu bölümde, bu tez çalışmasında kullanılan PSG işaretlerinin zaman ve frekans özellikleri verilmiş; uyku, uyku apnesi ve hipopne esnasında işaret özellikleri açıklanmıştır.

2.2. Elektroensefelogram İşaretleri

Beynin yüzeyinden veya kafanın dış yüzeyinden kaydedilen elektrik işaretleri, beynin sürekli bir elektriksel aktivite içerisinde olduğunu gösteren önemli bir işarettir. Bu elektriksel aktivitenin yoğunluğu ve deseni uyku, uyanıklık, epilepsi ve hatta çeşitli psikolojik hastalıklar sebebi ile beynin farklı bölümlerinde farklı şekillerde görülür. Kaydedilen elektrik işaretlerindeki dalgalanmalara beyin dalgaları denir ve bütün kayıt EEG olarak isimlendirilir.

Kafa derisinin üzerinden kaydedilen EEG işaretlerinin genliği 0-200 mV arasında ve frekansları ise birkaç saniyede 1'den 50 Hz'e kadar veya daha fazla olabilir. Bir biyolojik işaretin genliği, sıfır noktasına ya da bir referans noktaya göre ölçülen genlik değil, işaretin tepeden tepeye genliğini göstermektedir [17]. EEG dalgalarının karakteristiği, serebral korteksin ilgili bölümlerindeki aktivitenin derecesine bağlıdır.

EEG işaretlerinin işlenmesi ile uyku skorası [18-25]; uyku esnasında görülen K-Kompleksi ve uyku içiği (Sleep Spindle) olarak isimlendirilen geçici EEG bileşenlerinin tespit edilmesi [27]; uyarılma (arousal) olarak isimlendirilen derin uykudan daha hafif uyku evresine veya uyanıklık durumuna ani geçişlerin tespit edilmesi [50]; epilepsi [51, 52] ve benzeri birçok durum tespit edilmektedir. EEG işaretleri kullanılarak


beyin ile dış dünya arasında bağlantı kurma [53], zihni aktiviteleri sınıflandırma [54], anestezi derinliğinin ölçülmesi [55] ve benzeri çalışmalar da yapılmaktadır.

EEG işaretlerinin kaydedilmesi için ölçme problemleri Şekil 2.1’de görüldüğü gibi AASM tarafından belirlenen 10-20 kuralına göre yerleştirilir. Şekil 2.2(a)’da uyanık bir kişinin EEG işareti Şekil 2.2(b)’de ise bu EEG işaretinin frekans spektrumu görülmektedir. Bu hasta uyanık fakat uyumaya hazırlanmaktadır. İşaretin en büyük enerji taşıyan frekansı 0.4 Hz, band genişliği 0.185 Hz’dir.


Beyin dalgaları çoğu zaman düzensiz ve öngörülemez olduğundan EEG işaretlerinde genel bir yapının tanımlanması mümkün değildir [2]. EEG işaretini zaman ekseninde bir bütün olarak değerlendirmek yerine, bu işaret delta, teta, alfa ve beta dalgaları olarak isimlendirilen alt bandlarına ayrılarak incelenir. Bu dalgalar sıra ile Şekil 2.3 ve Şekil 2.4’te gösterilmiştir. Epilepsi ve benzeri durumlarda ise farklı ve duruma özel bazı işaret desenleri görülür.

Delta dalgaları, 3.5 Hz’den daha düşük frekans bandının tamamını içerir. Çok derin uykuda, çocuklukta ve ciddi organik beyin hastalıklarında ortaya çıkarlar. Subkortikal kesiyle korteksi talamustan ayrılan deney hayvanlarının kortekslerinde de oluşurlar. Bu sebeple, delta dalgalarının beynin daha aşağı bölgelerindeki etkinliklerden bağımsız olarak kortekste oluşabildiği bilinmektedir [2]. Şekil 2.2(a)’da verilen EEG işaretinin delta bandı Şekil 2.3(a)’da görülmektedir.


Teta dalgaları, 4-7 Hz arasındaki frekans bandında görülür. Özellikle çocukların paryetal ve temporal bölgelerinde gözlenmekle birlikte, bazı erişkinlerde düş kırıklığı gibi duygusal stresler sırasında ortaya çıkabilirler. Teta dalgaları sıklıkla beynin dejeneratif durumları olmak üzere birçok beyin hastalıklarında da oluşurlar [2]. Şekil 2.2(a)’da verilen EEG işaretinin teta bandı Şekil 2.3(b)’de görülmektedir.




Şekil 2.1. AASM kurallarına göre EEG problemlerinin yerleştirilmesi için (a) tavsiye edilen ve (b) kabul edilebilir ölçüm noktaları [16].



Şekil 2.2. Uyanık haldeki bir kişinin (a) EEG işareti ve (b) EEG işaretinin frekans spektrumu.



Şekil 2.3. Uyanık haldeki bir kişinin EEG işaretinin (a) Delta bandı ve (b) Teta bandı.



Şekil 2.4. Uyanık haldeki bir kişinin EEG işaretinin (a) Alfa bandı ve (b) Beta bandı.

Alfa dalgaları, 8-13 Hz arasındaki frekans bandında görülür, sakin ve sessiz durumdaki uyanık genç ve yetişkinlerin hemen hemen tamamının EEG'sinde bulunurlar. Bu dalgalar frontal (beynin ön bölümü) ve paryetal bölgede (beynin orta bölümü) görülmesine rağmen en güçlü olarak oksipital bölgede (beynin arka bölümü) ölçülür. Gerilimleri genellikle 50 μ V civarındadır. Derin uyku sırasında alfa dalgaları ortadan kalkar. Uyanık durumdaki kişinin dikkati özel tipte bir zihinsel etkinliğe yönlendirildiğinde alfa dalgaları yerini asenkron, yüksek frekanslı ve şiddeti daha düşük beta dalgalarına bırakırlar. Şekil 2.2(a)'da verilen EEG işaretinin alfa bandı Şekil 2.4(a)'da görülmektedir.

Beta Dalgaları, 14-80 Hz arasındaki frekans bandında bulunur. Merkezi sinir sisteminin aktivasyonu fazla olduğu zaman veya gergin hallerde, kafatasının frontal ve paryetal alanlarından kaydedilirler [2]. EEG işaretlerinde 35 Hz'in üzerindeki frekanslarda işaret enerjisi çok azalmaktadır. AASM kurallarına göre yapılan skorlamalarda EEG işaretinin 0.3-35 Hz frekans bandı kullanılmaktadır [16]. Şekil 2.2(a)'da verilen EEG işaretinin beta bandı Şekil 2.4(b)'de görülmektedir.

Gözlerin parlak ışıktaki açılması ve kapanmasının alfa dalgaları üzerindeki etkisi Şekil 2.5'te görülmektedir. Parlak ışıktaki gözler kapalı olduğunda EEG işaretinde alfa dalgaları görülürken, gözlerin açılması durumunda alfa dalgaları yerini beta dalgalarına bırakır. Gözlerin kapanması ile birlikte alfa dalgaları tekrar görülmeye başlar. Görsel uyarılmanın alfa dalgalarını ani olarak durdurduğu ve bunların yerine düşük gerilimli asenkron beta dalgalarının ortaya çıktığı görülmektedir [2].

Şekil 2.2'de verilen EEG işaretinin ve alt bandlarının frekans aralıkları ve genlikleri Tablo 2.1'de verilmiştir. Bu tabloda EEG işaretinin genliği 136.18 μ V iken delta, teta, alfa ve beta bandlarının genlikleri sıra ile 103.71 μ V, 35.18 μ V, 17.21 μ V ve 29.22 μ V



Şekil 2.5. Parlak ışıktaki gözlerin açılıp kapanmasının alfa dalgaları üzerindeki etkisi [2].

Tablo 2.1. Şekil 2.2’de verilen EEG işaretinin ve alt bandlarının frekans aralıkları ve genlikleri.

	Alt Kesim Frekans <i>Hz</i>	Üst Kesim Frekans <i>Hz</i>	En Büyük Değeri $\cdot 10^{-6} V$	En Küçük Değeri $\cdot 10^{-6} V$	İşaretin Genliği $\cdot 10^{-6} V$
EEG	0.30	35.00	75.88	-60.30	136.18
Delta	0.30	3.50	50.93	-52.78	103.71
Teta	4.00	7.00	17.32	-17.79	35.18
Alfa	8.00	13.00	8.61	-8.60	17.21
Beta	14.00	35.00	14.24	-14.98	29.22


olarak ölçülmüştür. Bu değişimlere göre, EEG işaretinin frekansı arttığında genliği azalmaktadır. Beta bandının ise 14-35 Hz aralığında geniş bir band olduğuna dikkat edilmelidir.

2.2.1. Uyanıklık ve Uykunun Farklı Evrelerinde EEG Değişimleri

Bir kişinin, uyanıklık ve uykunun farklı evrelerindeki EEG işareti Şekil 2.6’da verilmiştir. Şekil 2.6 (a) ve (b)’de görüldüğü gibi, dikkatli uyanıklık yüksek frekanslı beta dalgaları ile karakterize iken sakin uyanıklık genellikle alfa dalgaları ile karakterize edilir.

Yavaş dalga uykusu dört evreye ayrılır (Yeni kurallara göre üç evre). Çok yüzeysel bir uyku olan ilk evrede (NREM1), EEG dalgalarının gerilimi çok azalmıştır. EEG dalgaları periyodik olarak oluşan ve uyku iğcikleri olarak adlandırılan, kısa, iğ şeklinde alfa dalgası paketleri ile kesintiye uğramaktadır. Şekil 2.6 (d), (e) ve (f)’de görüldüğü gibi yavaş dalga uykusunun 2., 3. ve 4. evrelerinde (NREM2, NREM3, NREM4) EEG’nin frekansı gittikçe azalarak 4. evrede saniyede sadece 1-3 dalgaya kadar düşmektedir. Bu işaretler tipik delta dalgalarıdır.

Şekil 2.6(c), REM uykusu sırasındaki EEG’yi göstermektedir. Genellikle bu beyin dalgası şekli ile uyanık bir kişinin beyin dalgası arasındaki farkı belirtmek güçtür. Dalgalar, normalde uyanıklıkta gözlemlendiği gibi yüksek ancak desenkronize zihin aktivitesini düşündüren düzensiz, yüksek frekanslı beta dalgalarıdır. Bu nedenle REM uykusu sıklıkla, belirgin beyin etkinliğine karşın nöronların ateşlenmesinde senkroni bulunmadığı için desenkronize uyku olarak adlandırılır [2].



Şekil 2.6. Uyanıklık ve uykunun farklı evrelerinde EEG işaretinin karakteristik görüntüsü [2].

2.3. Elektrookülogram İşaretleri


EOG işareti, retina ve kornea arasındaki potansiyel farkını göstermektedir. Göz, retinanın pozitif, korneanın negatif olduğu bir dipol olarak kabul edilebilir. Bu dipolün hareketi ile göz çevresinde bir potansiyel farkı oluşmaktadır. Bu potansiyel, göz etrafına yerleştirilen bir çift elektrot ile ölçülür. Tek bir gözden EOG işareti kaydedilebilir fakat sağlıklı bir insanda her iki göz birlikte hareket ettiğinden, her iki gözden EOG işaretinin kaydedilmesi daha uygundur. Bu yöntem ile gözün hem dikey hem de yatay hareketi ölçülebilir. EOG işaretinin genliği 50 μ V ile 3.5 mV arasında değişir [56, 57].

EOG işareti, işaret işleme uygulamalarında çoğunlukla uyku seviyelerinin belirlenmesinde kullanılır. Uyku, fizyolojik olarak hızlı göz hareketlerinin olduğu REM (rapid eye movement) ve NREM (nonrapid eye movement) olmak üzere iki seviyeye ayrılır. Ayrıca NREM uykusu yüzeysel uyku olan NREM1 ve NREM2 seviyeleri ile derin uyku olan NREM3 ve NREM4 seviyelerinden oluşur. Yeni skorlama kurallarında

NREM3 ve NREM4 birleştirilerek NREM3 olarak değerlendirilmektedir. Bütün uyku skorlamaları, EEG, OEG ve EMG işaretlerini içeren PSG kayıtlarına dayanmaktadır [21].

EOG işaretlerinin işlenmesi ile önceden tanımlanmış sembollerin göz hareketleri ile yazılması [58], engelli araçlarının kontrolü [59], insan-makine arayüzleri ve teşhis amaçlı kullanmak üzere farklı göz hareketlerinin tespiti [60] mümkündür.

Şekil 2.7’de görülen EOG işaretinin genlik değerleri Tablo 2.2’de verilmiştir. Tablo 2.2’ye göre en büyük işaret genliği uyanık durumda $455.49 \mu\text{V}$, en büyük band genişliği REM uykusunda 0.31 Hz olarak ölçülmüştür.



Şekil 2.7. Bir kişinin (a) uyanık halde, (b) REM ve (c) NREM3 uyku dönemlerinde EOG işaretleri.


Tablo 2.2. Şekil 2.7’de görülen EOG işaretlerinin genlik değerleri.

	En Büyük Değer $\cdot 10^{-6} V$	En Küçük Değer $\cdot 10^{-6} V$	Genlik $\cdot 10^{-6} V$	İşaret Gücü $\cdot 10^{-9} V^2$	Merkez Frekansı Hz	Band Genişliği Hz
Uyanıklık	242.98	-212.51	455.49	10.66	0.50	0.16
REM	20.81	-19.27	40.08	0.03	0.50	0.31
NREM3	47.70	-54.02	101.71	0.42	0.30	0.19

2.4. Elektromiyogram İşaretleri

EMG işaretleri, merkezi sinir sistemi tarafından uyarılan kas dokusunun kasılması esnasında üretilen işaretlerdir. Yüzey EMG işaretleri (The surface electromyogram, sEMG), belirli bir biçimi olmayan, genlik ve frekans içeriğine göre sınıflandırılan bir işaret olup 0-450 Hz frekans bandında bulunur [61].

Kas ve sinir sistemi hastalıkları, kasları uyaran beyin hücreleri (motor neurons), kas ve sinir bağlantı yerleri (neuromuscular junctions) ve kas dokusu ile ilgili hastalıkları ifade eden genel bir terimdir [62]. Kas ve sinir sistemi ile ilgili hastalıkların teşhisi [62] ile dış iskelet robot kontrol uygulamalarında [63] çok kullanılan EMG işaretlerinin analiz ve sınıflandırılması hakkında birçok çalışma yapılmıştır [62-69]. Şekil 2.8’de görülen EMG işaretinin özellikleri Tablo 2.3’te gösterilmiştir. Tablo 2.3’e göre işaret genliği uyanıklık durumunda, REM ve NREM3 dönemlerinde sırası ile 126.50 μV , 38.17 μV ve 52.78 μV olarak ölçülmüştür. Bu tabloya göre işaret genliği ve işaret gücü uyanıklık ve uyku durumu arasında önemli oranda değişiklik göstermektedir.



Şekil 2.8. Bir hastanın (a) uyanık halde, (b) REM ve (c) NREM3 uykusunda EMG işaretinin görünümü.

Tablo 2.3. Bir hastanın uyanık halde, REM ve NREM3 uykusunda EMG işaretinin özellikleri.


	En Büyük Değer $\cdot 10^{-6} V$	En Küçük Değer $\cdot 10^{-6} V$	Genlik $\cdot 10^{-6} V$	İşaret Gücü $\cdot 10^{-12} V^2$	Merkez Frekansı Hz	Band Genişliği Hz
Uyanıklık	55.10	-71.40	126.50	175.00	47.68	38.49
REM	20.31	-17.86	38.17	12.36	47.88	8.61
NREM3	28.96	-23.82	52.78	28.55	54.67	39.39

EMG işaretlerinin özelliklerini çıkarmak için dalgacık analizi [62, 66, 68, 69], Tekil Spektrum Analizi (Singular Spectrum Analysis, SSA) [61], Ampirik Mod Ayırma (Empirical Mode Decomposition, EMD) [64], STFT [65] ve güç spektrumu [67] kullanılmıştır. EMG işaretlerin sınıflandırılması için uyarlamalı sinirsel bulanık mantık sistemi [62, 67] ve SVM gibi sınıflandırıcılar [65] kullanılmaktadır.


2.5. Solunum Basıncı İşaretleri

Solunum, dokulara oksijen sağlamak ve dokularda oluşan karbondioksiti uzaklaştırmak için akciğer ve atmosfer arasında gerçekleşen fizyolojik bir olaydır [70]. Hastanın solunum değişkenlerine karşılık gelen bilgilerinin analiz edilmesi ile apne veya hipopne gibi olası hastalıkların tespit edilmesi mümkündür [27]. Üst solunum yollarında görülen sürekli ve iki yönlü hava akışı, sıcaklık bilgisi, arteriyel kanda ölçülen oksijen saturasyonu (SaO_2) ile hem karın hem de göğüs bölgesinde görülen solunum çabası, solunum değişkenleri olarak kullanılmaktadır [27, 30]. Solunum basıncı ve sıcaklık bilgisi burun kanülü; kandaki oksijen saturasyonu parmak, alın veya kulak memesine yerleştirilen oksimetre; solunum çabası karın ve göğüs bölgesine yerleştirilen bandlar ile alınmaktadır. Bütün bu bilgiler solunum değişkenleri, solunum basıncı ise solunum işareti olarak değerlendirilmektedir [28].

Bir hastanın uyku apnesi zaman dilimlerindeki solunum işareti Şekil 2.9'da verilmiştir. Şekildeki gösteriminde "1" seviyesi normal solunum, "0" seviyesi uyku apnesi veya hipopne olan zaman dilimlerini göstermektedir. Normal solunum zamanında işaret genliğinin büyük, uyku apnesi zamanında ise çok azaldığı veya tamamen kaybolduğu görülmektedir. Şekil 2.10'da ise hipopne zamanındaki solunum işareti gösterilmiştir. Hipopne zamanında işaret genlik ve güçlerinin önemli oranda azaldığı görülmektedir. Ancak hipopne zamanında kısmen de olsa solunum devam ettiğinden işaret genliği uyku apnesinde olduğu kadar azalmamaktadır.



Şekil 2.9. Bir hastanın uyku apnesi zaman dilimindeki solunum işareti ve uyku apnesi gösterimi.



Şekil 2.10. Bir hastanın hipopne zaman dilimindeki solunum işareti ve hipopne gösterimi.

Bir hastanın uyku apnesi durumunda solunum işareti özellikleri Tablo 2.4'te verilmiştir. Bu tabloda normal solunum zamanında işaret genliği $262.72 \mu V$ olarak görülürken uyku apnesi durumunda işaret genliği $10.31 \mu V$ olarak ölçülmüştür. İşaret gücünde de aynı farklar vardır. İşaret genlikleri ve güçleri arasındaki bu farklar işaretler için belirleyici bir özelliktir ve skorlama için kullanılmaktadır. Aynı hastanın hipopne durumunda işaret özellikleri Tablo 2.5'te verilmiştir. Normal solunum zamanında işaret genliği $266.45 \mu V$ olarak görülürken hipopne durumunda işaret genliği $139.43 \mu V$ olarak ölçülmüştür.

Tablo 2.4. Bir hastanın bir zaman dilimindeki solunum işareti ile bu zaman dilimindeki normal solunum ve uyku apnesi zamanlarındaki işaret özellikleri.

