

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**UYKU EVRELERİNİN EEG İŞARETLERİ
KULLANILARAK SINIFLANDIRILMASINDA YENİ BİR
YAKLAŞIM**

DOKTORA TEZİ

Elektronik Yüksek Müh. Murat YILDIZ

Enstitü Anabilim Dalı : ELEKTRİK - ELEKTRONİK MÜH.

Enstitü Bilim Dalı : ELEKTRONİK

Tez Danışmanı : Prof. Dr. Etem KÖKLÜKAYA

Şubat 2009

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

UYKU EVRELERİNİN EEG İŞARETLERİ
KULLANILARAK SINIFLANDIRILMASINDA YENİ BİR
YAKLAŞIM


DOKTORA TEZİ

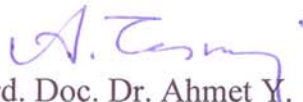
Elektronik Yüksek Müh. Murat YILDIZ

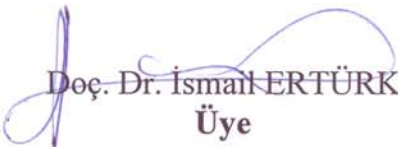
Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ
Enstitü Bilim Dalı : ELEKTRONİK


Bu tez 25 / 02 / 2009 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.


Prof. Dr. Abdullah
FERİKOĞLU
Jüri Başkanı


Prof. Dr. Etem
KÖKLÜKAYA
Üye


Yrd. Doç. Dr. Ahmet Y.
TEŞNELİ
Üye


Doç. Dr. İsmail HERTÜRK
Üye


Doç. Dr. Yusuf OYSAL
Üye

TEŞEKKÜR

EEG konusunda çalışmamı destekleyen ve çalışmalarım süresince bilgilerini benimle paylaşan, çalışmalarımı yönlendiren danışman hocam Prof. Dr. Etem KÖKLÜKAYA ve Yrd. Doç. Dr. Cabir VURAL hocama, yapay sinir ağları hususunda yardımlarını esirgemeyen arkadaşım Yrd. Doç. Dr. Ali GÜLBAĞ'a ve tezimi okuyarak gerekli düzeltmeleri yapmamda yardımcı olan arkadaşlarım Yrd. Doç. Dr. M. Recep BOZKURT, ve araştırma görevlileri Özhan ÖZKAN ve İhsan BAYIR'a ayrıca emeği geçen tüm arkadaşlarıma teşekkür ederim.

Ayrıca maddi – manevi desteklerini hiç esirgemeyen ve haklarını hiçbir zaman ödeyemeyeceğim anne ve babama; çalışmalarım esnasında gösterdiği sabır ve yaptığı fedakârlıklardan dolayı sevgili eşime; mutluluk ve huzur kaynağım sevgili kızım Ayşe Yasemin'e sonsuz şükranlarımı sunarım.

Bu tez çalışması Sakarya Üniversitesi Bilimsel Araştırma Projeleri Komisyon Başkanlığı tarafından 2006.50.02.057 numaralı proje kapsamında desteklenmiştir.

Murat YILDIZ

İÇİNDEKİLER

TEŞEKKÜR.....	ii
İÇİNDEKİLER	iii
SİMGELER VE KISALTMALAR LİSTESİ	vi
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ.....	xiii
ÖZET.....	xv
SUMMARY.....	xvi
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
EEG İŞARETLERİ	11
2.1. Giriş.....	11
2.2. EEG İşaretlerinin Frekans İçeriği	12
2.2.1. Delta dalgaları	13
2.2.2. Teta dalgaları	14
2.2.3. Alfa dalgaları	14
2.2.4. Beta dalgaları	14
2.2.5. Gamma dalgaları	15
2.3. Diğer Önemli Beyin Aktivitesi İşaretleri	16
2.4. EEG Elektrot Sistemi ve EEG'nin Kaydedilmesi	17
2.5. EEG Teşhisinin Temel Prensipleri	19
BÖLÜM 3.	
UYKU EEG'Sİ VE UYKU EVRELERİ	21

3.1. Giriş.....	21
3.2. Uyku Fonksiyonu	21
3.3. Uyku Evreleri	23
3.3.1. Uyanıklık (evre W)	26
3.3.2. Hareket zamanı	27
3.3.3. Evre 1	27
3.3.4. Evre 2	28
3.3.5. Evre 3	29
3.3.6. Evre 4	30
3.3.7. REM uykusu (evresi)	31
3.4. Hipnogram	31
3.5. Uyku Evreleri Standartlarının Sınırları	32

BÖLÜM 4.

UYKU EEG’İNDE ÖZELLİK ÇIKARMA VE İŞARETLERİN ÖN-

İŞLENMESİ	34
4.1. Giriş.....	34
4.2. Zaman Kuşağında Kullanılan Özelliklerin Çıkarılması	34
4.2.1. Ortalama	35
4.2.2. Standart sapma	35
4.2.3. Hjorth parametreleri	36
4.3. Frekans Kuşağındaki Özelliklerin Çıkarılması	37
4.3.1. Bağlı enerji yoğunlukları	37
4.3.2. Harmonik parametreler	38
4.3.3. Spektral kenar frekansı	39
4.4. İşaretlerin Ön-işlenmesi	39
4.4.1. Butterworth bant geçiren filtreleme	39
4.4.2. Yule-Walker AR yöntemi	43

BÖLÜM 5.

UYKU EVRELERİNİ GRUPLAMA VE SINIFLANDIRMA

YÖNTEMLERİ	49
5.1. Giriş.....	49

5.2. Temel Bileşen Analizi (PCA)	49
5.3. Kernel Tabanlı Temel Bileşen Analizi	52
5.3.1 Çok boyutlu uzayda vektörlerin ortalamasının sıfır yapılması	57
5.3.2 Kernel fonksiyonları	60
5.6. Olasılıksal Sinir Ağları	60
BÖLÜM 6.	
SİMÜLASYON UYGULAMALARI	66
6.1. Giriş	66
6.2. Temel Bileşen Analizi Simülasyon Sonuçları	68
6.2.1. Zaman-uzayı özellikleri simülasyon sonuçları	68
6.2.2. Frekans-uzayı özellikleri simülasyon sonuçları	69
6.2.3. Hibrit özellikleri simülasyon sonuçları	72
6.3. Yeni Veriler ile Temel Bileşen Analizi Simülasyon Sonuçları	75
6.4. Yeni Veriler ile Kernel Tabanlı Temel Bileşen Analizi Simülasyon Sonuçları	78
6.4.1. Polinomik kernel PCA simülasyon sonuçları	78
6.4.2. Radyal Kernel PCA simülasyon sonuçları	80
6.5. Olasılıksal Sinir Ağları Simülasyon Sonuçları	83
6.5.1. Hibrit özellikleri PNN simülasyon sonuçları	83
6.5.2. PCA bileşenleri olasılıksal sinir ağları simülasyon sonuçları	83
6.5.3. Polinomik Kernel PCA bileşenleri PNN simülasyon sonuçları	85
6.5.4. Radyal Kernel PCA bileşenleri PNN simülasyon sonuçları	86
BÖLÜM 7.	
SONUÇLAR VE ÖNERİLER	88
EKLER	95
KAYNAKLAR	104
ÖZGEÇMİŞ	113

SİMGELER VE KISALTMALAR LİSTESİ

A1-A2	: Elektrot yerleştirmede kulak lobu
AASM	: American Academy of Sleep Medicine
AR	: Öz ilişki (Autoregressive)
b	: Kernel fonksiyon parametresi
C	: Ortalama kovaryans matrisi
C_i	: i. evre için ortalama kovaryans matrisi
Cx	: Elektrot yerleştirmede merkez
CAPS	: Cyclic Alternating Pattern Sequences
d	: Kernel fonksiyon parametresi
D_i	: olasılık fonksiyonu pozisyon arası uzaklık
EEG	: Elektroensefalogram
EKG	: Elektrokardiyogram
EMG	: Elektromiyogram
EOG	: Elektrookülogram
EP	: Uyarılmış Potansiyel
$f_A(X)$: Olasılık fonksiyonu
F	: Kernel özellik uzayı
F_x	: Elektrot yerleştirmede başın önü
F_p	: Elektrot yerleştirmede ön kutup
GYSA	: Geriyayınımli Sinir Ağı
$k(x,y)$: Kernel fonksiyonu
K	: Kernel Uzayı özellik matrisi
\bar{K}	: Normalleştirilmiş Kernel uzayı özellik matrisi
m_i	: i. evre için ortalama vektörü
M	: Toplam epok sayısı
n	: Her epoktaki eleman sayısı