	Zaman s	İşaret Ortalaması $\cdot 10^{-6} V$	Standart Sapma $\cdot 10^{-6}$	En Küçük Değer $\cdot 10^{-6} V$	En Büyük Değer $\cdot 10^{-6} V$	İşaret Genliği $\cdot 10^{-6} V$	İşaret Gücü $\cdot 10^{-12} V^2$
Bütün İşaret	247.05	-0.05	17.88	-134.91	127.80	262.72	319.72
Normal Solunum	108.14	-0.39	26.96	-134.91	127.80	262.72	726.79
Uyku Apnesi	138.97	0.21	1.66	-7.47	2.85	10.31	2.81

Tablo 2.5. Bir hastanın bir zaman dilimindeki solunum işareti ile bu zaman dilimindeki normal solunum ve hipopne zamanlarındaki işaret özellikleri.

	Zaman s	İşaret Ortalaması $\cdot 10^{-6} V$	Standart Sapma $\cdot 10^{-6}$	En Küçük Değer $\cdot 10^{-6} V$	En Büyük Değer $\cdot 10^{-6} V$	İşaret Genliği $\cdot 10^{-6} V$	İşaret Gücü $\cdot 10^{-12} V^2$
Bütün İşaret	237.01	0.08	12.34	-108.37	172.01	280.38	152.18
Normal Solunum	54.03	0.63	23.75	-94.44	172.01	266.45	564.19
Hipopne	183.02	-0.09	5.53	-108.37	31.05	139.43	30.55

Solunum hipopne durumunda kısmen devam ettiği için işaret genlik farkları uyku apnesine göre daha azdır.

2.6. Solunum Çabası İşaretleri


Solunum esnasında akciğere hava dolmakta ve göğüs genişlemekte, solunumdan sonra ise tekrar eski haline gelmektedir. Göğüs genişliği solunum ile ilişkili olup solunumun seyri hakkında bilgi vermektedir. Tıkayıcı uyku apnesinde solunum kesilmekte fakat solunum çabası devam etmektedir. Merkezi uyku apnesi durumunda solunum durmakta fakat solunum çabası görülmemektedir. Bu iki husus dikkate alınarak uyku apnesinin tipi belirlenmektedir.

PSG işaretleri kaydedilirken göğse yerleştirilen bir sensör band ile göğüs hareketleri ölçülmekte ve kaydedilmektedir. Bu ölçüm solunum çabası olarak değerlendirilmektedir. Bir hastanın uyku apnesi ve hipopne zamanlarındaki solunum çabaları sıra ile Şekil 2.11 ve Şekil 2.12’de verilmiştir.


Solunum basıncı ve solunum çabası işaretlerinin birbiri ile uyumlu olması beklendiğinden, Şekil 2.9 ve Şekil 2.11 ile Şekil 2.10 ve Şekil 2.12 görsel olarak birbirleri ile uyumludur. Bu şekillerde normal solunum zamanında işaret genliği büyük, hipopne zamanlarında işaret genliği önemli oranda azalmış, uyku apnesi zamanlarında ise işaret genliği ya çok azalmış ya da solunum tamamen durmuştur.

Tablo 2.6’da bir hastanın uyku apnesi durumunda solunum çabası işaret özellikleri verilmiştir. Bu tabloda 0.66 mV olan işaret genliği uyku apnesi zamanında 0.23 mV olarak ölçülmüştür. Normal solunumda işaret genliğinin ve gücünün büyük olmasına rağmen uyku apnesi olması durumunda bu değerler küçülmektedir. Tablo 2.7’de ise aynı hastanın hipopne durumunda solunum çabası işaret özellikleri verilmiştir. Normal solunum zamanında 1.2 mV olan işaret genliği hipopne zamanında 0.25 mV olarak ölçülmüştür.

Uyku apnesi durumunda solunum çabasında görülen değişimler hipopne durumunda da görülmektedir. İşaret genlik ve güç oranları normal solunumda yüksek, uyku apnesi veya hipopne durumunda ise daha düşüktür.



Şekil 2.11. Bir hastanın uyku apnesi zaman dilimindeki solunum çabası ve uyku apnesi gösterimi.



Şekil 2.12. Bir hastanın hipopne zaman dilimindeki solunum çabası ve hipopne gösterimi.

Tablo 2.6. Bir hastanın bir zaman dilimindeki solunum çabası işareti ile bu zaman dilimindeki normal solunum ve uyku apnesi zamanlarındaki işaret özellikleri.

	Zaman s	İşaret Ortalaması $\cdot 10^{-6} V$	Standart Sapma $\cdot 10^{-6}$	En Küçük Değer $\cdot 10^{-3} V$	En Büyük Değer $\cdot 10^{-3} V$	İşaret Genliği $\cdot 10^{-3} V$	İşaret Gücü $\cdot 10^{-9}$
Bütün İşaret	247.06	-0.01	84.61	-0.36	0.31	0.66	7.16
Normal Solunum	108.20	0.81	124.39	-0.36	0.31	0.66	15.47
Uyku Apnesi	139.02	-0.68	26.13	-0.14	0.09	0.23	0.68

2.7. Oksijen Saturasyonu İşaretleri

Solunumun amacı, dokulardaki karbondioksiti uzaklaştırmak ve dokulara oksijen sağlamaktır. Bu sebeple solunum ve kandaki oksijen saturasyonu arasında bir bağlantı vardır. Normal solunum devam ettiği müddetçe kandaki oksijen saturasyonu da belirli değerler arasında kalmaktadır. Uyku apnesi başladığında kandaki oksijen saturasyonu da azalmaya başlamakta, solunum başlaması ile tekrar yükselmektedir. Fakat uyku apnesinin başlaması ile ölçülen oksijen saturasyonu hemen azalmamakta, solunumun başlaması


Tablo 2.7. Bir hastanın bir zaman dilimindeki solunum çabası işareti ile bu zaman dilimindeki normal solunum ve hipopne zamanlarındaki işaret özellikleri.

	Zaman s	İşaret Ortalaması $\cdot 10^{-6} V$	Standart Sapma $\cdot 10^{-6}$	En Küçük Değer $\cdot 10^{-3} V$	En Büyük Değer $\cdot 10^{-3} V$	İşaret Genliği $\cdot 10^{-3} V$	İşaret Gücü $\cdot 10^{-9}$
Bütün İşaret	237.02	0.20	87.69	-0.61	0.59	1.20	7.69
Normal Solunum	54.10	-3.98	171.69	-0.61	0.59	1.20	29.48
Hipopne	183.08	1.43	35.24	-0.08	0.17	0.25	1.24


ile de hemen yükselmemektedir. Solunum ve oksijen saturasyonu arasında bir zaman gecikmesi olmaktadır.

Uyku apnesi ve hipopne durumunda oksijen saturasyonunun değişimi Şekil 2.13 ve Şekil 2.14'te gösterilmiştir. Bu iki şekilde de solunum ve oksijen saturasyonu arasındaki zaman gecikmesi çok rahat görülmektedir. Uyku apnesinde solunum kesintili olarak devam ettiğinden oksijen saturasyonunda da bu dalgalanmalar görülmektedir. Uyku apnesi başladıktan sonra bile ölçülen oksijen saturasyonu artmaya devam etmekte, yaklaşık 20 saniye sonra azalmaya başlamaktadır. Solunumun tekrar başlamasından sonra azalmaya devam etmekte, 20 - 30 saniye sonra yükselmeye başlamaktadır. Bu farkın, büyük oranda akciğerde oksijen ile karbondioksit değişimi ve akciğer ile ölçme noktası arasındaki zaman gecikmesinden kaynaklandığı düşünülmektedir.

Tablo 2.8'de bir hastanın oksijen saturasyonu işaretinin normal solunum ve uyku apnesi zamanlarındaki genlik değerleri verilmiştir. Tablo 2.8'e göre normal solunum zamanında 11 nV olan işaret genliği uyku apnesi zamanında 14.01 nV olarak ölçülmüştür. Tablo 2.9'da ise aynı hastanın normal solunumda 4.98 nV olan işaret genliği hipopne durumunda 7.99 nV olarak ölçülmüştür. Uyku apnesi ve hipopne gösterimi ile eşzamanlı olarak verilen bu ölçümler otomatik skorlamada zorluk çıkaracaktır. Doğru bir skorlama yapmak için zaman gecikmesi dikkate alınmalıdır.



Şekil 2.13. Bir hastanın uyku apnesi zaman dilimindeki oksijen saturasyonu ve uyku apnesi gösterimi.



Şekil 2.14. Bir hastanın hipopne zaman dilimindeki oksijen saturasyonu ve hipopne gösterimi.

Hem uyku apnesi hem de hipopne skorlamalarında oksijen saturasyonunda azalma olup olmadığına bakılır. Oksijen saturasyonunun %3 azalması (ODI3) uyku apnesi olarak kabul edilmektedir [30]. Literatürde ODI2, ODI3 ve ODI4 ile çalışmalar yapılmıştır [45, 46, 48]. Oksijen saturasyonu yavaş değişen bir işaret olduğu için örnekleme frekansının 10 Hz olarak seçilmesi yeterli olmaktadır.

Tablo 2.8. Bir hastanın belirli bir zaman dilimindeki oksijen saturasyonu işaretinin, bu zaman dilimindeki normal solunum ve uyku apnesi zamanlarındaki işaret özellikleri.

	Zaman s	İşaret Ortalaması $\cdot 10^{-12} V$	Standart Sapma $\cdot 10^{-9}$	En Küçük Değer $\cdot 10^{-9} V$	En Büyük Değer $\cdot 10^{-9} V$	İşaret Genliği $\cdot 10^{-9} V$	İşaret Gücü $\cdot 10^{-18} V^2$
Bütün İşaret	247.10	-100.10	3.85	-7.72	6.28	14.01	14.82
Normal Solunum	108.40	-945.66	2.87	-5.72	5.27	11.00	9.13
Uyku Apnesi	139.20	561.13	4.35	-7.72	6.28	14.01	19.26

Tablo 2.9. Bir hastanın belirli bir zaman dilimindeki oksijen saturasyonu işaretinin, bu zaman dilimindeki normal solunum ve hipopne zamanlarındaki işaret özellikleri.

	Zaman s	İşaret Ortalaması $\cdot 10^{-12} V$	Standart Sapma $\cdot 10^{-9}$	En Küçük Değer $\cdot 10^{-9} V$	En Büyük Değer $\cdot 10^{-9} V$	İşaret Genliği $\cdot 10^{-9} V$	İşaret Gücü $\cdot 10^{-18} V^2$
Bütün İşaret	237,10	2306,61	2,11	-1,01	6,97	7,99	9,76
Normal Solunum	54,50	916,27	1,20	-1,01	3,97	4,98	2,28
Hipopne	183,40	2714,02	2,14	-1,01	6,97	7,99	11,95

3. BÖLÜM

UYKU VE UYKU APNESİ SKORLAMA YÖNTEMLERİ

3.1. Giriş

Bu bölümde uyku ve uyku apnesi skorlamak için kullanılan yöntemler hakkında bilgiler verilmiştir. Algoritmik yöntemler uzman görüşüne dayanan, girişi ile çıkışı arasındaki bağlantı tam olarak bilinen sistemlerin modellenmesinde kullanılan yöntemlerdir. YSA ve ANFIS ise girişi ve çıkışı arasındaki bağlantının tam olarak bilinmediği sistemlerin modellenmesinde kullanılan başarılı yöntemlerdir. Morfolojik filtreler zaman ekseninde işaretin biçimini kullanım amacı doğrultusunda iyileştiren özel filtre algoritmaları olup YSA ve ANFIS çıkışlarında skorlama başarısını artırmak için kullanılmıştır.

3.2. Algoritmik Yöntemler

Uyku apnesinin uzman görüşlerine göre oluşturulan kurallar ile otomatik olarak skorlanmasına algoritmik skorlama denir. Kuralların doğruluğu skorlama başarısını doğrudan etkilemektedir. Uyku apnesi skorlama kuralları AASM tarafından belirlenmiştir [4, 16]. Bu kurallara göre bir zaman diliminin uyku apnesi olarak skorlanabilmesi için belirlenen üç kuralın aynı anda gerçekleşmesi gerekmektedir. Bu üç kural aşağıda verilen denklemler ile ifade edilir.

$$\text{Kural 1: Solunum zamanının en az 10 saniye sürmesi} \quad (3.1)$$

$$\text{Kural 2: Bu solunum zamanında hava akımının} \\ \text{en az \%90 oranında azalması} \quad (3.2)$$

$$\text{Kural 3: Bu solunum zamanının} \\ \text{en az \%90'ında hava akımının azalması} \quad (3.3)$$

1. *Kural* kolaylıkla kontrol edilebilir. Ancak 2. ve 3. *Kural*'ların nasıl gerçekleştirileceği açık değildir. Solunum işaretinin uyku apnesini gösteren belirli bir eşik değeri olursa buna göre skorlama yapmak kolaydır. Ancak işaret genliği hastaların fizik ve fizyolojik

özelliklerine göre değiştiğinden belirli bir eşik değerinin kullanılması iyi bir çözüm olmayacaktır.

Bu hususta bir başka problemde gece boyunca hastalardan alınan fizyolojik işaret genliklerinde değişimler ve seviye kaymaları olmaktadır. Tıbbi uzmanlar bu değişimleri görmekte ve buna göre skorlama yapmaktadır. Bilgisayar algoritmalarının bu değişimleri kendiliğinden görmeleri mümkün değildir. Skorlama algoritmalarına bu değişimleri sezecek ve buna göre davranış belirleyecek yeni kuralların eklenmesi ve daha önceden belirlenen eşik değerlerinin sürekli güncellenmesi gerekmektedir.

Her ne kadar kurallar belirli olsa da bu kurallara göre bir algoritma geliştirmek kolay değildir. Burada tıbbi uzman görüşü ve algoritmanın gerçekleştirilme biçimi skorlama başarısı üzerinde etkilidir.

3.3. Yapay Sinir Ağları

Klasik problemler analitik olarak çözülebilirken günümüzde ortaya çıkan birçok problem için bu çözümler yetersiz kalmaktadır. Karmaşık problemlerin çözümünde çoğu olasılık ve istatistik teorilerine dayanan optimizasyon ve sınıflandırma yöntemleri geliştirilmiştir. Bu yöntemlerin başında YSA gelmektedir. YSA ilk olarak McCulloch ve Pitts tarafından 1943 yılında duyurulmuştur [71]. Bu araştırmacılar ilk YSA sinir hücresinin tasarımını yapmışlardır. YSA çalışmaları Rosenblatt tarafından Perceptron'un tasarımı ile hız kazanmıştır [72]. Perceptron, lineer olmayan problemlerin çözümünde yetersiz kalınca Minsky ve Papert [73] tarafından iki katmanlı YSA önerilmiştir. Rumelhart ve McClelland tarafından karmaşık ve çok katmanlı YSA için geri yayılmalı öğrenme algoritmaları ortaya konmuştur [74, 75].

YSA, girişleri ve çıkışları arasındaki bağlantının bilinmediği sistemlerin gerçekleştirilmesinde kullanılan güçlü bir modeldir. Bu model gücünü içindeki veri bağlantılarının ve transfer fonksiyonu parametrelerinin optimize edilmesinden alır. Bu işlem eğitim olarak isimlendirilir.


YSA, sinir hücrelerinden oluşan bir sınıflandırma modelidir. Bir yapay sinir hücresi (perceptron) insan sinir hücresine benzer biçimde geliştirilmiştir. Şekil 3.1'de bir sinir hücresi modeli görülmektedir.

Sinir hücresinin çıkışı,


$$y = f[(\sum_{i=1}^n x_i w_i) + \beta] \quad (3.4)$$

denklemleri ile hesaplanmaktadır. Bu denklemde f sinir hücresinin transfer fonksiyonudur. n, x_i, w_i ve β parametreleri sırasıyla giriş verilerinin sayısını, giriş verilerini, her bir girişin ağırlığını ve eşik değerini (bias) göstermektedir.

YSA'lar sinir hücrelerinin yer aldığı çok sayıda katmandan oluşur [75]. Şekil 3.1'de görülen sinir hücrelerini kullanarak oluşturulan üç katmanlı bir YSA modeli Şekil 3.2'de görülmektedir. Şekil 3.2'de görülen YSA modelinde O_i , sinir ağına çıkışlarını; aradaki bağlantılar ise ağırlıkları göstermektedir.



Şekil 3.1. YSA sinir hücresi modeli (Perceptron).



Şekil 3.2. Üç girişli, üç katmanlı ve iki çıkışlı sinir ağı modeli.

3.3.1. Bağlantı Ağırlıklarının Optimizasyonu

YSA'nın bir problem çözümünde doğru sonuç vermesi için eğitilmesi gerekir. Bu eğitim YSA'nın ağırlıklarının ve transfer fonksiyonu parametrelerinin optimizasyonu ile yapılır. Optimize edilen değişkenlerin başlangıç değerleri bilinmediğinden çoğu durumda rastgele değerler kullanılır.

YSA'nın öğrenmesi için eğitim verileri kullanılır. Bu eğitim verilerinde modellenen sistemin giriş ve çıkış değerleri bilinmekte fakat YSA modelinin girişleri ve çıkışları arasındaki bağlantı ağırlıkları bilinmemektedir. Bilinen ağırlıklar ile YSA çıkışı hesaplanır. Bilinen çıkış ile hesaplanan çıkış arasındaki fark hata olarak değerlendirilir. Bu hata, türev fonksiyonları ve geri yayılım algoritmaları ile YSA'nın ağırlıklarının optimize edilmesinde kullanılır. Optimizasyon işleminin tekrar edilmesi iterasyon olarak isimlendirilir. Hata her bir iterasyonda gittikçe azalır. YSA'nın çıkışında hesaplanan hata, kabul edilebilir bir değere ulaştığı zaman eğitim tamamlanmış olur. Eğitimi tamamlanan YSA ile bilinen girişlere karşılık bilinmeyen çıkışlar hesaplanır.

Şekil 3.2'de verilen YSA'nın çıkışında oluşan hata,

$$e = \frac{1}{2} \sum_{i=1}^m (d_i - o_i)^2 \quad (3.5)$$

denklemleri ile hesaplanır. Bu denklemde m , d_i ve o_i parametreleri sırası ile örnek sayısını, YSA'nın çıkışında olması istenen değerleri ve YSA çıkışında elde edilen değerleri göstermektedir. Bu hata, ortalama karesel hata (Mean Squared Error, MSE) olarak isimlendirilir. YSA'da kullanılan bağlantı ağırlıkları aşağıda verilen denklem ile güncellenir.

$$w_i^{t+1} = w_i^t - \eta \frac{\partial e}{\partial w_i} \quad (3.6)$$

Bu denklemde t ve η parametreleri sırası ile iterasyon sayısını ve öğrenme katsayısını göstermektedir. Öğrenme katsayısı, YSA'nın öğrenme hızını belirler. Öğrenme katsayısının küçük olması, YSA'nın yavaş öğrenmesine sebep olur. Büyük olması daha hızlı öğrenme sağlarken, bağlantı ağırlıklarının bozulmasına da sebep olabilir.

3.3.2. Eğitim Verilerinin Hazırlanması

YSA'nın başarısı, tasarım parametrelerine bağlı olduğu kadar, eğitim için kullanılan verilere de bağlıdır. YSA güçlü bir model olduğu için tasarımında ve eğitim verilerinde olan küçük hataları bertaraf etmektedir. En kötü ihtimal ile YSA çıkışında küçük bir miktar hata görülür.

Gözden kaçırılmaması gereken diğer bir husus, eğitim için kullanılan verilerin sıralanmasıdır. Bu sıralamaya dikkat edilmez ise aşırı öğrenme veya ezber durumu oluşabilmekte ve YSA hatalı öğrenmektedir. Eğitim verilerinin dağılımı düzgün olmadığı zaman YSA bir sınıfın özelliklerini çok iyi öğrenmekte, diğer sınıfın özelliklerini öğrenememektedir.