N_i	: i. evredeki epok sayısı
NFC	: Nöro-Fuzzy Sınıflandırıcı (Neuro-Fuzzy Classifier)
NREM	: Derin uyku
O	: Elektrot yerleştirmede başın arkası
P	: Elektrot yerleştirmede yan taraf
PCA	: Temel Bileşen Analizi (Principle Component Analysis)
PEB	: Her bandın toplam Spectral gücü
P_g	: Elektrot yerleştirmede nasopharyngeal
p_i	: i. evrenin önsel olasılığı
PNN	: Olasılıksal Sinir Ağı (Probabilistic Neural Network)
PSG	: Polisomnograf
q_1, q_2	: Özvektörün temel bileşenleri
R&K	: Rechtschaffen and Kales
REM	: Hızlı göz hareketleri (rapid eye movement)
RPEB	: Bağlı yüzde spektral güç
SWS	: Yavaş dalga uykusu (slow wave sleep)
t	: Toplam test epok sayısı
T	: matris transpozu
TPC	: Toplam spektral güç
x	: Her bir evre için bir epok vektörü
x_i	: Epoğun i. elemanı
X	: Olasılık fonksiyonu pozisyonu
X_{Ai}	: Olasılık fonksiyonu örnekleme noktası
v	: PCA'da özvektör
V	: Kernel tabanlı PCA'da özvektör
α	: Alfa bandı
α^M	: Özdeğerlere karşılık gelen özvektörler
$\bar{\alpha}^k$: Ortalanmış Kernel Matrisinin özvektörleri
β	: Beta bandı
θ	: Teta bandı
δ	: Delta bandı
ζ	: Uyku İğcikleri
κ	: K-kompeksleri

- σ^2 : Kernel fonksiyon parametresi
 σ_0 : \mathbf{x} özellik vektörünün varyansı
 σ_i : \mathbf{x} özellik vektörünün i . türevinin varyansı
 $\Phi(\mathbf{x})$: Kernel uzayı dönüştürme fonksiyonu

ŞEKİLLER LİSTESİ

Şekil 1.1.	EEG işaretinin sınıflandırılmasındaki adımlar	2
Şekil 2.1.	EEG işaretinden alınmış frekans bantlarına örnekler	15
Şekil 2.2.	Uyku İğciği ve K-Kompleks örneği	16
Şekil 2.3.	Uluslararası 10-20 elektrot yerleşim sistemi	18
Şekil 2.4.	EEG işaretlerinin ölçümünün blok şeması	19
Şekil 2.5.	Şuurun seviyesine bağlı EEG aktivitesi	20
Şekil 3.1.	EEG kaydında elektrotların yerleşimi	24
Şekil 3.2.	Uyanık evresine ait örnekler	27
Şekil 3.3.	Örnek bir hareket zamanı grafiği	27
Şekil 3.4.	Evre 1 örnekleri	28
Şekil 3.5.	Evre 2 örnekleri	29
Şekil 3.6.	Evre 3 örnekleri	30
Şekil 3.7.	Evre 4 örnekleri	30
Şekil 3.8.	REM evresi örnekleri	31
Şekil 3.9.	Normal bir insanın uyku hipnogramı	32
Şekil 3.10.	Uyanık evresinden Evre 1'e kademeli geçiş özelliği içeren bir epoğun ortası	33
Şekil 4.1.	Filtreleme işlemi	40
Şekil 4.2.	Uyku EEG'si için tasarlanan filtre karakteristiği	42
Şekil 4.3.	Filtrelenmemiş bir Evre 1 epoğu	42
Şekil 4.4.	Filtrelenmiş bir Evre 1 epoğu	43
Şekil 4.5.	Evre 1 için Yule-Walker AR parametreleri ile elde edilen güç spektrumları	46
Şekil 4.6.	Evre 2 için Yule-Walker AR parametreleri ile elde edilen güç spektrumları	46