Eğitimi verilerinde iki farklı sınıf "1" ve "0" ile gösterilirse, veriler "11110000" gibi peş peşe aynı özellikte olduğu zaman aşırı öğrenme durumu oluşmakta ve hatalı sınıflandırma yapılmaktadır. Eğitim verileri yeniden sıralanarak "10101010" biçimine getirilirse aşırı öğrenmenin önüne geçilebilir. Eğitim verilerinin az olması yetersiz öğrenmeye neden olurken, gereğinden çok olması öğrenme başarısını artırmaz.

3.3.3. Katman Sayısının Seçimi

Yapay sinir ağının kaç katmandan oluşacağına dair bir kural yoktur. Katman sayısı tecrübe ve denemelerle belirlenmektedir. Çoğunlukla 2 veya 3 katmanlı modeller kullanılmaktadır.

3.3.4. Sinir Hücrelerinin Sayısının Seçimi

YSA'nın çıkış katmanında YSA'nın çıkış adedince sinir hücresi bulunur. Ancak gizli katmanlarda kullanılan sinir hücrelerinin sayısının belirlenmesinde bir kural yoktur. Gizli katmanlarda kullanılan sinir hücresi sayısı tecrübe ve denemelerle belirlenmektedir. Eğitim verilerinde bulunan değişkenlerin sayısı, sinir hücrelerinin sayısını belirlemek için bir başlangıç noktası olabilir. Sinir hücrelerinin sayısı giriş değişkenlerinin sayısının bir, iki veya üç katı olabilir.


3.3.5. Transfer Fonksiyonunun Seçimi

Sinir hücrelerinde kullanılacak olan transfer fonksiyonu, işaret özelliklerinin değişim aralığına ve ağ çıkışında beklenen değerlere uygun olmalıdır. Logaritmik transfer

fonksiyonunun çıkışı “0.0” ile “1.0” aralığında değişmektedir. Bu transfer fonksiyonunun kullanıldığı çıkış katmanından “-1.0” ile “1.0” arasında bir değer beklemek yanlış olacaktır. Fakat ağ çıkışı ilave işlemlerle istenilen değer aralığına ölçeklenebilir. YSA’da kullanılan bazı transfer fonksiyonları Şekil 3.3’te verilmiştir.

3.3.6. Yapay Sinir Ağı Öğrenme Algoritmasının Seçimi

Tasarımı yapılan YSA’nın en iyi sonucu vermesi için eğitilmesi veya öğrenmesi önemli bir işlem adıdır. Bu işlem esasında YSA’nın matematik modelinin optimizasyonudur. Bu işlemi gerçekleştirmek için pek çok öğrenme algoritması geliştirilmiştir [76-83]. Farklı öğrenme algoritmaları birçok durumda benzer sonuçlar verir. Ancak bazı öğrenme algoritmalarının bazı örneklerde daha iyi veya daha kötü sonuçlar verdiği de görülmektedir. En iyi öğrenme yöntemi denemelerle seçilmektedir. Yapılan denemelerde Levenberg-Marquardt [76] algoritmasının daha yavaş çalışmasına rağmen daha iyi sonuçlar verdiği görülmüştür.



Şekil 3.3. Yapay sinir ağlarında kullanılan (a) Simetrik sigmoid, (b) Logaritmik sigmoid, (c) Eşik aktivasyon ve (d) Doğrusal aktivasyon transfer fonksiyonları.

3.3.7. Yapay Sinir Ağının Gerçekleştirilmesi

YSA ile sınıflandırma veya modelleme yapmak için aşağıda verilen işlem adımları takip edilir.

- a) Eğitim verileri oluşturulur.
- b) Model parametreleri belirlenir.
- c) Yapay sinir ağı oluşturulur.
- d) Yapay sinir ağı optimize edilir (yapay sinir ağının eğitimi veya öğrenme).
- e) İstenilen giriş değerlerine göre yapay sinir ağının çıkışı hesaplanır.

Daha önce eğitimi yapılan bir YSA, model parametrelerini değiştirmeden güncellenen eğitim verileri ile yeniden eğitime tabi tutulabilir. Giriş ve çıkış sayılarının, katman ve sinir hücreleri sayılarının veya transfer fonksiyonlarının değişmesi durumunda YSA'nın yeniden eğitilmesi gerekmektedir.

3.4. Uyarlamalı Sinirsel Bulanık Mantık Sistemi

Klasik mantık teorisinde bir olay için “1” ve “0” ile gösterilen iki durum vardır. Bu gösterime göre bir bilgi ya doğrudur ya da yanlıştır, bir olay ise ya olmuştur ya da olmamıştır. Bu gösterim bazı durumlarda yeterli olsa bile gerçek dünya problemlerinde “1” ve “0”dan daha fazlası vardır. Bir bilgi kısmi olarak doğru veya bir olay kısmi olarak gerçekleşmiş olabilir. Bu durum bizi sadece “1” ve “0”ın olduğu iki durumdan kısmi derecelerin olduğu üyelik fonksiyonlarına götürür. Üyelik fonksiyonları Zadeh tarafından 1965 yılında yayımlanan makalesinde açıklanmıştır [84]. Zadeh tarafından üyelik fonksiyonlarını kullanan bulanık mantık geliştirilmiş ve birçok uygulamada başarı ile kullanılmıştır. YSA ve bulanık mantık güçlü birer model olduğundan bu her iki modelin iyi taraflarını bir arada kullanan uyarlamalı sinirsel bulanık mantık sistemleri geliştirilmiştir. Bu yöntemlerden biriside Jang tarafından 1993 yılında yayımlanan ANFIS modelidir [85].

Birinci derece Sugeno bulanık mantık modelinde A_i ve B_i bulanık kümelerini göstermek üzere bulanık kurallar aşağıda verilen denklemler ile tanımlanır.

$$\text{Kural 1: Eğer } x_1 = A_1 \text{ ve } x_2 = B_1 \text{ ise } f_1 = p_1x_1 + q_1x_2 + r_1 \quad (3.7)$$

$$\text{Kural 2: Eğer } x_1 = A_2 \text{ ve } x_2 = B_2 \text{ ise } f_2 = p_2x_1 + q_2x_2 + r_2 \quad (3.8)$$

Bu denklemlerde; x_i , giriş değişkenlerini; f_j , çıkış değişkenlerini; p_j, q_j ve r_j , sonuç değişkenlerini göstermektedir. Bu denklemlerle ifade edilen kurallara göre tasarımı yapılan bulanık sistemin örnek üyelik fonksiyonları Şekil 3.4'te görülmektedir. Bu şekilde A_1 ve A_2 , genelleştirilmiş çan eğrisi; B_1 ve B_2 , π – tipi üyelik fonksiyonlarıdır. Üyelik fonksiyonları Şekil 3.4'te görülen bulanık sistemin çıkışları aşağıda verilen denklemler ile hesaplanır.

$$w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y), i = 1,2 \quad (3.9)$$

$$f_1 = p_1x_1 + q_1x_2 + r_1 \quad (3.10)$$


$$f_2 = p_2x_1 + q_2x_2 + r_2 \quad (3.11)$$

$$f = \frac{w_1f_1 + w_2f_2}{w_1 + w_2} \quad (3.12)$$


$$f = \bar{w}_1f_1 + \bar{w}_2f_2 \quad (3.13)$$

Bu denklemlerde w_i , bağlantı ağırlıklarını; $\bar{w}_i$, normalize edilmiş bağlantı ağırlıklarını göstermektedir. İki girişli ve iki çıkışlı Sugeno tipi bulanık modele eşdeğer ANFIS yapısı Şekil 3.5'te görülmektedir [85].

ANFIS, YSA gibi çok katmanlı bir yapıdır. Ancak YSA'nın katman sayısı gerektiği gibi seçilebilirken ANFIS'in belirli bir katman yapısı vardır. ANFIS'te her bir giriş için kaç adet üyelik fonksiyonu kullanılacağı ve kullanılacak üyelik fonksiyonlarının seçimi yapılabilir. Bu seçimin nasıl yapılacağına dair bir kural yoktur, tecrübe ve denemelerle yapılmaktadır.



Şekil 3.4. İki girişli ve iki kurallı Sugeno tipi bulanık mantık modelinin örnek üyelik fonksiyonları.



Şekil 3.5. İki girişli ve iki kurallı Sugeno tipi bulanık çıkarıma eşdeğer ANFIS mimarisi [85].

YSA ile sınıflandırma veya modelleme yapmak için kullanılan işlem adımları aynı şekilde ANFIS için de kullanılabilir. ANFIS'te de YSA gibi model parametrelerini değiştirmeden, güncellenen eğitim verileri ile yeniden eğitim yapılabilir. Model parametrelerinde bir değişiklik olursa ANFIS'in yeniden eğitilmesi gerekmektedir.

3.5. Morfolojik Filtreler

Morfolojik filtreler, daha çok görüntü işleme algoritmalarında görüntüleri şekil ve yapısal olarak iyileştirmek için kullanılan algoritmik yapılardır. Görüntü işlemede morfolojik fonksiyonlar kenar belirleme, kenar düzeltme ve benzeri diğer işlemler için kullanılır. Biyolojik işaretler bir boyutlu görüntü işareti gibi düşünülebilir. Bu sebeple morfolojik fonksiyonlar biyolojik işaretlerin iyileştirilmesinde de kullanılabilir. Morfolojik filtreler, morfolojik işlemler ile gerçekleştirilmektedir. Morfolojik filtrelerin genişleme ve aşınma olmak üzere temel iki fonksiyonu vardır. Genişleme ve aşınma işlemlerinin farklı sıra ile kullanılması, kapanma ve açılma gibi daha yüksek seviyeli morfolojik fonksiyonları oluşturur.

Morfolojik işlemler ileri yönlü bir dönüşümdür. Morfolojik dönüşüm bir f kümesi ve bir k yapı elemanı ile gerçekleştirilir. f, F kümesinde tanımlı bir fonksiyon ve k, K kümesinde tanımlı bir yapı elemanı olsun. Genişleme ve aşınma işlemleri,

$$(f \oplus k)(x) = \max\{f(x - z) + k(z)\}, z \in K, (x - z) \in F \quad (3.14)$$

$$(f \ominus k)(x) = \min\{f(x + z) - k(z)\}, z \in K \quad (3.15)$$

ile tanımlanır. Eğer k sıfır genlikli bir yapı elemanı ise genişleme ve aşınma işlemleri aşağıda verilen denklemler ile hesaplanır.

$$(f \oplus k)(x) = \max\{f(x)\}, x \in F \quad (3.16)$$

$$(f \ominus k)(x) = \min\{f(x)\}, x \in F \quad (3.17)$$

Genişleme işlemi ile bir görüntü veya işaret dilimi daha belirgin hale getirilirken, aşınma işlemi ile zayıflatılır. Kapanma ve açılma işlemleri,

$$f \bullet k = (f \oplus k) \ominus k \quad (3.18)$$

$$f \circ k = (f \ominus k) \oplus k \quad (3.19)$$

ile gerçekleştirilir [86]. Morfolojik işlem örnekleri yapay sinir ağları ile uyku apnesinin skorlanması konusunda verilmiştir.

4. BÖLÜM

UYKU VE UYKU APNESİ SKORLAMA

4.1. Giriş

Bu bölümde PSG işaretleri kullanılarak uyku ve uyku apnesi skorlaması yapılmıştır. Uyku skorlaması için YSA kullanılmıştır. Skorlama için kullanılan işaretler, işaret özellikleri, YSA'nın tasarım parametrelerinin seçimi, en iyi sonuç veren YSA modeli ve skorlama başarıları bu bölümde verilmiştir.

Uyku apnesini skorlamak için görsel skorlama kurallarına dayalı bir algoritma, YSA ve ANFIS olmak üzere üç farklı yöntem kullanılmıştır. Uyku apnesinin skorlanmasında kullanılan işaretler, işaret özellikleri, her bir yöntemin tasarım parametrelerinin seçimi ve skorlama başarıları da bu bölümde verilmiştir. Her bir hasta grubu için her bir yöntem ile elde edilen başarı ortalamaları ayrı ayrı sunulmuştur.

4.2. Yapay Sinir Ağları İle Uyku Skorlama

Uyku skorlama, ilk defa 1968 yılında Rechtschaffen ve Kales'in hazırladığı teknik ve skorlama el kitabına göre yapılmıştır [87]. Bu skorlama kurallarına göre uyku, REM uyku ve NREM uyku olmak üzere ikiye ayrılır. Ayrıca NREM uykusu da dört evreye ayrılır. NREM1, NREM2, NREM3 ve NREM4 olarak isimlendirilen bu evrelerde, NREM1'den NREM4'e doğru uyku derinliği giderek artmaktadır. 2007 yılında AASM tarafından bu kurallar gözden geçirilmiş ve NREM3 ve NREM4 evreleri birleştirilerek NREM3 olarak isimlendirilmiştir.

Uyku skorlaması için üç EEG, sağ ve sol gözden alınan birer EOG ve bir çene EMG'si kullanılmıştır. Uyanıklık ve uyku seviyelerinin belirlenmesi için kurallar AASM el kitaplarında verilmiştir [16, 17].

Uyku seviyelerini skorlamak için izlenen adımlar şu şekilde sıralanmaktadır:

- a) Biyolojik işaret en baştan itibaren 30 saniyelik dilimlere ayrılır.
- b) Her bir işaret dilimi ayrı ayrı skorlanır.
- c) Bir işaret diliminde birden fazla uyku evresi görülüyorsa bu zaman dilimi en fazla görülen uyku evresi olarak skorlanır.

4.2.1. Uyku Skorlama İçin Kullanılan Polisomnografi İşaretleri ve İşaret Özellikleri

Uyku skorlamak için EEG işaretlerinden F4, C4 ve O2; EOG işaretlerinden E1 ve E2; çeneden alınan EMG işareti kullanılmıştır. Bu işaretler zaman ekseninde işaret özelliklerinin yaklaşık sabit kaldığı 30 saniyelik dilimlere bölünerek her bir dilimin işaret ortalaması, enerjisi, gücü ve etkin değeri hesaplanmıştır.

N adet örnekten oluşan bir x işaretinin aritmetik ortalaması,

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (4.1)$$

ile hesaplanmıştır. Aritmetik ortalama belirleyici bir özelliktir. Ancak bazı işaretlerin ortalaması sıfır olduğundan bu işaretlere dikkat edilmelidir.

Bir x işaretinin enerjisini hesaplamak için,

$$E = \sum_{i=1}^N |x_i|^2 \quad (4.2)$$

denklemini kullanılmıştır. Bir işaretin enerjisi işaretin örnek sayısına bağlıdır. Eğer farklı işaret dilimlerinin enerjisi hesaplanacaksa işaret dilimleri aynı uzunlukta olmalıdır.

Bir x işaretinin gücü,

$$P = \frac{1}{N} \sum_{i=1}^N |x_i|^2 \quad (4.3)$$

ile hesaplanmıştır. İşaret gücü, işaret enerjisinin dağılımını gösterir. Örnek sayısından bağımsız olduğu için işaretin enerjisine göre daha iyi bir belirleyicidir.

Bir x işaretinin etkin değerini hesaplamak için aşağıda verilen denklem kullanılmıştır.

$$x_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N |x_i|^2} \quad (4.4)$$

Biyolojik işaret işleme çalışmalarında hangi işaret özelliğinin daha belirleyici olduğu yapılan denemelerle belirlenmiştir.

4.2.2. Polisomnografi İşaretlerinin Özelliklerinin Çıkarılması

PSG işaretlerin özellikleri Bölüm 2’de açıklanmıştır. Uyku skorlamasında kullanılan işaretler, ön işleme adımları, işaretlerin iyileştirilmesi ve özelliklerinin çıkarılması için aşağıda verilen işlem adımları takip edilerek özellikler tablosu oluşturulmuştur.

- a) Bazı durumlarda biyolojik işaretler, içinde bilgi taşımayan doğrusal eğilimler (DC değerler) bulundurmaktadır. Bu eğilimler işaret genliğini ve ortalamasını olumsuz etkilemektedir. Biyolojik işaretler DC değerlerden temizlenerek karakteristiği daha doğru bir işaret elde edilmiştir.
- b) EEG ve OEG işaretleri alt kesim frekansı 0.3 Hz, üst kesim frekansı 35Hz; EMG işaretleri alt kesim frekansı 10 Hz, üst kesim frekansı 100 Hz olan 4. dereceden Butterworth filtresi ile istenmeyen frekans bileşenlerinden temizlemiştir.
- c) EEG işaretleri ayırık dalgacık dönüşümü ile 0-4 Hz, 4-8 Hz, 8-12 Hz ve 12-16 Hz olan dört alt banda ayrılmış ve her bir frekans bandının işaret gücü; EOG ve EMG işaretleri ise alt bandlara ayrılmadan işaret güçleri hesaplanmıştır. Her bir özellik vektöründe 15 adet değişken bulunmaktadır.
- d) İşaret özellikleri tablosunda bulunan her bir özelliğin ortalaması ve standart sapması hesaplanmıştır. Buna göre, %95 olasılıkla $\mu \pm 2\sigma$ aralığındaki değerler geçerli, bu aralığın dışındaki değerler artefakt olarak kabul edilmiş ve özellikler tablosundan çıkarılmıştır.

Bu işlem adımları bütün hastalardan alınan işaretler için tekrar edilmiştir. PSG işaret özellikleri çıkarılan toplam 32 hastaya ait veriler, eğitim ve test verileri olmak üzere iki gruba ayrılmıştır. Eğitim verilerinin seçiminde, uyku evrelerinin dağılımına ve her bir evrenin mümkün olduğu kadar çok görülmesine dikkat edilmiştir. YSA’nın eğitimi için kullanılan veriler Tablo 4.1’de, test için kullanılan veriler Tablo 4.2’de verilmiştir.

Tablo 4.1. Uyku skorlama için YSA'nın eğitiminde kullanılan verilerde hastalara ait AHİ ve epok sayıları.

S/N	AHİ	Epok	Artefakt	Uyanık	REM	NREM1	NREM2	NREM3
1	6	864	48	59	123	36	187	411
2	7	921	31	210	119	63	215	283
3	27	836	40	278	45	47	295	131
4	17	1022	71	76	224	36	400	215
5	25	967	64	115	195	40	364	189
6	13	884	27	385	88	30	207	147
Toplam	...	5494	281	1123	794	252	1668	1376
En Küçük	6	836	27	59	45	30	187	131
En Büyük	27	1022	71	385	224	63	400	411
Ortalama	15.83	915.67	46.83	187.17	132.33	42.00	278.00	229.33
Std. Sapma	8.86	69.27	17.72	127.99	66.61	11.71	89.29	104.08


Tablo 4.1'de görüldüğü gibi YSA'nın eğitimi için 6 hasta verisi kullanılmıştır. Bu verilerde hastaların AHİ'leri 6 ile 27 arasında değişmekte, ortalaması ise 15.83'tür. Toplam 5494 epogun 281 tanesi artefakt olarak işaretlenmiş, 5213 epok ise eğitim için kullanılmıştır. Eğitim için kullanılan epokların 1123 adedi uyanıklık (%21.54), 794 adedi REM (%15.23), 252 adedi NREM1 (%4.83), 1668 adedi NREM2 (%32.00) ve 1376 adedi NREM3 (%26.40) dönemlerine aittir.

Tablo 4.2'de görüldüğü gibi YSA'nın test edilmesi için 26 hasta verisi kullanılmıştır. Bu verilerde hastaların AHİ'leri 0,3 ile 77 arasında değişmekte, ortalaması ise 19,90'dır. Test için kullanılan verilerin ortalama AHİ değeri, eğitim için kullanılan verilerin ortalama değerine oldukça yakındır. YSA'nın testi için toplam 24404 epogun 1061 tanesi artefakt olarak işaretlenmiş, 23343 epok ise test için kullanılmıştır. Test için kullanılan epokların 2733 adedi uyanıklık (%11.71), 3984 adedi REM (%17.07), 546 adedi NREM1 (%2.34), 9729 adedi NREM2 (%41.68) ve 6351 adedi NREM3 (%27.21) dönemlerine aittir.

Eğitim verilerinde 2 sıra numaralı hastanın uyanıklık ve uyku seviyelerini gösteren grafik (hipnogram) Şekil 4.1'de verilmiştir. Şekil 4.1'de verilen hipnogramda görüldüğü gibi

Tablo 4.2. Uyku skorlaması için test grubu hastalara ait AHİ ve epok sayıları.

S/N	AHİ	Epok	Artefakt	Uyanık	REM	NREM1	NREM2	NREM3
1	77	851	22	120	155	6	405	143
2	13	1033	60	177	197	20	295	284
3	26	1003	39	29	236	25	344	330
4	5	935	70	112	152	16	391	194
5	37	893	27	153	50	17	477	169
6	9	975	35	18	217	26	482	197
7	17	949	49	74	106	26	488	206
8	18	923	71	116	124	22	355	235
9	17	984	49	33	211	18	467	206
10	8	959	30	189	214	19	289	218
11	40	928	31	149	119	29	320	280
12	32	940	50	47	132	26	448	237
13	9	937	37	166	178	23	358	175
14	0,3	968	27	66	118	23	401	333
15	7	940	38	247	144	21	226	264
16	20	943	26	160	135	21	350	251
17	18	1008	44	77	251	27	446	163
18	22	966	33	80	178	29	158	488
19	13	936	36	148	124	26	407	195
20	16	1011	17	44	215	15	489	231
21	5	869	50	91	156	14	343	215
22	4	886	25	144	47	27	326	317
23	22	846	32	25	129	16	294	350
24	12	1029	59	129	154	23	397	267
25	22	919	60	78	144	19	478	140
26	48	773	44	61	98	12	295	263
Toplam	...	24404	1061	2733	3984	546	9729	6351
En Küçük	0.3	773	17	18	47	6	158	140
En Büyük	77	1033	71	247	251	29	489	488
Ortalama	19.90	938.62	40.81	105.12	153.23	21.00	374.19	244.27
Std. Sapma	16.45	60.32	14.64	58.82	51.91	5.67	86.06	76.27



Şekil 4.1. Eğitim için kullanılan verilerden 2 sıra numaralı hastanın uyku hipnogramı.

uyku NREM1 ile başlar, NREM2 ve NREM3 ile devam eder. Bu dönemden sonra uyku derinliği hızla azalmaya başlayıp REM dönemine kadar devam eder. Daha sonra tekrar derinleşmeye başlayan uyku seviyesi eğer bir uyarıcı olmaz ise uyanıncaya kadar aynı şekilde devam eder. Şekil 4.1’de verilen örneğin alındığı kişi uyku apnesi hastası olduğundan REM uyku dönemlerinden sonra kısa süreli uyanıklık dönemleri görülmektedir. Ancak normal uyku süresinin sonuna yaklaşıldığında uyku derinliği NREM3 dönemini görmemeye başlar.

4.2.3. Uyku Skorlama Başarısının Hesaplanması

Yapılan skorlama çalışmasının doğruluğunun veya başarısının hesaplanması için doğruluk (accuracy) testi yapılır. Doğruluk testi, tıbbi uzman tarafından yapılan skorlama ile YSA tarafından yapılan skorlama karşılaştırılarak hesaplanır. İstenilen uyku seviyeleri “1”, diğer uyku seviyeleri “0” ile gösterilirse muhtemel durumlar Tablo 4.3’te görüldüğü gibi olacaktır. Tablo 4.3’e göre doğruluk oranı aşağıdaki şekilde hesaplanır.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (4.5)$$

Doğruluk, “0.0” ile “1.0” arasında değişir. Bu değer ne kadar büyükse yapılan sınıflandırma o kadar başarılıdır [29, 44, 88].

Tablo 4.3. Değerlendirme tablosu.

Tıbbi Uzman Skoru	YSA Skoru	Durum
0	0	Doğru Negatif (DN)
0	1	Yanlış Pozitif (YP)
1	0	Yanlış Negatif (YN)
1	1	Doğru Pozitif (DP)

4.2.4. Uyku Skorlama İçin Yapay Sinir Ağı Parametrelerinin Seçimi

PSG işaretleri ile uyanıklık, REM, NREM1, NREM2 ve NREM3 olmak üzere beş farklı seviyede uyku skorlaması yapılmıştır. Her bir uyku seviyesi için ayrı bir YSA oluşturulmuştur. İlk olarak özellikler tablosu, istenilen uyku seviyesinin olduğu ve olmadığı durumlar olmak üzere ikiye ayrılmıştır. Özellikler tablosunda istenilen uyku seviyesi olan zaman dilimleri “+1”, diğer zaman dilimleri “-1” olarak işaretlenmiştir. Bu değerler YSA’da kullanılan sinir hücrelerinin transfer fonksiyonu ile uyumludur.

YSA tasarımında katman sayısının seçimi için genel bir kural olmadığından bu çalışmada 2 ve 3 katmanlı YSA modelleri ile denemeler yapılmıştır.

4.2.5. Sinir Hücrelerinin Sayısının Seçimi

Sinir hücrelerinin sayısının seçimi için herhangi bir kural yoktur. Bu çalışmada iki katmanlı YSA ile yapılan denemelerde gizli ve çıkış katmanında sıralı olarak (3, 1), (6, 1), (9, 1), (12, 1), (15, 1) ve (18, 1) adet sinir hücresi kullanılmıştır. Üç katmanlı YSA ile yapılan denemelerde gizli ve çıkış katmanlarında sıralı olarak (3, 3, 1), (3, 6, 1), (3, 9, 1), (3, 12, 1), (3, 15, 1), (3, 18, 1), (6, 3, 1), (9, 3, 1), (12, 3, 1), (15, 3, 1), (18, 3, 1), (6, 6, 1), (6, 9, 1), (6, 12, 1), (6, 15, 1) ve (6, 18, 1) adet sinir hücreleri ile denemeler yapılmıştır.

Sinir hücrelerinin transfer fonksiyonlarının seçimi için herhangi bir kural yoktur. Fakat başarılı bir uygulama için YSA’nın giriş ve çıkış verileri ile sinir hücrelerinin transfer fonksiyonları uyumlu seçilmelidir. Uyku seviyelerinin skorlanması için kullanılan YSA modellerinde hiperbolik tanjant sigmoid transfer fonksiyonu kullanılmıştır.

4.2.6. Uyku Skorlamak İçin Yapay Sinir Ağlarının Gerçekleştirilmesi

Uyku skorlaması yapmak için iki ve üç katmanlı, farklı sayıda sinir hücrelerinden oluşan 22 farklı YSA modeli kullanılmıştır. Her bir YSA modelinde uyanıklık, REM, NREM1, NREM2 ve NREM3 olmak üzere beş farklı uyku seviyesi için beş ayrı YSA oluşturulmuştur. Bu tez çalışmasında kullanılan YSA'ların eğitimi 12 farklı öğrenme yöntemi ile yapılmıştır. Ancak bütün YSA'ları bütün öğrenme yöntemleri ile eğitmek uzun bir zaman alacağından üç farklı grup deneme yapılmıştır. YSA'nın eğitim verilerinde 5213 adet özellik verisi vardır. Bu veri 43.44 saatlik zamana karşılık gelmektedir. Yapılan denemelerde bu kadar özellik verisinin yeterli olduğu görülmüştür.

Birinci grup denemelerde, 22 farklı YSA modeli Levenberg-Marquardt öğrenme algoritması ile eğitilmiş ve yapılan skorlamanın doğruluğu Denklem (4.5) ile hesaplanmıştır. Bu denemelere ait öğrenme ve test başarıları Tablo 4.4'te verilmiştir. Bu denemelerde elde edilen başarı ortalamaları %70.82 ile %75.77 arasında bulunmuştur.

Tablo 4.4'te görüldüğü gibi yapılan iki katmanlı model denemelerinde gizli katmanda sıra ile 3, 6, 9, 12, 15 ve 18 sinir hücresi bulunan 6 model denemesi yapılmıştır. Bu denemelerde en yüksek test başarıları, gizli katmanda 3 hücre bulunan "Model 1" ile %74.69 olmuştur.

Üç katmanlı model denemelerinde birinci gizli katmanda 3 olmak üzere ikinci gizli katmanda sıra ile 3, 6, 9, 12, 15 ve 18 sinir hücresi bulunan 6 model denemesi yapılmıştır. Bu denemelerde en yüksek test başarıları birinci ve ikinci gizli katmanda 3'er hücre bulunan "Model 7" ile %75.77 olmuştur. Bu sonuç 2 katmanlı model denemelerinden biraz daha iyidir.

Üç katmanlı model denemelerinde ikinci gizli katmanda 3 olmak üzere birinci gizli katmanında sıra ile 6, 9, 12, 15 ve 18 sinir hücresi bulunan 5 model ile denemeler yapılmıştır. Bu denemelerde en iyi sonuç "Model 13" ile %73.96 olarak hesaplanmıştır.

Birinci gizli katmanda 6 olmak üzere ikinci gizli katmanında sıra ile 6, 9, 12, 15 ve 18 sinir hücresi bulunan 5 model denemesi yapılmıştır. Bu denemelerde elde edilen en iyi sonuç "Model 21" ile %72.95 olmuştur.

Tablo 4.4. Uyku seviyelerini belirlemek için kullanılan bütün YSA modellerinin Levenberg-Marquardt ile eğitilmesi durumunda hesaplanan öğrenme ve test başarıları.

YSA Model Numarası	Katman Sayısı	Giriş Katmanı Hücre Sayısı	Gizli Katman Hücre Sayısı	Çıkış Katmanı Hücre Sayısı	Ortalama Öğrenme Başarısı (%)	Ortalama Test Başarısı (%)
1	2	3	-	1	85.52	74.69
2	2	6	-	1	89.30	73.40
3	2	9	-	1	90.12	74.08
4	2	12	-	1	91.53	71.45
5	2	15	-	1	91.69	73.36
6	2	18	-	1	90.05	71.67
7	3	3	3	1	85.09	75.77
8	3	3	6	1	86.09	73.32
9	3	3	9	1	86.55	74.08
10	3	3	12	1	86.13	73.06
11	3	3	15	1	86.68	73.73
12	3	3	18	1	86.92	72.38
13	3	6	3	1	88.95	73.96
14	3	9	3	1	91.09	73.56
15	3	12	3	1	91.04	72.76
16	3	15	3	1	92.29	71.59
17	3	18	3	1	93.17	70.82
18	3	6	6	1	90.24	72.69
19	3	6	9	1	90.65	71.51
20	3	6	12	1	91.42	72.16
21	3	6	15	1	91.89	72.95
22	3	6	18	1	91.59	72.69
En Küçük					85.09	70.82
En Büyük					93.17	75.77
Ortalama					89.45	72.99
Std. Sapma					2.52	1.19

İkinci grup denemelerde, birinci grup denemelerle elde edilen en başarılı YSA modeli diğer 11 farklı öğrenme yöntemi ile eğitilmiş ve başarı ortalamaları hesaplanmıştır. Bu denemeye ait ortalama test başarıları Tablo 4.5'te verilmiştir. Yapılan bu grup denemelerde en iyi başarı ortalaması Bayesian Regularization öğrenme yöntemi ile %73.27 olarak elde edilmiştir. Levenberg-Marquardt ile elde edilen başarı ortalaması bu başarı ortalamasından daha yüksektir.

Üçüncü grup denemelerde, birinci grup denemelerle elde edilen 2., 3., 4. ve 5. en başarılı 4 YSA modeli diğer 11 farklı öğrenme yöntemi ile eğitilmiş ve başarı ortalamaları hesaplanmıştır. Her bir model ile yapılan denemelerde en iyi başarı ortalamasını veren öğrenme yöntemleri ve bu yöntemlerin başarı ortalamaları Tablo 4.6'da verilmiştir.

Tablo 4.6'ya göre farklı öğrenme algoritmaları farklı YSA modellerinde daha başarılı bulunmuştur. Öğrenme algoritmalarının ortalama test başarıları %73.88 ile %75.26 arasında hesaplanmıştır. Başarı ortalamalarının farkı bu çalışma için oldukça iyidir.

Tablo 4.5. Birinci grup denemelerde en iyi başarı ortalamasını veren YSA modeli diğer 11 farklı öğrenme algoritması ile eğitildiğinde elde edilen ortalama test başarıları.

S/N	Öğrenme Algoritması	Ortalama Test Başarısı (%)
1	Bayesian Regularization [77]	73.27
2	Scaled Conjugate Gradient [80]	72.56
3	BFGS Quasi-Newton [76, 78]	72.23
4	One Step Secant [81]	71.57
5	Resilient Backpropagation [78, 79]	70.77
6	Polak-Ribière Conjugate Gradient [82]	69.42
7	Conjugate Gradient with Powell/Beale Restarts [76]	69.19
8	Fletcher-Powell Conjugate Gradient [81]	68.61
9	Variable Learning Rate Gradient Descent [82]	66.96
10	Gradient Descent with Momentum [83]	61.47
11	Gradient Descent [83]	60.33
	Ortalama	69.21
	Standart Sapma	4.41

Tablo 4.6. Öğrenme algoritmalarının ortalama test başarıları.

Model Numarası	Öğrenme Algoritması	Ortalama Test Başarısı (%)
1	Bayesian Regularization [77]	75.26
3	BFGS Quasi-Newton [76, 78]	74.77
9	Bayesian Regularization [77]	74.13
13	Scaled Conjugate Gradient [80]	73.88
	Ortalama	74.45
	Standart Sapma	0.56

YSA modellerinin öğrenmeye rastgele değerler ile başladığı ve her defasında farklı değerler aldığı düşünülürse her denemede birbirine yakın fakat farklı sonuçlar elde edilmesi de mümkündür.

Özet olarak Tablo 4.4, Tablo 4.5 ve Tablo 4.6 birlikte değerlendirildiğinde en iyi test başarıları “Model 7” YSA, Levenberg-Marquardt öğrenme algoritması ile eğitildiğinde %75.77 olarak elde edilmiştir. Bu model üç katmanlı bir yapı olup, gizli katmanlarında 3'er, çıkış katmanında ise 1 sinir hücresi bulunmaktadır. Skorlama için üç EEG, iki EOG ve çene EMG işareti, işaret özelliği olarak her bir işaretin işaret gücü kullanılmıştır.

4.2.7. Yapay Sinir Ağları İle yapılan Uyku Skorlamasının Sonuçları

Uyku skorlamasında kullanılan hasta verileri, Levenberg-Marquardt öğrenme algoritması ile eğitilen en başarılı YSA modeli ile skorlandığında elde edilen öğrenme ve test başarıları sıra ile Tablo 4.7 ve Tablo 4.8'de verilmiştir.

Tablo 4.7'de öğrenme başarıları %82.33 ile %89.20 arasında değişmekte olup, ortalaması %85.09 olarak hesaplanmıştır. Öğrenme grubu hasta verileri içerisinde NREM1 uyku döneminin görülme oranı %4.83 olduğundan, YSA öğrenmesi zayıf kalmakta ve başarı ortalamasını düşürmektedir. NREM1'in olmadığı skorlama başarıları Ortalama* ile gösterilmiş olup toplam başarıdan biraz daha yüksektir.

Tablo 4.7. Eğitim grubu hastalara ait verilerin uyku skorlaması başarı ortalamaları.

S/N	Uyanık	REM	NREM1	NREM2	NREM3	Ortalama	Ortalama*
1	90.62	89.68	80.26	62.64	88.44	82.33	82.85
2	90.88	89.88	85.85	83.85	95.55	89.20	90.04
3	88.80	96.54	78.77	73.75	84.59	84.49	85.92
4	78.80	85.28	82.30	73.87	92.73	82.59	82.67
5	84.90	93.43	78.91	72.63	89.01	83.78	84.99
6	93.33	96.36	84.16	75.62	91.41	88.17	89.18
En Küçük	78.80	85.28	78.77	62.64	84.59	82.33	82.67
En Büyük	93.33	96.54	85.85	83.85	95.55	89.20	90.04
Ortalama	87.89	91.86	81.71	73.73	90.29	85.09	85.94
Std Sapma	5.26	4.39	2.90	6.79	3.81	2.91	3.11

Tablo 4.8’de test grubu hastalara ait skorlama başarıları görülmektedir. Bu tabloya göre en büyük skorlama başarıları %84.62 (Hasta 20), en küçük skorlama başarıları %67.60 (Hasta 15), ortalama başarı %75.77’dir. NREM1’in olmadığı skorlama başarıları ise %78.07 olmuştur.

Test grubu hastalarda uyku evreleri içinde en yüksek skorlama başarıları %88.70 ile uyanıklık evresinde elde edilmiştir. Aynı şekilde REM evresinde %78.82 ve NREM3 evresinde %76.25 oranında yüksek başarı ortalamaları elde edilmiştir. Ortalama başarı oranının standart sapması 4.28 olarak hesaplanmıştır. Bu değer her bir hastanın ortalama skorlama başarılarının dar bir aralıkta olduğunu göstermektedir. Bu değer küçük olması skorlama modelinin kararlılığını göstermektedir.

Tablo 4.8’de uyku seviyeleri içinde en düşük ortalama skorlama başarıları %66.60 ile NREM1 evresine aittir. NREM1 evresinin epok sayıları eğitim verilerinde %4.83, test verilerinde %2.34, toplamda ise %2.80’dir. Bu zaman dilimi çok kısa olduğundan YSA bu uyku evresini yeterince öğrenememiştir.

4.2.8. Yapay Sinir Ağları İle Yapılan Uyku Skorlamasının Değerlendirilmesi

Literatürde yapılan araştırmalarda uyku seviyelerinin skorlanması için farklı yöntemlerin kullanıldığı bazı çalışmalarda elde edilen başarı oranları Tablo 4.9’da verilmiştir. Tablo 4.9’da görüldüğü gibi Bajaj ve Pachori [19] tarafından sağlıklı kişilerde MC-LS-SVM sınıflandırıcı kullanılarak yapılan çalışmada %79.80 ile %92.93 arasında, Hassan ve Bhuiyan [20] tarafından sağlıklı kişilerde adaptive boosting (AdaBoost) ve TQWD kullanılarak yapılan çalışmada %90.01 ile %98.01 arasında, Wu ve arkadaşları [21] tarafından TUA şüphesi olan kişilerde yapılan çalışmada toplam %81.7, Uçar ve arkadaşları [25] tarafından TUA hastalarında yapılan çalışmada %73.36, Boostani ve arkadaşları [22] tarafından yapılan çalışmada sağlıklı kişilerde %87.06, hastalarda %69.05, bu tez çalışmasında uyku apnesi hastalarında %67.60 ile %84.62 arasında toplam %75.77 başarı oranları elde edilmiştir. NREM1 uyku seviyesi hariç olduğunda başarı oranı %78.07 olmaktadır.

Literatürde, uyku skorlaması başarılarının sağlıklı kişilerde yüksek, TUA hastalarında daha düşük olduğu görülmektedir. Bu tez çalışmasında yapılan otomatik uyku skorlama çalışmalarında eğitim başarıları yüksek, test başarıları kabul edilebilir bir seviyededir. Eğitim başarıları ile test başarıları arasındaki fark kullanılan verilerden kaynaklanmaktadır.