Şekil 4.7.	Evre 3 için Yule-Walker AR parametreleri ile elde edilen güç spektrumları	47
Şekil 4.8.	Evre 4 için Yule-Walker AR parametreleri ile elde edilen güç spektrumları	47
Şekil 4.9.	REM Evresi için Yule-Walker AR parametreleri ile elde edilen güç spektrumları	47
Şekil 4.10.	Uyanık Evresi için Yule-Walker AR parametreleri ile elde edilen güç spektrumları	48
Şekil 5.1.	Temel bileşen analizi yöntemi blok diyagramı	50
Şekil 5.2.	Şekil 5.2. PCA ve kernel PCA temel fikirleri	52
Şekil 5.3.	Bir olasılıksal sinir ağı blok diagram	62
Şekil 5.4.	Bir nöronda kullanılan fonksiyonlar	63
Şekil 5.5.	Olasılık yoğunluk fonksiyonu	64
Şekil 5.6.	Eğitim örneği ve tahmin noktası arası uzaklık	65
Şekil 6.1.	Zaman-uzayı özelliklerinin uyku evrelerini ayırıştırma yeteneği (birbirine karışan evreler)	69
Şekil 6.2.	Zaman-uzayı özelliklerinin uyku evrelerini ayırıştırma yeteneği (nispeten ayırışan evreler)	69
Şekil 6.3.	Frekans-uzayı özelliklerinin uyku evrelerini ayırıştırma yeteneği (birbirine karışan evreler)	70
Şekil 6.4.	Frekans-uzayı özelliklerinin uyku evrelerini ayırıştırma yeteneği (birbirine karışan evreler)	70
Şekil 6.5.	Frekans-uzayı özelliklerinin uyku evrelerini ayırıştırma yeteneği (birbiri ile ayırışan evreler)	71
Şekil 6.6.	Frekans-uzayı özelliklerinin uyku evrelerini ayırıştırma yeteneği (birbiri ile ayırışan evreler)	72
Şekil 6.7.	Hibrit özelliklerin uyku evrelerini ayırıştırma yeteneği (birbirine karışan evreler)	73
Şekil 6.8.	Hibrit özelliklerin uyku evrelerini ayırıştırma yeteneği (birbirine karışan evreler)	74
Şekil 6.9.	Hibrit özelliklerin uyku evrelerini ayırıştırma yeteneği (birbiri ile ayırışan evreler)	74

Şekil 6.10.	Hibrit özelliklerin uyku evrelerini ayırıştırma yeteneği (birbiri ile ayrışan evreler)	75
Şekil 6.11.	PCA'nın uyku evrelerini ayırıştırma yeteneği (birbirine karışan evreler)	76
Şekil 6.12.	PCA'nın uyku evrelerini ayırıştırma yeteneği (nispeten karışan evreler)	76
Şekil 6.13.	PCA'nın uyku evrelerini ayırıştırma yeteneği (birbiri ile ayrışan evreler)	77
Şekil 6.14	PCA'nın uyku evrelerini ayırıştırma yeteneği (birbiri ile ayrışan evreler)	77
Şekil 6.15	Polinomik Kernel PCA'nın uyku evrelerini ayırıştırma yeteneği (birbirine karışan evreler)	78
Şekil 6.16	Polinomik Kernel PCA'nın uyku evrelerini ayırıştırma yeteneği (nispeten ayrışan evreler)	79
Şekil 6.17	Polinomik Kernel PCA'nın uyku evrelerini ayırıştırma yeteneği (nispeten ayrışan evreler).....	79
Şekil 6.18	Polinomik Kernel PCA'nın uyku evrelerini ayırıştırma yeteneği (birbiri ile ayrışan evreler)	80
Şekil 6.19	Radyal Kernel PCA'nın uyku evrelerini ayırıştırma yeteneği (birbirine karışan evreler)	81
Şekil 6.20	Radyal Kernel PCA'nın uyku evrelerini ayırıştırma yeteneği (nispeten ayrışan evreler)	81
Şekil 6.21	Radyal Kernel PCA'nın uyku evrelerini ayırıştırma yeteneği (nispeten ayrışan evreler)	82
Şekil 6.22	Radyal Kernel PCA'nın uyku evrelerini ayırıştırma yeteneği (birbiri ile ayrışan evreler)	82
Şekil 7.1	PCA'nın uyku evrelerini ayırıştırma yeteneği (birbirine karışan evreler)	92
Şekil 7.2	PCA'nın uyku evrelerini ayırıştırma yeteneği (birbiri ile ayrışan evreler)	92
Şekil 7.3	Polinomik Kernel PCA'nın uyku evrelerini ayırıştırma yeteneği (nispeten ayrışan evreler)	93