4.3. Uyku Apnesinin Skorlanması

Uyku apnesinin skorlanması için geceyi hastanenin uyku laboratuvarında geçiren hastanın PSG işaretleri kaydedilir. Bu PSG işaretleri bir tıbbi uzman tarafından AASM tarafından yayımlanan skorlama kurallarına göre görsel olarak skorlanır. Skorlama sürecinde önce uyku sonra uyku apnesi skorlaması yapılır.

Bu tez çalışmasında uyku apnesinin skorlanması için görsel skorlama kuralları ile uyumlu aşağıda verilen üç yöntem kullanılmıştır.

- a) Algoritmik bir yöntem ile uyku apnesinin skorlanması.
- b) YSA ile uyku apnesinin skorlanması.
- c) ANFIS ile uyku apnesinin skorlanması.

Tablo 4.8. Test grubu hastalara ait verilerin uyku skorlaması başarı ortalamaları.

S/N	Uyanık	REM	NREM1	NREM2	NREM3	Ortalama	Ortalama*
1	88.22	83.90	76.85	74.53	68.80	78.46	78.86
2	89.76	80.09	54.62	57.96	89.77	74.44	79.40
3	92.41	51.51	65.34	75.65	81.23	73.23	75.20
4	87.05	87.17	76.03	70.36	82.19	80.56	81.69
5	91.58	74.57	57.07	68.87	69.08	72.23	76.03
6	88.02	86.86	63.95	64.52	79.34	76.54	79.68
7	89.29	78.15	62.93	68.85	56.99	71.24	73.32
8	92.12	77.61	56.20	67.71	78.85	74.50	79.07
9	91.69	81.01	53.38	66.99	84.84	75.58	81.13
10	87.50	56.22	59.89	71.80	75.25	70.13	72.69
11	91.78	73.33	77.07	59.97	73.91	75.21	74.74
12	87.01	75.86	80.56	59.82	57.66	72.18	70.09
13	79.29	78.46	55.02	65.41	75.72	70.78	74.72
14	93.66	81.29	50.76	69.72	70.23	73.13	78.72
15	87.10	67.74	51.70	63.09	68.34	67.60	71.57
16	87.32	84.14	67.58	68.25	87.76	79.01	81.87
17	69.39	76.93	72.36	73.65	85.96	75.66	76.48
18	94.26	87.15	62.44	51.48	68.14	72.69	75.26
19	94.68	70.55	69.51	69.68	83.55	77.59	79.61
20	94.11	90.24	74.87	78.12	85.78	84.62	87.06
21	83.86	91.78	72.11	75.95	88.58	82.45	85.04
22	90.45	67.75	76.38	62.90	83.46	76.19	76.14
23	83.90	85.84	76.50	68.27	73.60	77.62	77.90
24	87.87	84.01	70.22	74.43	54.05	74.12	75.09
25	90.08	90.49	69.70	79.39	72.46	80.42	83.11
26	93.86	86.53	78.52	73.73	87.02	83.93	85.29
En Küçük	69.39	51.51	50.76	51.48	54.05	67.60	70.09
En Büyük	94.68	91.78	80.56	79.39	89.77	84.62	87.06
Ortalama	88.70	78.82	66.60	68.50	76.25	75.77	78.07
Std. Sapma	5.39	9.95	9.40	6.63	10.06	4.28	4.33

Tablo 4.9. Literatürde yapılan araştırmalara göre uyku seviyelerinin skorlanması için yapılan çalışmalarda elde edilen başarı oranları.

Araştırmacı	Örnek Grubu	Doğruluk Oranları (%)
Bajaj ve Pachori [19]	Sağlıklı Kişiler	79.80 ile 92.93 arası
Hassan ve Bhuiyan [20]	Sağlıklı Kişiler	90.01 ile 98.01 arası
Wu ve ark. [21]	TUA Şüphesi	81.7 toplam başarı
Uçar ve ark. [25]	TUA Hastaları	73.36 toplam başarı
Boostani ve ark. [22]	Sağlıklı Kişiler	87.06 toplam başarı
	Hasta Kişiler	69.05 toplam başarı
Bu Tez Çalışmasında	TUA Hastaları	67.60 ile 84.62 arasında 75.77 toplam başarı 78.07 NREM2 Hariç

4.3.1. Uyku Apnesini Skorlamak İçin Kullanılan PSG İşaretleri ve İşaret Özellikleri

Uyku apnesinin skorlanması için EEG işaretlerinden F4, C4 ve O2; EOG işaretlerinden E1 ve E2; çene, sağ bacak ve sol baktan alınan birer EMG işaretleri; solunum değişkenlerinden solunum basıncı, solunum çabası ve oksijen saturasyonu olmak üzere 11 adet işaret kullanılmıştır. Bu işaretler zaman ekseninde işaret özelliklerinin yaklaşık sabit kaldığı 1 saniyelik dilimlere bölünerek, her bir işaret dilimin ortalaması, enerjisi, gücü ve etkin değeri Denklem (4.1) – (4.4) ile hesaplanmıştır. İşaret özelliklerinin yanında işaretlerin mutlak değerlerinin ortalaması hesaplanmış ve işaretler normalize edilmiştir. Bu sayede hem uyku apnesinin skorlanması kolaylaşmakta hem de skrolama başarısı artmaktadır. Bu işlemler aşağıda gösterildiği gibi hesaplanmaktadır.

Bazı işaretlerin ortalama değeri sıfır olduğundan, bu işaretlerin mutlak değerlerinin ortalamasının kullanılması daha uygundur. Bir x işaretinin mutlak değerlerinin ortalaması,

$$\mu_a = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (4.6)$$

ile hesaplanır. Bir x işaretinin mutlak değerlerinin ortalamasını “1.0” olacak şekilde normalize etmek için aşağıda verilen denklem kullanılır.

$$\bar{x}_j = \frac{|x_j|}{\mu_a}, j = 1..N \quad (4.7)$$

Bir x işaretini “0.0” ile “1.0” aralığına normalize etmek için

$$\bar{x}_j = \frac{x_j - \min(x)}{\max(x) - \min(x)}, j = 1..N \quad (4.8)$$

denklemi kullanılır. Bu denklemde $\min(x)$ ve $\max(x)$ işlemleri sıra ile x işaretinin en küçük ve en büyük değerlerini göstermektedir.

4.3.2. Polisomnografi İşaretlerinin Özelliklerinin Çıkarılması

Uyku apnesini skorlamak için önce üst hava yolunda görülen solunum işaretine bakılır. Fakat sadece bu işaret tek başına yeterli değildir. Bilhassa merkezi uyku apnesini belirleyebilmek için solunum çabasının olup olmadığına da bakılır ve kandaki oksijen saturasyonu da kontrol edilir. Normal solunum ile uyku apnesi ve hipopne durumunda işaret özellikleri Bölüm 2’de açıklanmıştır.

Uyku apnesinin skorlanmasında kullanılan PSG işaretlerinin önışleme ile iyileştirilmesi ve özelliklerinin çıkarılması için aşağıda verilen işlem adımları takip edilerek özellikler tablosu oluşturulmuştur.

- a) Bazı durumlarda biyolojik işaretler içinde bilgi taşımayan doğrusal eğilimler (DC değerler) bulundurmaktadır. Bu eğilimler işaret genliğini ve ortalamasını olumsuz etkilemektedir. Biyolojik işaretler bu DC değerlerden temizlenerek karakteristiği daha doğru bir işaret elde edilmiştir.
- b) AASM kurallarına göre EEG ve EOG işaretleri 0.3-35 Hz; EMG işaretleri 10-100 Hz; Solunum basıncı 0.03-100 Hz; Solunum çabası 0.1-15 Hz kesim frekanslarına sahip 4. dereceden Butterworth band geçiren filtresi ile istenmeyen frekans bileşenlerinden temizlenmiştir.
- c) Hastaların fizyolojik özellikleri birbirinden farklı olduğundan aynı şartlarda bile işaret genliklerinde farklılıklar görülmektedir. Bu farklılıkları düzeltmek için her bir işaret mutlak değerlerinin ortalaması “1.0” olacak şekilde normalize edilmiştir. Normalizasyon işlemi Denklem (4.6) – (4.7) kullanılarak yapılmıştır.
- d) Oksijen saturasyonu genliği % (yüzde) olarak ifade edildiğinden, bu işaretin genliği Denklem (4.8) ile “0.0” – “1.0” arasında normalize edilmiştir.

- e) Bütün işaretler baştan sona kadar 1 saniyelik dilimlere bölünerek Denklem (4.1) – (4.4) ile işaret özellikleri çıkarılmıştır.
- f) İstatistiki yöntemlerle artefakt olarak işaretlenen zaman dilimleri özellik tablosundan çıkarılmıştır.

Burada anlatılan ön işlemler bütün hastalardan alınan işaretler için tekrar edilerek özellik tabloları çıkarılmış ve bu tablolar uyku apnesini skorlamak için kullanılmıştır. Uyku apnesi skorlama kuralları AASM referans el kitaplarında ayrıntılı olarak verilmiştir [3, 16].

4.3.3. Uyku Apnesi Skorlama Başarısının Hesaplanması

Uyku apnesi skorlamasının başarısını hesaplamak için tıbbi uzman tarafından yapılan skorlama ile otomatik skorlama karşılaştırılır. Doğru ve hatalı skorlama zamanları aşağıda verilen mantıksal denklemler ile hesaplanır.

$$\begin{aligned} & \text{Eğer bir zaman diliminde yapılan skorlamalar aynı ise} \\ & \text{doğru skorlama yapılmıştır.} \end{aligned} \quad (4.9)$$

$$\begin{aligned} & \text{Eğer bir zaman diliminde yapılan skorlamalar farklı ise} \\ & \text{hatalı skorlama yapılmıştır.} \end{aligned} \quad (4.10)$$

Doğru ve hatalı skorlama zamanlarının toplamı, toplam skorlama zamanını verir. Skorlama başarısı aşağıdaki denklem ile hesaplanır.

$$\text{Skorlama Başarısı} = \frac{\text{Doğru Skorlama Zamanı}}{\text{Toplam Skorlama Zamanı}} \quad (4.11)$$

4.4. Algoritmik Yöntemle Uyku Apnesinin Skorlanması

Algoritmik skorlama, görsel skorlama kurallarına göre skorlama yapan bir tıbbi uzman deneyiminin algoritmik yöntemlerle gerçekleştirilmesidir. Bu amaçla bir skorlama algoritması oluşturulmuştur. Bu çalışmanın başarısı uzman deneyimine ve bu deneyimlerin algoritmik olarak gerçekleştirilmesine bağlıdır.

Bu çalışmada algoritmik skorlama için solunum işaretleri kullanılmıştır. Solunum işaretinin genliğinin en az 10 saniye süre ile %70 azalması hipopne, %90 azalması uyku apnesi olarak tanımlanır. Görsel skorlama kuralları daha ayrıntılı olmakla beraber

temelde bu kurala uyar. Uyku apnesinin uzman deneyimine bağılı olarak algoritmik yöntemlerle skorlanmasında da bu kural esas kabul edilmiştir.

4.4.1. Algoritmik Skorlama Kuralları

Görsel skorlama kurallarına göre uyku apnesinin skorlanması için 10 saniye genişliğinde iki işaret dilimi alınır. Denklem (4.1) ile her bir işaret dilimlerindeki ortalama işaret genlikleri (sıra ile *Ortalama1* ve *Ortalama2*) hesaplanır. Uyku apnesinin başlangıcı ve bitişi aşağıda verilen kurallar ile belirlenir.

$$\text{Kural 1: Eğer } \left(\frac{\text{Ortalama2}}{\text{Ortalama1}} \right) < \text{Apne eşik değeri ise uyku apnesinin başlangıcı} \quad (4.12)$$

$$\text{Kural 2: Eğer } \left(\frac{\text{Ortalama1}}{\text{Ortalama2}} \right) < \text{Apne eşik değeri ise uyku apnesinin sonu} \quad (4.13)$$

Apne eşik değeri, normalize edilmiş solunum işaretinin %10'unu gösterir. AASM kurallarına göre bu değer "0.1"dir. Bu tez çalışmasında kullanılan işaretler ile yapılan denemelerde Apne eşik değerinin "0.2" alınması daha başarılı sonuçlar vermiştir. Hastaların fizyolojik özellikleri, uzman deneyimleri ve algoritmanın gerçekleştirme şekli bu değer belirlenmesinde etkilidir. Bu eşik değeri, ortalama sekiz saat süre ile kayıt yapılan 74 hastanın verilerinde yapılan hesaplamalardan elde edilmiştir. Daha başka ve daha fazla hasta verilerinde bu oran değişebilir ve daha iyi skorelama başarıları elde edilebilir. Skorelama algoritması ile uyku apnesinin skorlanması, Denklem (4.12)-(4.13) ile ifade edilen kurallar ile yapılmıştır.

4.4.2. Uyku Apnesini Skorelamak için Algoritmanın Gerçekleştirilmesi

Uyku apnesini otomatik olarak skorelamak için bir skorelama algoritması oluşturulmuştur. Bu algoritmanın kuralları görsel skorelama kuralları ile uyumludur. Aşağıda verilen bu algoritma bütün hastalar için tekrar edilmiştir. Skorelama için özellikler tablosundaki solunum işaretinin özellikleri kullanılmıştır.

Görsel skorlama kurallarına göre oluşturulan skorlama algoritması:

-
- 1) Uyku apnesini skorlamaya başla.
 - 2) Hastanın işaret özellikleri tablosunu al.
 - 3) İşaret dilimlerinin indekslerini ayarla.
 - 4) Birinci işaret diliminin ortalama genliğini hesapla (Ortalama1).
 - 5) İkinci işaret diliminin ortalama genliğini hesapla (Ortalama2).
 - 6) *Kural 1* ile uyku apnesinin başlangıcını işaretle.
 - 7) *Kural 2* ile uyku apnesinin bitişini işaretle.
 - 8) İşaret dilimlerinin indekslerini yeniden ayarla.
 - 9) Eğer bütün işaret skorlanmadı ise 4. adıma git.
 - 10) Skorlama başarısını hesapla.
 - 11) Skorlamayı tamamla.
-

4.4.3. Skorlama Algoritması İle Yapılan Uyku Apnesi Skorlamasının Sonuçları

Skorlama algoritması ile yapılan skorlama çalışması özet olarak Tablo 4.10'da verilmiştir. Bu yöntem ile 74 hastanın uyku apnesi skorlaması yapılmış olup, skorlama başarısı Denklem (4.11) ile hesaplanmıştır. Hastaların AHI'leri 0.3 ile 100.4 arasında değişmekte, ortalaması ise 21.83'tür. 14 hastanın (hastaların %19'u) skorlama başarısı %50'nin altından olduğundan bu hasta verilerinin işlenmesinde, skorlama algoritması başarısız olarak değerlendirilmiştir. Toplam skorlama başarısı %69.35'tir. 45 hastanın (hastaların %60'ı) skorlama başarısı ortalama başarıdan daha yüksek, 29 hastanın (hastaların %40'ı) skorlama başarısı ortalama başarının altındadır. Skorlama algoritmasının başarılı olduğu değerlendirilen 60 hastanın (hastaların %81'i) skorlama başarı ortalaması %81.23 olarak hesaplanmıştır. Bu değer oldukça iyi bir başarı ortalamasıdır.

AHI'leri 5'ten küçük olan normal kişilerin sayısı 9'dur (hastaların %12'si). Bu kişilerde ortalama skorlama başarısı %44.30 olarak hesaplanmıştır. Bu grupta 4 kişinin skorlama başarısı çok iyi, 5 kişinin skorlama başarısı çok kötüdür. Skorlama algoritmasının bu grup hastaların skorlanmasında başarısız olduğu görülmektedir.

Tablo 4.10. Skolama algoritması ile yapılan uyku apnesi skolamasının başarı oranları.

		En Küçük	En Büyük	Ortalama
Toplam 74 kişi	AHI	0.30	100.40	21.83
	Skolama Başarısı (%)	0.26	100.00	69.35
Normal 9 kişi	AHI	0.30	4.70	2.72
	Skolama Başarısı (%)	0.26	100.00	44.30
Hafif Seviye 25 kişi	AHI	5.00	14.00	9.99
	Skolama Başarısı (%)	1.52	98.23	77.71
Orta Seviye 23 kişi	AHI	16.00	29.00	20.70
	Skolama Başarısı (%)	6.12	95.90	75.34
Ağır Hasta 17 kişi	AHI	31.90	100.40	50.87
	Skolama Başarısı (%)	20.54	83.55	62.23

AHI'leri 5 ile 15 arasında olan hafif uyku apnesi hastalarının sayısı 25'tir (hastaların %34'ü). Bu kişilerde ortalama skolama başarıları %77.71 olarak hesaplanmıştır. Bu gruptaki 19 hastanın skolama başarıları ortalamanın üstünde, 6 hastanın skolama başarıları ortalamanın altında kalmıştır. Skolama algoritması bu grup hastaların skorlanmasında oldukça başarılıdır.

AHI'leri 15 ile 30 arasında olan orta seviyede uyku apnesi hastalarının sayısı 23'tür (hastaların %31'i). Bu kişilerde ortalama skolama başarıları %75.34 olarak hesaplanmıştır. Bu gruptaki 15 hastanın skolama başarıları ortalamanın üstünde 8 hastanın skolama başarıları ortalamanın altında kalmıştır.

AHI'leri 30'dan daha büyük olan ağır seviyede uyku apnesi hastalarının sayısı 17'dir (hastaların %23'ü). Bu kişilerde ortalama skolama başarıları %62.23 olarak hesaplanmıştır. Bu gruptaki 7 hastanın skolama başarıları ortalamanın üstünde, 10 hastanın skolama başarıları ortalamanın altındadır.


4.4.4. Skolama Algoritması İle Yapılan Uyku Apnesi Skolamasının

Değerlendirilmesi

Şekil 4.2'de skolama algoritması ile yapılan bir skolama görülmektedir. "0" seviyeleri, uyku apnesini "1" seviyeleri normal solunumu göstermektedir. Bu şekilde otomatik

skorlama ile görsel skorlamanın uyumlu olduğu görülmektedir. Skorlama kurallarının gerçekleştirilme şekline bağlı olarak skorlanan uyku apnesinin genişliklerinde bazı farklar görülmektedir. Skorlama algoritmasına ilave kural eklenerek bu farkların önlenmesi mümkündür.

Görsel skorlama kurallarının en temel iki kuralına göre yapılan skorlama algoritması ile skorlama çalışmasında uyku apnesi olmayan normal hastaların haricinde iyi bir skorlama başarısı elde edilmiştir. Skorlama algoritması hasta kişilerin PSG işaretlerine göre optimize edildiğinden, normal kişilerin skorlama başarısı beklenen ortalamanın altında



Şekil 4.2. Skorlama algoritması ile yapılan uyku apnesi skorlama. (a) Solunum işareti, (b) Görsel skorlama ve (c) Algoritmik skorlama.

kalmıştır. Skorlama algoritmasına, uzman deneyimine göre daha fazla kural eklenerek normal hastaların skorlama başarısı da yükseltilebilir. Bu yöntemin gelişmeye açık olması, sebep ile sonuç arasındaki bağlantının tam olarak bilinmesi büyük bir avantajdır.

4.5.Yapay Sinir Ağları İle Uyku Apnesinin Skorlanması

Görsel skorlama kurallarına göre skorlama algoritmasıyla uyku apnesinin skorlanması için kullanılan hasta verileri bu defa YSA ile skorlama yapmak için kullanılmıştır. YSA ile yapılan skorlama başarısı, işaret özellikleri ile YSA model parametrelerinin belirlenmesine bağlıdır. YSA'nın tasarımı ana hatları ile doğru olduğu zaman tasarımda yapılan küçük hatalar YSA tarafından düzeltilmekte, skorlama başarısı yaklaşık sabit kalmaktadır. Özellik tablolarında beklenen ağ çıkışları “-1.0” ve “+1.0” olacak şekilde planlanmıştır. Bu değerler YSA'da kullanılan sinir hücrelerinin transfer fonksiyonu ile uyumlu seçilmiştir.

YSA tasarımında katman sayısının seçimi için herhangi bir kural yoktur. Bu çalışmada 2 ve 3 katmanlı YSA modelleri ile denemeler yapılmıştır.

4.5.1. Sinir Hücrelerinin Sayısının Seçimi

Sinir hücrelerinin sayısının seçiminde herhangi bir kural olmadığı için iki katmanlı YSA'lar ile yapılan denemelerde gizli ve çıkış katmanında sıralı olarak (6, 1), (9, 1), (12, 1) ve (15, 1) adet sinir hücreleri kullanılmıştır. Ayrıca yapılan denemelerde farklı sayıda işaret özelliği kullanıldığından gizli katmanda işaret özelliklerinin sayısı kadar ve işaret özelliklerinin sayısının iki katı kadar sinir hücreleri ile de denemeler yapılmıştır.

Üç katmanlı YSA'lar ile yapılan denemelerde gizli ve çıkış katmanlarında sıralı olarak (6, 3, 1), (10, 5, 1), (14, 7, 1) ve (18, 9, 1) adet sinir hücreleri ile denemeler yapılmıştır. Ayrıca yapılan denemelerde farklı sayıda işaret özelliği kullanıldığından birinci gizli katmanda işaret özelliklerinin sayısı kadar ve işaret özelliklerinin sayısının iki katı kadar sinir hücreleri, ikinci gizli katmanda işaret özelliklerinin sayısı kadar sinir hücreleri ile denemeler yapılmıştır.

Sinir hücresi transfer fonksiyonlarının seçimi için herhangi bir kural yoktur. Fakat başarılı bir uygulama için YSA'nın giriş ve çıkış verileri ile sinir hücrelerinin transfer

fonksiyonları uyumlu seçilmelidir. Uyku apnesinin skorlanması için kullanılan YSA modellerinde hiperbolik tanjant sigmoid transfer fonksiyonu kullanılmıştır.

4.5.2. Yapay Sinir Ağları İle Uyku Apnesini Skorlama

Uyku apnesini skorlamak için kullanılan YSA'ların çıkışlarında skorlama başarısını artırmak için morfolojik işlemler ve hareketli ortalamalar kullanılarak işaret iyileştirmeleri yapılmış ve altı farklı çıkış elde edilmiştir. Bu skorlama ve işaret iyileştirme işlemleri aşağıda verilmiştir.

- a) Ağ çıkışında hiçbir işlem yapılmadı.
- b) Ağ çıkışında morfolojik kapanma işlemi yapıldı.
- c) Ağ çıkışında morfolojik açılma işlemi yapıldı.
- d) Ağ çıkışında hareketli ortalama işlemi yapıldı.
- e) Ağ çıkışında önce hareketli ortalama sonra morfolojik kapanma işlemi yapıldı.
- f) Ağ çıkışında önce hareketli ortalama sonra morfolojik açılma işlemi yapıldı.

Toplam altı çıkışın her biri aşağıda verilen skorlama kuralları ile ayrı ayrı skorlanarak başarı ortalamaları hesaplanmıştır.

$$\text{Kural 1: Eğer } Ağ \text{ çıkışı} \geq 0 \text{ ise uyku apnesi değildir.} \quad (4.14)$$

$$\text{Kural 2: Eğer } Ağ \text{ çıkışı} < 0 \text{ ise uyku apnesidir.} \quad (4.15)$$

Uyku apnesini skorlamak için bu çalışmada farklı işaret özellikleri, iki veya üç katmanlı ağ yapıları, farklı sayıda sinir hücrelerinin kullanılması ve YSA çıkışında işaret iyileştirmelerinin yapılması ile oluşturulan 288 YSA modeli oluşturulmuştur. YSA'nın eğitimi için 12 farklı öğrenme yöntemi kullanılmıştır. Ancak bütün YSA modellerinin bütün öğrenme yöntemleri ile eğitilmesi uzun zaman alacağından iki farklı grup deneme yapılmıştır. YSA'nın eğitim verilerinde 21467 adet özellik verisi vardır. Bu veri 5.96 saatlik zamana karşılık gelmektedir. Yapılan denemelerde bu kadar özellik verisinin yeterli olduğu görülmüştür.

Birinci grup denemelerde 288 farklı YSA modeli Levenberg-Marquardt öğrenme algoritması ile eğitilmiş ve yapılan skorlamanın doğruluğu Denklem (4.11) ile hesaplanmıştır. Bu denemede en başarılı YSA modeli ile %89.60 başarı ortalaması elde

edilmiştir. Bu YSA modeli üç katmanlı bir yapı olup her bir katmanda sıra ile 18, 9 ve 1 adet sinir hücresi kullanılmıştır. Farklı sayıda işaret grupları ile denemeler yapılmış olup en iyi başarı ortalaması, solunum basıncı ve solunum çabası işaretleri kullanıldığında elde edilmiştir. YSA'nın girişinde bu işaretlerin ortalaması kullanılmıştır. YSA'nın çıkışında morfolojik kapanma işleminin kullanılması ile elde edilen sonuçların daha iyi olduğu görülmüştür. Morfolojik yapı elemanının 9 saniye genişliğinde olması durumunda en iyi sonuçlar elde edilmiştir.

Yapılan denemelerde en iyi ikinci başarı ortalaması %89.54'tür. Bu sonucu veren model ise yine üç katmanlı bir yapı olup, her bir katmanda sıra ile 4, 2 ve 1 adet sinir hücresi kullanılmıştır. Bu modelde de solunum basıncı ve solunum çabası işaretleri ve bu işaretlerin etkin değeri kullanılmıştır.

Üç katmanlı modeller ile yapılan denemelerde iki model başarısız olmuştur. Bu modellerde skorum başarıları %38.11 ve %32.36 olarak hesaplanmıştır. Bu iki modelin dışında başarı ortalamaları %78.36 ile %89.60 arasında değişmektedir. Başarısız olan modellerin YSA katmanlarında sıra ile 2, 2 ve 1 sinir hücresi kullanılmıştır. Bu YSA modelleri yapılan denemelerde en az sinir hücrelerine sahip modellerdir.

İki katmanlı yapıların en başarısız iki modelinde başarı ortalamaları %36.35 ve %19.43'tür. Bu iki modelin dışında başarı ortalamaları %77.44 ile %89.31 arasında değişmektedir. En başarısız modelin YSA katmanlarında sıra ile 15 ve 1 adet sinir hücresi kullanılmıştır. Bu model iki katmanlı modellerde en çok sinir hücrelerine sahip modeldir.

İkinci grup denemelerde, birinci grup denemelerde elde edilen en başarılı YSA modeli diğer 11 farklı öğrenme yöntemi ile eğitilmiş ve başarı ortalamaları hesaplanmıştır. Bu denemeye ait ortalama test başarıları Tablo 4.11'de verilmiştir. Yapılan bu denemede Bayesian Regularization öğrenme yöntemi ile %89.48 başarı ortalaması elde edilmiştir. Levenberg-Marquardt ile elde edilen başarı ortalaması bu başarı ortalamasından daha yüksektir.

Tablo 4.11. Levenberg-Marquardt öğrenme algoritması kullanılarak seçilen en iyi YSA modelinin farklı öğrenme algoritmaları ile eğitilmesi durumunda elde edilen ortalama test başarıları.

S/N	Öğrenme Algoritması	Ortalama Test Başarısı (%)
1	Bayesian Regularization [77]	89.48
2	Conjugate Gradient with Powell/Beale Restarts [76]	89.22
3	One Step Secant [81]	89.02
4	Resilient Backpropagation [78, 79]	88.65
5	BFGS Quasi-Newton [76, 78]	88.59
6	Polak-Ribière Conjugate Gradient [82]	88.48
7	Variable Learning Rate Gradient Descent [82]	87.85
8	Scaled Conjugate Gradient [80]	87.60
9	Fletcher-Powell Conjugate Gradient [81]	87.44
10	Gradient Descent [83]	78.97
11	Gradient Descent with Momentum [83]	54.28

Tablo 4.11’de verilen 11 farklı öğrenme algoritması ile eğitilen YSA’ların 9’unda oldukça iyi başarı ortalamaları elde edilmiştir. Bu başarı ortalamaları %87.44 ile %89.48 arasında değişmektedir. Diğer iki öğrenme algoritması ile eğitilen YSA’ların skortlama başarıları biraz düşük çıkmıştır. Gradient Descent öğrenme algoritmaları oldukça hızlı çalışmaktadır. Fakat bu öğrenme algoritması ile eğitilen YSA’ların başarı ortalamalarının düşük olduğu görülmektedir. Yapılan denemelerde öğrenme algoritmalarının başarı ortalamaları, veri kümeleri ve ağ yapılarına göre değişiklik göstermektedir. Yapılan her denemede birbirine yakın ancak farklı sonuçların alınacağı göz önünde tutulmalıdır.

4.5.3. Yapay Sinir Ağları İle Yapılan Uyku Apnesi Skortlamasının Sonuçları

Levenberg-Marquardt algoritması ile eğitilen YSA ile bulunan uyku apnesi skortlaması sonuçları özet olarak Tablo 4.12’de verilmiştir. Bu yöntem ile 74 hastanın uyku apnesi skortlaması yapılmıştır. Hastaların AHI’leri 0.3 ile 100.4 arasında değişmekte olup ortalaması 21.83’tür. Skortlama başarıları %69.95 ile %100 arasında değişmektedir. Bu grup hasta verileri ile elde edilen ortalama başarı %89.60’tır. 49 hastanın (hastaların %66’sı) skortlama başarıları ortalama başarıdan daha yüksek, 25 hastanın (hastaların

Tablo 4.12. Levenberg-Marquardt algoritması ile eğitilen YSA ile bulunan uyku apnesi skorlamasının başarı oranları.

		En Küçük	En Büyük	Ortalama
Toplam 74 kişi	AHI	0.30	100.40	21.83
	Skorlama Başarısı (%)	69.95	100.00	89.60
Normal 9 kişi	AHI	0.30	4.70	2.72
	Skorlama Başarısı (%)	91.29	100.00	96.22
Hafif Seviye 25 kişi	AHI	5.00	14.00	9.99
	Skorlama Başarısı (%)	73.35	98.57	92.45
Orta Seviye 23 kişi	AHI	16.00	29.00	20.70
	Skorlama Başarısı (%)	72.69	96.48	88.54
Ağır Hasta 17 kişi	AHI	31.90	100.40	50.87
	Skorlama Başarısı (%)	69.95	93.17	83.34

%34'ü) skorlama başarısı ortalama başarıdan daha düşüktür. Başarı ortalamaları en hafif hastalık grubundan en ağır hastalık grubuna doğru bir azalma gösterse de kabul edilebilir bir seviyededir.

AHI'leri 5'ten küçük olan normal kişilerin sayısı 9'dur (hastaların %12'si). Skorlama başarısı %91.29 ile %100 arasında değişmekte olup ortalama %96.22'dir. Bu gruptaki bütün kişilerin skorlama başarısı ortalamanın üstündedir.

AHI'leri 5 ile 15 arasında olan hafif uyku apnesi hastalarının sayısı 25'tir (hastaların %34'ü). Skorlama başarısı %73.35 ile %98.57 arasında değişmekte olup ortalama %92.45'tir. Bu gruptaki 21 hastanın skorlama başarısı ortalamanın üstünde, 4 hastanın skorlama başarısı ortalamanın altında kalmıştır.


AHI'leri 15 ile 30 arasında olan orta seviyede uyku apnesi hastalarının sayısı 23'tür (hastaların %31'i). Skorlama başarısı %72.69 ile %96.48 arasında değişmekte olup ortalama %88.54'tür. Bu gruptaki 15 hastanın skorlama başarısı ortalamanın üstünde, 8 hastanın skorlama başarısı ortalamanın altında kalmıştır.

AHI'leri 30'dan daha büyük olan ağır seviyede uyku apnesi hastalarının sayısı 17'dir (hastaların %23'ü). Skorlama başarısı %69.95 ile %93.17 arasında değişmekte olup


ortalama %83.34'tür. Bu gruptaki 4 hastanın skorlama başarısı ortalamanın üstünde, 15 hastanın skorlama başarısı ortalamanın altında kalmıştır.

Bu çalışmada YSA ile, algoritmik skorlama yöntemine göre daha iyi bir skorlama başarısı elde edilmiştir. YSA ile yapılan uyku apnesi skorlaması Şekil 4.3 ve Şekil 4.4'te görülmektedir. Şekil 4.3'te görüldüğü gibi solunum işareti YSA çıkışında daha belirgin bir hale gelmiş, morfolojik işlemler ile YSA çıkışı daha da iyileştirilmiştir.

Şekil 4.4'te YSA ve morfolojik filtre çıkışının skorlanması görülmektedir. Bu şekilde YSA çıkışında yapılan skorlama ile görsel skorlamanın uyumlu fakat morfolojik filtre çıkışında yapılan skorlamanın daha başarılı olduğu görülmektedir.



Şekil 4.3. YSA ile uyku apnesi skorlama. (a) Solunum İşareti, (b) YSA çıkışı ve (c) Morfolojik filtre çıkışı.



Şekil 4.4. YSA ile uyku apnesi skortlama. (a) Görsel skortlama, (b) YSA çıkışının skortlanması ve (c) Morfolojik filtre çıkışının skortlanması.

4.6. Uyarlamalı Sinirsel Bulanık Mantık Sistemi ile Uyku Apnesinin Skortlanması

Uyarlamalı sinirsel bulanık mantık sistemi, yapay sinir ağları ile bulanık mantığın (FIS) iyi yönlerinin birlikte kullanıldığı güçlü bir modeldir. YSA ve ANFIS birer işlem bloğu gibi düşünülebilir. Her ne kadar bu iki işlem bloğunun yapıları birbirinden farklı olsa da giriş ve çıkış yapıları benzerdir. YSA geri beslemeli ve çok katmanlı olabilir. ANFIS'in kullanımında üyelik fonksiyonları ve sayılarının değişmesine rağmen katman yapısı değişmemektedir.

ANFIS ile uyku apnesi skortlamak için, YSA ile kullanılan işaretler ve özellik tabloları kullanılmaktadır. Her iki yapının tasarım parametrelerinde benzerlikler olsa da

birbirinden farklı olan parametreleri de vardır. ANFIS'in yapısı ve tasarımı sebebiyle eğitimi ve ağ çıkışlarının hesaplanması daha uzun sürmektedir. Bu sebeple YSA ile elde edilen en iyi bazı özelliklerin ANFIS'in tasarımında kullanılması kolaylık sağlayacaktır.

4.6.1. Kullanılan İşaretler ve İşaret Özellikleri

YSA ile yapılan skorlamada en iyi skorlama başarısı, solunum basıncı ve solunum çabası işaretleri ile elde edilmiştir. Bu işaretler ANFIS ile skorlama denemelerinde aynı şekilde kullanılmış, diğer işaretler ile deneme yapılmamıştır. YSA ile yapılan skorlama denemelerinde kullanılan işaretlerin ortalama değeri, etkin değeri, enerjisi ve gücü olmak üzere 4 farklı özelliği, ANFIS ile yapılan denemelerde de kullanılmıştır. ANFIS'in eğitim verilerinde 21467 adet özellik verisi vardır. Bu veri 5.96 saatlik zamana karşılık gelmektedir. Yapılan denemelerde bu kadar özellik verisinin yeterli olduğu görülmüştür.

4.6.2. Üyelik Fonksiyonlarının Seçimi

Üyelik fonksiyonlarının ve sayısının belirlenmesi için herhangi bir kural olmadığı için farklı sayılarda üyelik fonksiyonları kullanılarak denemeler yapılmıştır. Deneme yapılan 7 farklı ANFIS modeli aşağıda verilmiştir.

- a) Her bir giriş için 2 adet genelleştirilmiş çan eğrisi üyelik fonksiyonu.
- b) Her bir giriş için 3 adet genelleştirilmiş çan eğrisi üyelik fonksiyonu.
- c) Her bir giriş için 4 adet genelleştirilmiş çan eğrisi üyelik fonksiyonu.
- d) Her bir giriş için 2 adet gauss eğrisi üyelik fonksiyonu.
- e) Her bir giriş için 2 adet asimetrik gauss eğrisi üyelik fonksiyonu.
- f) Her bir giriş için 2 adet üçgen üyelik fonksiyonu.
- g) Her bir giriş için 2 adet pi tipi üyelik fonksiyonu.

Bu çalışmada, kullanılan işaret özelliklerinin ve farklı üyelik fonksiyonlarının sayısına bağlı olarak toplam 28 farklı ANFIS modeli ile denemeler yapılmış ve model çıkışları hesaplanmıştır. YSA çıkışlarında yapılan işaret iyileştirmeleri ve skorlama başarısının değerlendirilmesi, ANFIS'in çıkışlarında da aynı şekilde kullanılmıştır.

4.6.3. Uyarlamalı Sinirsel Bulanık Mantık Sistemi İle Uyku Apnesi Skorlamasının Gerçekleştirilmesi

Uyku apnesini skorlamak için 28 farklı ANFIS modeli ile denemeler yapılmıştır. Ortalama en büyük başarı, işaret gücünün kullanıldığı işaret özellikleri ile elde edilmiştir. En iyi başarı ortalamasının elde edildiği ANFIS modelinde her bir giriş için 2 üçgen üyelik fonksiyonu kullanılmıştır. ANFIS'in çıkışında morfolojik işlemlerin kullanılması ile elde edilen sonuçların daha da iyileştiği görülmüştür.

ANFIS ile yapılan skorlama çalışması özet olarak Tablo 4.13'de verilmiştir. Bu yöntem ile 74 hastanın uyku apnesi skorlaması yapılmıştır. Hastaların AHI'leri 0.3 ile 100.4 arasında değişmektedir. Ortalama AHI 21.83'tür. Skorlama başarısı %71.01 ile %100 arasında değişmekte olup ortalama %88.81'dir. 45 hastanın (hastaların %60'ı) skorlama başarısı ortalama başarıdan daha yüksek, 29 hastanın (hastaların %40'i) skorlama başarısı ortalama başarıdan daha düşüktür.

4.6.4. Uyarlamalı Sinirsel Bulanık Mantık Sistemi İle Yapılan Uyku Apnesi Skorlamasının Sonuçları

Tablo 4.13'e göre hastalık teşhisi konulan 65 kişinin AHI'leri ise 5 ile 100.4 arasında değişmektedir. Bu hastaların skorlama başarıları %71.01 ile %98.77 olup ortalaması %88.81'dir.

AHI'leri 5'ten küçük olan normal kişilerin sayısı 9'dur (hastaların %12'si). Bu kişilerde ortalama skorlama başarısı %94.88 olarak hesaplanmıştır. Bu grupta 8 hastanın skorlama başarısı ortalamanın üstündedir.

AHI'leri 5 ile 15 arasında olan hafif uyku apnesi hastalarının sayısı 25'tir (hastaların %34'ü). Bu kişilerde ortalama skorlama başarısı %90.73 olarak hesaplanmıştır. Bu grupta 19 hastanın skorlama başarısı ortalamanın üstünde, 6 hastanın skorlama başarısı ortalamanın altında kalmıştır.