Şekil 7.4. Polinomik Kernel PCA'nın uyku evrelerini ayırıştırma yeteneđi (birbiri ile ayrıřan evreler)	93
---	----

TABLolar LİSTESİ

Tablo 2.1	Polisomnografıan elde edilen bazı EEG iřaretleri	12
Tablo 3.1	EEG zelliklerinin frekans, genlik ve zaman karakteristikleri ...	25
Tablo 3.2	Uyku evreleri ve her evrenin genel karakteristiđi	26
Tablo 4.1	EEG iřaretlerinin Spektral Enerji Bandları	38
Tablo 6.1	Eđitim ve test amacıyla kullanılan zellik vektrleri sayıları ...	67
Tablo 6.2	Eđitim ve test amacıyla kullanılan zellik vektrleri yeni sayıları	68
Tablo 6.3	Hibrit zellikler PNN simlasyon sonuları	83
Tablo 6.4	PCA ile en byk 5 temel bileřen PNN simlasyon sonuları ..	84
Tablo 6.5	PCA ile en byk 6 temel bileřen PNN simlasyon sonuları ..	84
Tablo 6.6	PCA ile en byk 7 temel bileřen PNN simlasyon sonuları ..	84
Tablo 6.7	PCA ile en byk 8 temel bileřen PNN simlasyon sonuları ..	85
Tablo 6.8	Polinomik Kernel PCA ile en byk 5 temel bileřen PNN simlasyon sonuları	85
Tablo 6.9	Polinomik Kernel PCA ile en byk 6 temel bileřen PNN simlasyon sonuları.....	86
Tablo 6.10	Polinomik Kernel PCA ile en byk 7 temel bileřen PNN simlasyon sonuları	86
Tablo 6.11	Polinomik Kernel PCA ile en byk 8 temel bileřen PNN simlasyon sonuları	86
Tablo 6.12	Radyal Kernel PCA ile en byk 5 temel bileřen PNN simlasyon sonuları	87
Tablo 6.13	Radyal Kernel PCA ile en byk 6 temel bileřen PNN simlasyon sonuları	87
Tablo 6.14	Radyal Kernel PCA ile en byk 7 temel bileřen PNN simlasyon sonuları	87

Tablo 6.15	Radyal Kernel PCA ile en büyük 8 temel bileşen PNN simülasyon sonuçları	87
Tablo 7.1	[95]'deki uyku evreleri için simülasyon sonucu	89
Tablo 7.2	Evreler için sınıflandırma başarısı (%)	91
Tablo 7.3	PCA bileşen izdüşümleri ile PNN simülasyon sonuçları	91
Tablo 7.4	Polinomik Kernel PCA bileşen izdüşümleri ile PNN simülasyon sonuçları	94

ÖZET

Anahtar kelimeler: EEG, uyku evrelerinin sınıflandırılması, uyku skorlama, temel bileşen analizi, Kernel PCA, olasılıksal sinir ağları.

Bu çalışmada uyku evrelerini sınıflandırma amacıyla EEG işaretlerinden çıkartılan özelliklerin uyku evrelerini ne ölçüde ayrıştırdığını belirlemek amacıyla yöntemler sunulmuş ve olasılıksal sinir ağları ile uygulaması yapılmıştır. Sunulan yöntemler, Karhunen-Loeve dönüşümü olarak da bilinen temel bileşen analizine dayalıdır. Uyku evrelerini sınıflandırmada sunulan özellikler ana üç grupta toplanmıştır: (i) zaman-uzayı özellikleri, (ii) frekans-uzayı özellikleri, (iii) hibrit özellikler. Yapılan detaylı simülasyonlarla her bir gruptaki özelliklerin uyku evrelerini ne oranda ayrıştırdığı belirlenmiş ve elde edilen önbilginin literatürdeki sonuçlarla uyumlu olduğu görülmüştür. Sunulan yöntemler sayesinde sınıflandırıcının başarılı sonuç verip vermeyeceğini ve sınıflandırma başarısının analiz kısmında elde edilen sonuçlarla uyumlu olup olmadığını sınıflandırıcıyı gerçekleştirmeden söylemek mümkündür. Temel bileşen analizi ile hangi özelliklerin sınıflandırma için daha iyi sonuç vereceği tespit edilmeye çalışılmıştır. Simülasyonlar hibrit özelliklerinin en iyi ayrıştırmayı verdiğini göstermiştir. Daha sonra, sadece hibrit özellikler kullanılarak temel bileşen analizi ve kernel tabanlı temel bileşen analizi ile uyku evrelerinin ne oranda ayrıştığı incelenmiştir. Yapılan bu ayrıştırma sonuçlarının geçerliliği olasılıksal sinir ağları kullanılarak gösterilmiştir. Çalışma sonunda temel bileşen analizi ve kernel tabanlı temel bileşen analizinin ayrıştırma yetenekleri olasılıksal sinir ağı aracılığıyla karşılaştırılmıştır.

A NEW APPROACH IN SLEEP STAGES CLASSIFICATION USING EEG SIGNALS

SUMMARY

Key Words: EEG, sleep stage classification, sleep scoring, principle component analysis, Kernel PCA, probabilistic neural networks.

In this study, methods were presented in order to determine how well features extracted from the EEG signals separate the sleep stages for the purpose of sleep stage classification and they were implemented using probabilistic neural networks. The proposed methods are based on the principle component analysis also known as the Karhunen-Loève transform. The features frequently used in the sleep stage classification studies were divided into three main groups: (i) time-domain features, (ii) frequency-domain features, and (iii) hybrid features. That how well features in each group separate the sleep stages was determined by performing extensive simulations and it was seen that the results obtained are in agreement with those available in the literature. Considering the fact that sleep stage classification algorithms consist of two steps, namely feature extraction and classification, it will be possible to tell a priori whether the classification step will provide successful results or not without carrying out its realization thanks to the proposed methods. Principle component analysis was used in order to determine the features that give the best results. Simulations showed that hybrid features give the best separation. Then, how well sleep stages separate was investigated with principle component analysis and kernel based principle component analysis by using only hybrid features. The validity of these separation results was shown by using probabilistic neural networks. Finally, separation capabilities of principle component analysis and kernel based principle component analysis was compared by means of probabilistic neural network.

BÖLÜM 1. GİRİŞ

Vücuttaki hayati fonksiyonların denetimi beyin tarafından gerçekleştirilir. Beyin, denetim merkezi özelliğine sahip olup denetimsel faaliyetleri sırasında karmaşık ve kompleks yapıda biyopotansiyel işaretler üretir. Elektroensefalogram (EEG) olarak isimlendirilen bu işaretler, beynin ve vücudun diğer organlarının çalışmalarıyla ilişkili birçok bilgiler içerir. Bu bilgiler hekimler tarafından değerlendirilerek, hastalık teşhisi ve tedavi amaçlı olarak kullanılırlar. Elde edilen EEG işaretlerinin içerdiği bilgiler ya doğrudan hekimin görüş ve tecrübesiyle değerlendirilir, ya da mühendisler tarafından çeşitli işaret işleme ve sınıflandırma yöntemleri kullanılarak daha sağlıklı bir teşhis ve tedavi için hekimlerin değerlendirmesine sunulur.