AHI'leri 15 ile 30 arasında olan orta seviyede uyku apnesi hastalarının sayısı 23'tür (hastaların %31'i). Bu hastalarda ortalama skorlama başarısı %87.39 olarak hesaplanmıştır. Bu grupta 13 hastanın skorlama başarısı ortalamanın üstünde 10 hastanın skorlama başarısı ortalamanın altında kalmıştır.


Tablo 4.13. ANFIS ile yapılan uyku apnesi skorlamasında elde edilen başarı oranları.

		En Küçük	En Büyük	Ortalama
Toplam 74 kişi	AHI	0.30	100.40	21.83
	Skorlama Başarısı (%)	71.01	100.00	88.81
Normal 9 kişi	AHI	0.30	4.70	2.72
	Skorlama Başarısı (%)	86.36	100.00	94.88
Hafif Seviye 25 kişi	AHI	5.00	14.00	9.99
	Skorlama Başarısı (%)	72.93	98.77	90.73
Orta Seviye 23 kişi	AHI	16.00	29.00	20.70
	Skorlama Başarısı (%)	71.01	96.80	87.39
Ağır Hasta 17 kişi	AHI	31.90	100.40	50.87
	Skorlama Başarısı (%)	71.60	91.90	84.70

AHI'leri 30'dan daha büyük olan ağır seviyede uyku apnesi hastalarının sayısı 17'dir (hastaların %23'ü). Bu kişilerde ortalama skorlama başarıları %84.70 olarak hesaplanmıştır. Bu grupta 5 hastanın skorlama başarıları ortalamanın üstünde, 12 hastanın skorlama başarıları ortalamanın altındadır.

ANFIS ile yapılan uyku apnesi skorlama çalışmasında başarı ortalaması %88.81 olarak hesaplanmıştır. Başarı oranları en hafif hastalık grubundan en ağır hastalık grubuna doğru bir azalma gösterse de yine de çok iyi bir başarı ortalaması elde edilmiştir.


Şekil 4.5'te ANFIS ile yapılan skorlama işlemine ait örnek bir zaman dilimi gösterilmiştir. Bu şekilde sırası ile solunum işaretinin özellikleri ile ANFIS ve morfolojik filtre çıkışlarından alınan işaretler görülmektedir. ANFIS çıkışında solunum işaretlerinin daha belirgin hale geldiği ve morfolojik filtre ile ANFIS çıkışının daha da iyileştiği görülmektedir. Şekil 4.6'da ise aynı solunum işaretinin görsel skorlama grafiği ile ANFIS ve morfolojik filtre çıkışlarının otomatik olarak skorlanması ile elde edilen grafikler görülmektedir.



Şekil 4.5. ANFIS ile uyku apnesi skorlama. (a) Solunum işareti, (b) ANFIS çıkışı ve (c) Morfolojik filtre çıkışı.

Şekil 4.6'dan ANFIS çıkışında yapılan skorlamanın görsel skorlama ile uyumlu olduğu fakat ANFIS çıkışının morfolojik filtre ile iyileştirilmesinden sonra yapılan skorlamanın daha iyi olduğu görülmektedir.

Bu çalışmada YSA ile ANFIS'de aynı işaret ve özellik tablolarını kullandığından dolayı yapılan uyku apnesi skorlama çalışmaları birbiri ile uyumlu sonuçlar vermiştir.



Şekil 4.6. ANFIS ile uyku apnesi skrlama. (a) Görsel skrlama, (b) ANFIS çıkışının skrlanması ve (c) Morfolojik filtre çıkışının skrlanması.

4.7. Uyku Apnesi Skrlama Çalışmasının Değerlendirilmesi

Bu tez çalışmasında uyku apnesinin skrlanması için algoritmik bir yöntem, YSA ve ANFIS kullanılmıştır. Literatürde mevcut skrlama başarıları ile bu tez çalışmasında elde edilen skrlama başarıları Tablo 4.14’te verilmiştir.

Tablo 4.14’e göre uyku apnesi skrlamak için çoğunlukla ya bütün PSG işaretleri ya da sadece EKG işaretlerinin kullanıldığı görülmektedir. Oksijen saturasyonu veya solunum sesleri gibi tek kanal işaret kullanılarak da skrlama yapılmıştır. Fakat bu şekilde tek kanal işaret ile skrlama yapılması tavsiye edilmemektedir [46].

Tablo 4.14. Bu tez çalışmasında ve literatürde yapılan araştırmalara göre uyku apnesinin skorlanması için yapılan çalışmalar, kullanılan yöntemler ve başarı oranları.

Araştırmacı	Hedef Kitle	İşaretler	Skorlama Yöntemleri	Başarı Oranları (%)
Berdinas ve ark. [4]	Yetişkinler	PSG	YSA	94.62
Tağluk ve ark. [6]	Yetişkinler	PSG	YSA	73.42
Romero ve ark. [7]	Yetişkinler	PSG	YSA	83.78
Canosa ve ark. [27]	Yetişkinler	PSG	Zekî Sistemler	92.31
Güneş ve ark. [28]	Yetişkinler	PSG	YSA	84.14
Rios ve Erazo [29]	Çocuklar	PSG	SVM YSA LR	100 28.67 47.3
Surrel ve Murali [31]	Yetişkinler	EKG	Zaman-Frekans Analizi	92.15
Li ve ark. [33]	Yetişkinler	EKG	YSA	85
Varon ve ark. [34]	Yetişkinler	EKG	LDA SVM LS-SVM	71.43 72.6 84.7
Sharma ve Sharma [35]	Yetişkinler	EKG	KNN YSA SVM	77.03 93.04 97.14
Hassan ve Haque [36]	Yetişkinler	EKG	Makine Öğrenme Algoritmaları	91.94
Hassan [37]	Yetişkinler	EKG	Adaboost Algoritması	87.33
Hassan ve Haque [38]	Yetişkinler	EKG	Bagging Algoritması	85.97
Babaeizadeh ve ark. [39]	Yetişkinler	EKG	Solunumdan Elde Edilen KAHD	88
Javid ve ark. [44]	Yetişkinler	Solunum Sesleri	LDA	70
Tobal ve ark. [30]	Çocuklar	O2Sat	LR	86.3
Villar ve ark. [45]	Çocuklar	O2Sat	Frekans Analizi	Orta: 81.3 Ağır: 85.3
Bu Tez Çalışmasında	Yetişkinler	PSG	Skorlama Algoritması YSA ANFIS	69.35 89.60 88.81

Uyku apnesi skorlamak için YSA ve ANFIS'in yanında SVM, LR, LDA, KNN, zaman-frekans analizleri ve özel öğrenme algoritmaları gibi birçok algoritma kullanılmıştır. Skorlama başarıları çoğunlukla %70 ile %95 aralığında değişmektedir. Bu skorlama başarılarında kullanılan işaretlerin etkisi büyüktür.

Tablo 4.14'te skarlama alıřmalarının yetiřkin insanlarda ve ocuklarda ayrı ayrı yapıldığı görölmektedir. Yetiřkin insanlarda kullanılan yöntemlerin, ocuklarda aynı başarıyı vermediğı görölmüřtür [29].

Tablo 4.14'teki verilere göre bu tez alıřmasında yapılan uyku apnesi skarlama alıřması oldukça başarılı görölmektedir.



5. BÖLÜM

TARTIŞMA, SONUÇ VE ÖNERİLER

Bu tez çalışmasında Kahramanmaraş Sütçü İmam Üniversitesi Tıp Fakültesi araştırma ve uygulama hastanesi uyku laboratuvarında geceyi geçiren hastalardan alınan PSG işaretleri kullanılarak uyku ve tıkalı tip uyku apnesi skorlaması yapılmıştır.

Uyku seviyeleri, PSG işaretleri kullanılarak AASM skorum kurallarına göre YSA ile skorumuştur. Skorum için ortalama sekiz saatlik kayıt süresi olan EEG, EOG ve EMG işaretleri kullanılmış, önişleme ile yapılan iyileştirmelerden sonra bu işaretlerin özellikleri çıkarılmıştır. Bu özelliklerin çıkarılması için EEG işaretleri dalgacık dönüşümü ile alt bandlarına ayrılmış ve her bir EEG bandının işaret gücü ayrı ayrı hesaplanmıştır. EOG ve EMG işaretleri alt bandlarına ayrılmadan işaret güçleri hesaplanarak her bir epok için özellik tabloları oluşturulmuştur.

Uyku seviyelerinin skorumasında farklı sayıda YSA katmanı, her katmanda farklı sayıda sinir hücreleri ve farklı öğrenme algoritmaları ile denemeler yapılmıştır. Birbirine yakın sonuçlar elde edilmesine rağmen en iyi başarı ortalaması üç katmanlı YSA ile elde edilmiştir. Skorum çalışmasında ortalama başarı hesaplanarak yapılan skorum değerlendirilmiştir. Farklı öğrenme yöntemlerinin etkisini görmek için çok sayıda deneme yapılmasına rağmen başarı ortalamalarının birbirine yakın olduğu görülmüştür.

Uyku seviyelerinin skorumasında oldukça iyi başarı ortalamaları elde edilmiştir. NREM1 uyku evresinin skorum başarısının, diğer uyku evrelerinin skorum başarılarına yakın ama biraz daha düşük olduğu görülmüştür. Toplam uyku içerisinde NREM1 uyku dönemi çok kısa ve bu uyku dönemine ait az sayıda epok bulunduğundan YSA, NREM1 uyku evresini yeterince öğrenememiştir.

Uyku seviyelerinin skorumasında kullanılan PSG işaretleri uyku apnesi hastalarından alındığından, bu hastaların uykuları sık sık bölünmekte ve uyku skorumasını olumsuz etkilemektedir. Yapılan çalışmanın ortalama başarısı literatürde yapılan çalışmalar ile

karşılaştırılmış, aynı hasta grubunda yapılan uyku skorlamaları ile uyumlu sonuçlar elde edilmiştir.

Uyku apnesinin skorlanması için, uyku skorlamasında kullanılan PSG işaretleri kullanılmıştır. Ancak skorlama kuralları farklı olduğundan kullanılan işaret özelliklerine yeni özellikler eklenmiş ve yeni özellik tabloları oluşturulmuştur. Uyku apnesi, görsel skorlama kurallarına göre oluşturulan bir skorlama algoritması, YSA ve ANFIS olmak üzere üç farklı yöntem kullanılarak skorlanmıştır. Üç farklı tipi olan uyku apnesinin en yaygın görülen tipi TUA olduğundan bu çalışmada da TUA skorlaması yapılmıştır. Uyku apnesini skorlamak için EEG, EOG, EMG ve solunum işaretleri kullanılmıştır. İşaret kaydı yapılan kişiler uyku apnesi hastası veya şüphelisi olduklarından gece boyunca yapılan işaret kayıtlarında sorunlar görülmüş, işaret özellikleri istatistiki olarak değerlendirilerek işaretlerde bulunan bazı artefaktlar giderilmiştir.

Algoritmik yöntem ile uyku apnesinin skorlanması için görsel skorlama kurallarına dayalı bir algoritma kullanılmıştır. Hafif ve orta sınıf uyku apnesi vakalarında oldukça iyi başarı ortalamaları, ağır sınıf hastalarda ise kabul edilebilir sonuçlar elde edilmiştir. Skorlama algoritması hasta kişilerin PSG işaretlerinin skorlanması için optimize edildiğinden hastalık şüphesi olan fakat normal kişilerin PSG işaretlerinin skorlama başarısı beklenenden düşük çıkmıştır. Görsel skorlama kurallarına göre yapılan skorlama algoritmasına daha fazla kural eklendiğinde başarı ortalamalarının daha yüksek olacağı beklenmektedir.

YSA ile uyku apnesi skorlama denemelerinde farklı sayıda YSA katmanı ve her katmanda farklı sayılarda sinir hücresi kullanılmıştır. YSA'lar farklı 12 öğrenme algoritması ile eğitilmiştir. Genellikle birbiri ile uyumlu sonuçlar alınmıştır. En iyi sonuç solunum işaretlerinin ortalamalarının kullanıldığı üç katmanlı YSA modeli ile elde edilmiştir.

ANFIS ile her bir giriş için farklı sayıda ve farklı üyelik fonksiyonlarının kullanıldığı modeller ile denemeler yapılmıştır. YSA ile en iyi başarının elde edildiği işaret özellikleri ANFIS ile yapılan denemelerde de kullanılmıştır. Bu denemelerde ANFIS çıkışlarının birbiri ile uyumlu olduğu görülmüştür. En iyi başarı ortalaması, her bir giriş için iki üçgen üyelik fonksiyonunun kullanıldığı ANFIS modeli ile elde edilmiştir.

Uyku apnesi skorlamasında YSA ve ANFIS ile elde edilen sonuçlar birbiri ile uyumludur. YSA ve ANFIS ile elde edilen skorlama başarıları, skorlama algoritmasıyla yapılan skorlama başarısından daha yüksek bulunmuştur. Fakat skorlama algoritmasının girişi ve çıkışı arasındaki bağlantının bilinmesi bu yöntemin güçlü tarafıdır. YSA ve ANFIS gibi yöntemler ile yapılan skorlama çalışmalarında modellemenin daha kolay olması ve yüksek başarı oranlarına rağmen literatürde algoritmik yöntemler ile yapılan çalışmaların devam etmesi bu yöntemlerin gelişmeye açık olduğunu göstermektedir.

YSA ile yapılan uyku ve uyku apnesi skorlama denemelerinde, iki katmanlı yapılar ile oldukça başarılı skorlamalar yapılmakla birlikte, üç katmanlı yapılar ile daha yüksek skorlama başarıları elde edilmiştir. YSA'ların katmanlarında gereğinden az veya gereğinden fazla sinir hücrelerinin kullanılması durumunda yapılan denemeler başarısız olmuştur.

Bu tez çalışmasında yapılan uyku apnesi skorlaması literatürde yapılan çalışmalar ile karşılaştırıldığında tatmin edici başarı ortalamaları elde edilmiştir. Yapılan çalışmalarda skorlama başarısının yüksek olması, öncelikle kullanılan yöntemle bağlıdır. Ancak kullanılan veri tabanları ve bu verilerin görsel skorlamasını yapan tıbbi uzmanın tecrübesi de etkilidir.

Hem algoritmik yöntemlerle hem de YSA ve ANFIS gibi yapay zekâ teknikleri ile yapılan otomatik skorlama çalışmalarının uyku ve uyku apnesi çalışmalarına katkı sağlayacağı düşünülmektedir. Uyku apnesi hastalarının tedavi planlaması uyku ve uyku apnesi skorlamasına göre yapıldığından bu konuda yapılan çalışmaların insan sağlığına önemli katkıları olacaktır.

KAYNAKLAR

1. Carskadon, M.A., Dement, W.C., 2011. Normal Human Sleep: An Overview, 16-26. Monitoring and staging human sleep (Kryger, M. H., Roth, T., Dement, W. C.). Elsevier Saunders.
2. Guyton, A. C., Hall, J. E., 2001. Beynin Etkinlik Durumları-Uyku; Beyin Dalgaları; Epilepsi; Psikozlar, 689-696. Tıbbi Fizyoloji (T. Demiralp). Yüce Yayınları A.Ş. ve Nobel Tıp Kitabevleri Ltd. Şti.
3. Çiftçi, T. U., 2012. Solunum olaylarının skorlanması. **Türk Toraks Dergisi**, 13:27-29.
4. Berdiñas, B. G., Pereira, E., H., Barral, D. P., 2012. A mixture of experts for classifying sleep apneas. **Expert Systems with Applications**, 39:7084-7092.
5. Schaffernocker, T., Morrison, J., Khayat, R. N., 2014. Central sleep apnea: From pathophysiology to clinical management. **Journal of Cardiovascular Disease**, 2:32-38.
6. Tagluk, M. E., Akin, M., Sezgin, N., 2010. Classification of sleep apnea by using wavelet transform and artificial neural networks. **Expert Systems with Applications**, 37:1600–1607.
7. Romero, O. F., Berdinas, B. G., Betanzos, A. A., Bonillo, V. M., 2005. A new method for sleep apnea classification using wavelets and feedforward neural networks. **Artificial Intelligence in Medicine**, 34:65-76.
8. Öter, A., Aydoğan, O., Tuncel, D., 2019. Dalgacık Dönüşümü ile Yapay Sinir Ağları Kullanılarak Uyku Evrelerinin Otomatik Sınıflandırılması. **Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi**, Cilt 8, Sayı 1, 59-68.
9. Öter, A., Aydoğan, O., Tuncel, D., 2017. Tıkayıcı Uyku Apnesinin Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi ile Sınıflamasında Üyelik Fonksiyonlarının Etkisinin İncelenmesi. **Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi**, Cilt 20, Sayı 2, Sayfa 74-80.

10. Aydoğan, O., Öter, A., Güney, K., Kıymık, M. K., Tuncel, D., 2016. Automatic Diagnosis of Obstructive Sleep Apnea Hypopnea Events Using Respiratory Signals. **Journal of Medical Systems**, Cilt 40, Sayı 12.
11. Aydoğan, O., Öter, A., Güney, K., Automatic Diagnosis of Obstructive Type Sleep Apnea Cases Using Respiratory Markers. *International Conference on Natural Science and Engineering, (ICNASE'16)*. 19-20 Mart 2016, Kilis, Türkiye.
12. Aydoğan, O., Güney, K., Öter, A., 2019. K-Komplekslerinin Otomatik Belirlenmesi. *International Symposium on Advanced Engineering Technologies (ISADET)*. 02-03 Mayıs 2019, Kahramanmaraş, Türkiye.
13. Aydoğan, O., Öter, A., Doğmuş, O., Güney, K., 2017. Uyku İğciğinin Yapay Sinir Ağları ve Morfolojik Filtreler Kullanılarak Tespit Edilmesi. **Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi**, Cilt 20, Sayı 4, Sayfa 190-196.
14. Öter A., Aydoğan O., Güney K., Automatic Determination of Sleep Spindles using Teager Energy Operator. *2nd International Mediterranean Science and Engineering Congress, (IMSEC)*. 25-27 Ekim 2017. Adana, Türkiye.
15. Aydoğan, O., Güney, K., Öter, A., Kalp Atım Hızı Değişiminin Belirlenmesi. *International Symposium on Advanced Engineering Technologies, (ISADET)*. 02-03 Mayıs 2019, Kahramanmaraş, Türkiye.
16. Berry, R. B., Brooks, R., Gamaldo, C. E., et al., for the American Academy of Sleep Medicine, 2017. The AASM Manual for the Scoring of Sleep and Associated Events: Rules, Terminology and Technical Specifications. American Academy of Sleep Medicine, Darien, Illinois, USA, 89.
17. Çiftçi, T. U., 2012. Uyku evrelerinin skorlanması. **Türk Toraks Dergisi**, 13:21-26.
18. Köktürk, O., 2013. Uyku Kayıtlarının Skorlanması. **Solunum**, 15:14-29.