Tıpta belli başlı uyku düzensizlikleri; uykusuzluk hastalığı, derin uyku hali, horlama, uyku apnesi (soluk durması) vs. olarak kendini gösterir. Bunun yanında depresyon, şizofreni, Alzheimer hastalığı [1] gibi hastalıklar da; ağrıdan sonra sıklıkla görülen ve hastalık niteliği taşıyan rahatsızlıklar, uyku rahatsızlıkları olarak ortaya çıkar.

Uyku evrelerinin sınıflandırılması çalışmalarında sunulan özellikler incelendiğinde bu özelliklerin üç ana grupta toplandığı görülür. Bu özellikler;

- a) EEG işaretinin kendisinden hesaplanan özellikler (zaman-uzayı özellikleri)
- b) EEG işaretinin ayrık-zaman Fourier dönüşümü veya ayrık-dalgacık dönüşümü gibi uygun bir frekans dönüşümü vasıtasıyla frekans uzayına dönüştürülerek frekans uzayında hesaplanan özellikler (frekans-uzayı özellikleri)
- c) Zaman ve frekans uzayı özelliklerinin birlikte kullanılmasıyla oluşturulan özellikler (zaman ve frekans-uzayı özellikleri)

Yapılacak detaylı simülasyonlarla, her bir gruptaki özelliklerin uyku evrelerini ne oranda ayırttığı belirlenerek, elde edilecek önbilginin literatürdeki sonuçlarla uyumlu olup olmadığı araştırılacaktır.

Literatürde uyku düzensizliklerinin belirlenmesine yönelik EEG işaretlerinin kullanılması ve bu işaretlerden yararlanarak uyku evrelerinin sınıflandırılması için çok sayıda yöntem sunulmuştur [2-12]. Bu yöntemler genellikle iki adımdan oluşmaktadır: (i) EEG işaretinden özellik çıkartımı, (ii) çıkartılan özelliklerin bir sınıflandırıcıya uygulanması. Çıkartılan özellikler N -boyutlu bir vektör olarak gösterilirse; özellik çıkartımı adımının amacı, herhangi bir uyku evresine karşılık gelen işareti, N -boyutlu özellik uzayında bir nokta olarak temsil etmektir. Sınıflandırma adımının ise iki amacı vardır. Eğitim esnasındaki amaç, N -boyutlu özellik uzayını uyku evresi sayısı kadar bölgeye ayırmaktır. Sınıflandırma esnasındaki amaç ise N -boyutlu özellik uzayında bir nokta olarak temsil edilen EEG işaretinin hangi bölgeye daha yakın olduğunu tespit ederek kendisine karşılık gelen uyku evresini belirlemektir.



Şekil 1.1. EEG işaretinin sınıflandırılmasındaki adımlar

Şekil 1.1’de, sınıflandırmadaki iki adım, blok olarak gösterilmiştir. Burada, özellik çıkartımı adımının sınıflandırma adımının başarısını büyük oranda etkilediği görülmektedir. Sınıflandırma amacıyla kullanılan ideal bir özellik vektörü, aynı uyku evresine karşılık gelen işaretleri özellik uzayında küçük yarıçaplı bir üst kürenin içine kümelerken, farklı uyku evrelerine karşılık gelen üst küreleri birbirlerinden mümkün olduğunca uzakta tutmalıdır. Farklı uyku evrelerine karşılık gelen üst kürelerin kesişmesi, sınıflandırıcının karar verirken bu uyku evrelerini birbiriyle karıştırarak sınıflandırma performansının düşmesine neden olmaktadır. Literatürde sunulan yöntemlerde, özellik vektörlerinin uyku evrelerini birbirinden ne oranda ayırttığı gösteren bir analize rastlanmamıştır. Hâlbuki böyle bir analiz iki bakımdan çok önemlidir. Birincisi, analiz, sınıflandırıcının başarısı için bir üst sınır

belirler. Üst sınır bilgisi olmadan sınıflandırıcının başarısının üst sınırdan ne kadar uzakta olduğu bilinemez. İkincisi ise, analiz adımında belirlenen üst sınır, verilen uygulama için yeterli değilse sınıflandırma adımı ile vakit kaybetmeden özellik vektörünün değiştirilmesi gerekliliği belirlenmiş olur.