19. Bajaj, V., Pachori, R. B., 2013. Automatic classification of sleep stages based on the time-frequency image of EEG signals. **Computer Methods and Programs in Biomedicine**, 112 :320–328.
20. Hassan, A. R., Bhuiyan, M. I. H., 2017. An automated method for sleep staging from EEG signals using normal inverse Gaussian parameters and adaptive boosting. **Neurocomputing**, 219:76-87.
21. Wu, H., Talmon, R., Lo, Y., 2015. Assess sleep stage by modern signal processing techniques. **IEEE Transactions on Biomedical Engineering**, 6(4):1159-1168.
22. Boostani, R., Karimzadeh, F., Nami, M., 2017. A comparative review on sleep stage classification methods in patients and healthy individuals. **Computer Methods and Programs in Biomedicine**, 140:77-91.
23. Sors, A., Bonnet, S., Mirek, S., Vercueil, L., Payen, J. F., 2018. A convolutional neural network for sleep stage scoring from raw single-channel EEG. **Biomedical Signal Processing and Control**, 42:107-114.
24. Michiellia, N., Acharya, U. R., Molinari, F., 2019. Cascaded LSTM recurrent neural network for automated sleep stage classification using single-channel EEG signals. **Computers in Biology and Medicine**, 106:71-81.
25. Uçar, M. K., Bozkurt, M. R., Bilgin, C., Polat, K., 2018. Automatic sleep staging in obstructive sleep apnea patients using photoplethysmography, heart rate variability signal and machine learning techniques. **Neural Computing and Applications**, 29:1-16.
26. Crespo, A., Álvarez, D., Tobal, G. G., Castro, T. A., Arroyo, C. A., Hornero, R., Campo, F. D., 2016. Automated apnea-hypopnea index estimation by means of neural networks to assist in the diagnosis of sleep apnea in adults. *American Thoracic Society International Conference*, May 2016, San Francisco, USA, *American Journal of Respiratory and Critical Care Medicine*, 193.

27. Canosa, M. C., Pereiro, M. C., Ramos, M. G., Pereira, E. H., Bonillo, V. M., Egana, M. M., Hernando, H. V., 2003. An intelligent system for the detection and interpretation of sleep apneas. **Expert Systems with Applications**, 24:335-349.
28. Günes, S. Polat, K., Yosunkaya, Ş., 2010. Multi-class f-score feature selection approach to classification of obstructive sleep apnea syndrome. **Expert Systems with Applications**, 37: 998-1004.
29. Ríos, S. A., Erazo, L., 2016. An automatic apnea screening algorithm for children. **Expert Systems With Applications**, 48:42-54.
30. Tobal, G. C. G., Álvarez, M. L. A., Álvarez, D., Campoc, F., Santos, J. T., Hornero, R., Diagnosis of pediatric obstructive sleep apnea: Preliminary findings using automatic analysis of airflow and oximetry recordings obtained at patients' home. **Biomedical Signal Processing and Control**, 18: 401-407.
31. Surrel, G., Rincon, F., Atienza, D., Murali, S., 2016. Low-power wearable system for real-time screening of obstructive sleep apnea. *IEEE Computer Society Annual Symposium on VLSI*, 11-13 July 2016, Pittsburgh, PA, USA, IEEE.
32. Thomas, R. J., Mietus, J. E., Peng, C. G., Gilmartin, G., Daly, R. W., Goldberger, A. L., Gottlieb, D. J., 2007. Differentiating obstructive from central and complex sleep apnea using an automated electrocardiogram-based method. **Sleep**, 30(12):1756-1769.
33. Li, K., Pan, W., Li, Y., Jiang, Q., Liu, G., 2018. A method to detect sleep apnea based on deep neural network and hidden Markov model using single-lead ECG signal. **Neurocomputing**, 294:94-101.
34. Varon, C., Caicedo, A., Testelmans, D., Buyse, B., Huffel, S. V., 2015. A novel algorithm for the automatic detection of sleep apnea from single-lead ECG. **IEEE Transactions On Biomedical Engineering**, 62(9):2269-2278.

35. Sharma, H., Sharma, K. K., 2016. An algorithm for sleep apnea detection from single-lead ECG using Hermite basis functions. **Computers in Biology and Medicine**, 77:116-124.
36. Hassan, A. R., Haque, M. A., 2017. An expert system for automated identification of obstructive sleep apnea from single-lead ECG using random under sampling boosting. **Neurocomputing**, 235:122-130.
37. Hassan, A. R., 2016. Computer-aided obstructive sleep apnea detection using normal inverse Gaussian parameters and adaptive boosting. **Biomedical Signal Processing and Control**, 29:22-30.
38. Hassan, A. R., Haque, M. A., 2016. Computer-aided obstructive sleep apnea screening from single-lead electrocardiogram using statistical and spectral features and bootstrap aggregating. **Biocybernetics and biomedical engineering**, 36: 256-266.
39. Babaeizadeh, S., Zhou, S. H., Pittman, S. D., White, D. P., 2011. Electrocardiogram-derived respiration in screening of sleep-disordered breathing. **Journal of Electrocardiology**, 44:700-706.
40. Jin, C., Sinencio, E. S., 2015. A home sleep apnea screening device with time-domain signal processing and autonomous scoring capability. **IEEE Transactions On Biomedical Circuits And Systems**, 9(1):96-104.
41. Nandakumar, R., Gollakota, S., Watson, N., 2015. Contactless sleep apnea detection on smartphones, 45-57. *Proceedings of the 13th Annual International Conference on Mobile Systems*, 18-22 May 2015, Florence, Italy.
42. Tran, T. H. Yuldashev, Z. M., Sadykova, E. V., 2018. A multilevel system for diagnosis of sleep apnea. *2018 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus)*, 29 January - 1 February 2018, Moscow, Russia.

43. Akhter, S., Abeyratne, U. R., Swarnkar, V., 2016. Characterization of REM/NREM sleep using breath sounds in OSA. **Biomedical Signal Processing and Control**, 25: 130-142.
44. Javaid, A. Q., Noble, C. M., Rosenberg, R., Weitnauer, M. A., 2016. Towards detection of sleep apnea events by combining different non-contact measurement modalities, 5307-5310. *Engineering in Medicine and Biology Society (EMBC), Annual International Conference of the IEEE*, 16-20 August 2016.
45. Villar, F. V., Álvarez, D., Gozal, L. K., Tobal, G. C. G., García, V. B., Crespo, A., Campo, F., Gozal, D., Hornero, R., 2018. Utility of bispectrum in the screening of pediatric sleep apnea-hypopnea syndrome using oximetry recordings. **Computer Methods and Programs in Biomedicine**, 156: 141-149.
46. Blanco, A. M. A., Álvarez, D., Crespo, A., Arroyo, C. A., Hernández, A. C., Tobal, G. C. G., Hornero, R., Campo, F. D., 2017. Assessment of automated analysis of portable oximetry as a screening test for moderate-to-severe sleep apnea in patients with chronic obstructive pulmonary disease. **PloS One**, 12(11): e0188094.
47. Marcos, J. V., Hornero, R., Alvarez, D., Aboy, M., Campo, F. D., 2012. Automated prediction of the apnea-hypopnea index from nocturnal oximetry recordings. **IEEE Transactions On Biomedical Engineering**, 59(1):141-149.
48. Marcos, J. V., Hornero, R., Alvarez, D., Campo, F. D., Zamarron, C., 2009. Assessment of four statistical pattern recognition techniques to assist in obstructive sleep apnoea diagnosis from nocturnal oximetry. **Medical Engineering and Physics**, 31:971-978.
49. Fakhr, S. M., Torbati, M. M., Hill, M., Simpson, D., Bucks, R. S., Carroll, A., Hill, C. M., 2013. Respiratory cycle related EEG changes: Modified respiratory cycle segmentation. **Biomedical Signal Processing and Control**, 8:838-844.

50. Estevez, D. A., Varela, I. F., 2019. Large-scale validation of an automatic EEG arousal detection algorithm using different heterogeneous databases. **Sleep Medicine**, 57:6-14.
51. Singh, P., Joshi, S. D., Patney, R. K., Saha, K., 2015. Fourier-based feature extraction for classification of eeg signals using eeg rhythms. **Circuits, Systems, and Signal Processing**, 35:3700-3715.
52. Bhattacharyya, A., Sharma, M., Pachori, R. B., Sircar, P., Acharya, U. R., 2018. A novel approach for automated detection of focal EEG signals using empirical wavelet transform. **Natural Computing Applications**, 29:47-57.
53. Lakshmi, M. R., Prasad, T. V., Prakash, V. C., 2014. Survey on eeg signal processing methods. **International Journal of Advanced Research in Computer Science and Software Engineering**, 4(1):84-91.
54. Amin, H. U., Malik, A. S., Ahmad, R. F., Badruddin, N., Kamel, N., Hussain, M., Chooi, W. T., 2015. Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques. **Australasian Physical & Engineering Sciences in Medicine**, 38:139-149.
55. Liu, Q., Chen, Y. F., Fan, S. Z., Abbod, M. F., Shieh J. S., 2016. A comparison of five different algorithms for EEG signal analysis in artifacts rejection for monitoring depth of anesthesia. **Biomedical Signal Processing and Control**, 25: 24-34.
56. López, A., Ferrero, F., Postolache, O., 2019. An affordable method for evaluation of ataxic disorders based on electrooculography. **Sensors**, 19(17), 3756.
57. Munteanu, M., Magda, A., Rusu, C., Ciorap, R., Vlădăreanu, L. EOG Signal Processing Algorithm Used in Eye Movement Detection. *The 13th International Scientific Conference eLearning and Software for Education*. 27-28 April 2017, Bucharest.

58. Lee, K. R., Chang, W. D., Kim, S., Im, C. H., 2017. Real-time “eye-writing” recognition using electrooculogram. **IEEE Transactions on Neural Systems And Rehabilitation Engineering**, 25(1):37-48.
59. Bardhan, J., Suma, P., Jyothirmayi, M., 2017. Motorized wheelchair control using electrooculogram and head gear. *2016 International Conference on Inventive Computation Technologies (ICICT)*, 26-27 August 2016, Coimbatore, India, IEEE.
60. Khasnobish, A. Chakravarty, K., Chatterjee, D., Sinha, A., 2017. Wavelet based head movement artifact removal from electrooculography signals. *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 5-9 Mart 2017, New Orleans, LA, USA, IEEE.
61. Romero, F., Alonso, F. J., Cubero, J., Marín, G. G., 2015. An automatic SSA-based de-noising and smoothing technique for surface electromyography signals. **Biomedical Signal Processing and Control**, 18:317-324.
62. Yousefi, J., Wright, A. H., 2014. Characterizing EMG data using machine-learning tools. **Computers in Biology and Medicine**, 51:1-13.
63. Kiguchi, K., Tanaka, T., Fukuda, T., 2004. Neuro-fuzzy control of a robotic exoskeleton with EMG signals. **IEEE Transactions on Fuzzy Systems**, 12(4):481-490.
64. Mishra, V. K., Bajaj, V., Kumar, A., Sharma, D., Singh, G. K., 2017. An efficient method for analysis of EMG signals using improved empirical mode decomposition. **International Journal of Electronics and Communications (AEÜ)**, 72:200-209.
65. McCool, P., Petropoulakis, L., Soraghan, J. J., Chatlani, N., 2015. Improved pattern recognition classification accuracy for surface myoelectric signals using spectral enhancement. **Biomedical Signal Processing and Control**, 18:61-68.

66. Reaz, M. B. I., Hussain, M. S., Yasin, F. M., 2006. Techniques of EMG signal analysis: detection, processing, classification and applications. **Biological Procedures Online**, 8:11-35.
67. Veer, K., Sharma, T., 2016. A novel feature extraction for robust EMG pattern recognition. **Journal of Medical Engineering & Technology**, 40(4):149-154.
68. Khushaba, R. N., Al-Timemy, A., Kodagoda, S., Nazarpour, K., 2016. Combined influence of forearm orientation and muscular contraction on EMG pattern recognition. **Expert Systems With Applications**, 61:154-161.
69. Mahaphonchaikul, K., Sueaseenak, D., Pintavirooj, C., Sangworasil, M., Tungjitkusolmun, S., 2010. EMG signal feature extraction based on wavelet transform. ECTI-CON2010: *The 2010 ECTI International Confernce on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, 19-21 May 2010, Chiang Mai, Thailand, IEEE.
70. Guyton, A. C., Hall, J. E., 2001. Akciğer Ventilasyonu, 432-443. Tıbbi Fizyoloji (L. Çakar). Yüce Yayınları A.Ş. ve Nobel Tıp Kitabevleri Ltd. Şti.
71. McCulloch, W., S., Pitts, W., 1943, A Logical Calculus of The Ideas Immanent in Nervous Activity, **Bulletin of Mathematical Biophysics**, Volume 5, 115-133.
72. Rosenblatt, F., 1958. The Perceptron: A Probabilistic Model For Information Storage and Organization in The Brain, **Psychological Review**, Vol. 65, No. 6, 386-408.
73. Minsky, M., Papert, S., 1969. Perceptrons: An Introduction to Computational Geometry, M.I.T. Press, Cambridge, 258.
74. Rumelhart, D., E., McClelland, J., L., Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations, M.I.T. Press, Cambridge, 567.
75. Elmas, Ç., 2003. Yapay Sinir Ağları, Seçkin Yayıncılık San. ve Tic. A.Ş., Ankara, 192.

76. Ubeyli, E.D., 2009. Analysis of EEG signals by implementing eigenvector methods/recurrent neural networks. **Digital Signal Processing**, Volume 19, Page 134-143.
77. Khagi, B., Lee, K. H., Choi, K. Y., Lee, J. J., Kwon, G.-R., Yang, H.-D., 2021. VBM-Based Alzheimer's Disease Detection from the Region of Interest of T1 MRI with Supportive Gaussian Smoothing and a Bayesian Regularized Neural Network. **Applied Sciences**, Volume 11, Issue 13.
78. Cömert, Z., Kocamaz, A. F., 2017. A study of artificial neural network training algorithms for classification of cardiocography signals. **Bitlis Eren University Journal of Science and Technology**, 7(2) 93–103.
79. Forouzanfar, M., Dajani, H. R., Groza, V. Z., Bolic, M., Rajan, S., 2011. Feature-Based Neural Network Approach for Oscillometric Blood Pressure Estimation. **IEEE Transactions on Instrumentation and Measurement**, Vol. 60, No. 8., Page 2786-2796.
80. Mohan, Y., Chee, S. S., Xin, D. K. P., Foong, L. P., Artificial Neural Network for Classification of Depressive and Normal in EEG. *IEEE EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, 2016. Kuala Lumpur, Malaysia.
81. Birvinskas, D., Jusas, V., Martisius, I., Damasevicius, R., EEG Dataset Reduction and Feature Extraction using Discrete Cosine Transform. *Sixth UKSim/AMSS European Symposium on Computer Modeling and Simulation*, 2012. Page(s):199 – 204, Malta, Malta.
82. Mohamad, F. N., Megat Ali, M. S. A., Jahidin, A. H., Saaid, M. F., Noor, M. Z. H., Principal Component Analysis and Arrhythmia Recognition Using Elman Neural Network. *IEEE 4th Control and System Graduate Research Colloquium*, 19 - 20 Aug. 2013, Shah Alam, Malaysia.
83. Mohapatra, S. K., Palo, H. K., Mohanty, M. N., Detection of Arrhythmia using Neural Network. *The First International Conference on Information Technology and Knowledge Management*, 22–23 December 2017, New Delhi, India.

84. Zadeh, L. A., 1965. Fuzzy Sets. **Information and Control**, 8:338-353.
85. Jang, J. S. R., 1993. ANFIS: Adaptive-Network-Based Fuzzy Inference System. **IEEE Transactions on Systems, Man, and Cybernetics**, 23(3): 665-685.
86. Image Processing Toolbox Reference, The MathWorks, Inc., 2718.
87. Rechtschaffen, A. and Kales, A., 1968. A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects. Public Health Service, US Government Printing Office, Washington DC.
88. Fletcher, R. W., Fletcher, S. W., 2005. Clinical Epidemiology. Lippincott Williams and Wilkins, USA, 252.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Osman AYDOĞAN
Uyruğu: Türkiye (T.C)

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Yüksek Lisans	Erciyes Üniversitesi, Elektronik Anabilim Dalı.	1998
Lisans	Erciyes Üniversitesi, Elektronik Mühendisliği	1994
Lise	Merkez Teknik Lisesi Kayseri	1988

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
1997-Halen	Kahramanmaraş Sütçü İmam Üniversitesi	Öğretim Görevlisi
1996-1997	İskur Tekstil ve Tic A.Ş., Kahramanmaraş	Elektrik Şefi
1995	Kayseri Büyükşehir Belediyesi	Elektronik Mühendisi

YABANCI DİL

İngilizce

YAYINLAR

1. Öter A., Aydoğan, O., Tuncel, D., 2019. Dalgacık Dönüşümü ile Yapay Sinir Ağları Kullanılarak Uyku Evrelerinin Otomatik Sınıflandırılması. **Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi**, Cilt 8, Sayı 1, 59-68.
2. Öter A., Aydoğan, O., Tuncel, D., 2017. Tıkayıcı Uyku Apnesinin Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi ile Sınıflamasında Üyelik Fonksiyonlarının Etkisinin İncelenmesi. **Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi**, Cilt 20, Sayı 2, Sayfa 74-80.
3. Aydoğan, O., Öter, A., Doğmuş, O., Güney, K., 2017. Uyku İğciğinin Yapay Sinir Ağları ve Morfolojik Filtreler Kullanılarak Tespit Edilmesi. **Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi**, Cilt 20, Sayı 4, Sayfa 190-196.
4. Öter, A., Kıymık, M. K., Aydoğan, O., Tuncel, D., 2016. Tıkayıcı Uyku Apnesinin Yapay Sinir Ağları ve Morfolojik Filtreler kullanılarak Sınıflandırılması İçin Yeni Yöntem. **Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi**, Cilt 19, Sayı 2, Sayfa 52-57.
5. Aydoğan, O., Öter, A., Güney, K., Kıymık, M. K., Tuncel, D., 2016. Automatic Diagnosis of Obstructive Sleep Apnea Hypopnea Events Using Respiratory Signals. **Journal of Medical Systems**, Cilt 40, Sayı 12.

Tam metin bildiri (Uluslararası)

1. Aydoğan, O., Güney, K., Öter, A., K-Komplekslerinin Otomatik Belirlenmesi. International Symposium on Advanced Engineering Technologies (ISADET). 02-03 Mayıs 2019, Kahramanmaraş, Türkiye.
2. Aydoğan, O., Güney, K., Öter, A., Kalp Atım Hızı Değişiminin Belirlenmesi. International Symposium on Advanced Engineering Technologies, (ISADET). 02-03 Mayıs 2019, Kahramanmaraş, Türkiye.

3. Öter, A., Aydoğan, O., Güney, K., Automatic Determination of Sleep Spindles using Teager Energy Operator. 2nd International Mediterranean Science and Engineering Congress, (IMSEC). 25-27 Ekim 2017, Adana, Türkiye.
4. Aydoğan, O., Öter, A., Obstructive sleep apnea scoring by Adaptive Neuro-Fuzzy Inference System. 2nd International Mediterranean Science and Engineering Congress (IMSEC). 25-27 Ekim 2017, Adana, Türkiye.
5. Öter, A., Aydoğan, O., Kıymık, M. K., Scoring of Obstructive Sleep Apnea via Artificial Neural Networks and Morphological Filters. International Conference on Natural Science and Engineering, (ICNASE'16). 19-20 Mart 2016, Kilis, Türkiye.
6. Aydoğan, O., Öter, A., Güney, K., Automatic Diagnosis of Obstructive Type Sleep Apnea Cases Using Respiratory Markers. International Conference on Natural Science and Engineering, (ICNASE'16). 19-20 Mart 2016, Kilis, Türkiye.
7. Aydoğan, O., Öter, A., Kıymık, M. K., Tuncel, D., Automatic classification of sleep stages with artificial neural networks according to visual scoring rules. 2015 23rd Signal Processing and Communications Applications Conference, (SIU 2015). 16-19 Mayıs 2015, Malatya, Türkiye.