Bu çalışmada, ön sınıflandırma ile uyku ve uyku problemlerinin belirlenmesine ilişkin EEG işaretleri kullanılarak, sınıflandırma üzerine iki yöntem sunulmuştur. Bu yöntemlerde, bir özellik vektörünün uyku evrelerini ne ölçüde ayırttığı belirlenmiştir. Yöntemlerden ilki, özellik vektörlerinden elde edilen bir kovaryans matrisinin özvektörlerine veya temel bileşenlerine dayalıdır. Karhunen-Loeve dönüşümü olarak da bilinen temel bileşen analizi, sınıflandırma amacıyla örüntü tanıma, görüntü bölütleme ve sınıflandırma gibi birçok uygulamada başarıyla kullanılmıştır. Kernel temel bileşen analizi olarak adlandırılan ikinci yöntemde ise, özellik vektörleri bir fonksiyon vasıtasıyla başka bir üst uzaya taşınır. Elde edilen yeni özellik vektörlerinden hesaplanan kovaryans matrisinin özvektörleri, gruplandırma için kullanılır. Her iki yöntemde de verilen ve hangi evreye ait olduğu bilinmeyen özellik vektörleri hesaplanan özvektörler üzerine izdüşürülür. Özellik vektörleri ilgili oldukları uyku evresini iyi tanımlıyorsa farklı bölgelerde gruplanacaklardır.

Uyku evrelerinin bölgelere ayrılarak çıkartılan özellik vektörleri, temel bileşen analizine dayanılarak hazırlanan yöntemin ilk aşaması uygulandıktan sonra olasılıksal yapay sinir ağları ile sınıflandırılmıştır. Elde edilen sonuçların, uyku evrelerinin ayırtılması ve sınıflandırılması çalışmalarıyla uyumlu olup olmadığı belirlenmiştir. Çalışmalarda yapılan detaylı simülasyonlar ve simülasyonlardan elde edilen sonuçlar “Simülasyon Sonuçları” bölümünde ayrıntılı olarak verilmiştir.

Tez çalışması aşağıda verilen şekilde düzenlenmiştir. Bölüm 1’de, konuya kısa bir giriş yapıldıktan sonra EEG, uyku EEG’si ve uyku evrelerinin sınıflandırılması, skorlanması üzerine yapılmış önceki çalışmalara yer verildi.

Bölüm 2’de, EEG işaretlerinin temel özellikleri, EEG işaretleri elde edilirken kullanılan elektrotların özellikleri, elektrotların kafa üzerine yerleşim düzeni ve

elektrotlardan elde edilen EEG işaretlerinin bilgisayar ortamına aktarılması üzerinde durulmuştur.

Bölüm 3'te, uyku EEG'si işaretlerinin özellikleri verilmiştir. Uyku ile ilişkili hastalıkların tespitinde kullanılan uyku evreleri ile bu evrelerin genel özellikleri hakkında bilgiler bu bölümde sunulmuştur.

Bölüm 4'te, uyku EEG'si işaretlerinden çıkartılan ve uyku çalışmalarında kullanılan bazı özellik vektörlerinin tanımları ve nasıl hesaplanacakları üzerinde durulmuştur. Ayrıca bu özellik vektörleri hesaplanırken kullanılan önışleme yöntemleri olan Yule-Walker yöntemlerinin temel prensipleri de bu bölümde verilmiştir. Yule-Walker yöntemleri güç yoğunluğu hesaplanırken kullanılmıştır.

Bölüm 5'te, temel bileşen analizine dayanarak uyku evrelerinin bölgelere ayrılması için sunulan yöntemlerdeki işlem basamakları anlatılmıştır. Bu bölümde ayrıca sınıflandırma amaçlı kullanılan olasılıksal sinir ağları hakkında bilgilere yer verildi.

Bölüm 6'da, bölgelere ayrılan uyku evrelerinin test edilmesi için kullanılan sınıflandırma yöntemlerine ilişkin simülasyon çalışmaları ve sonuçları verilmiş, elde edilen sonuçlar yorumlanmıştır.

Çalışmanın sonuçları ve daha sonra yapılacak çalışmalar için öneriler, Bölüm 7'de verilmiştir.

Önceki Çalışmalar ve Tarihi Gelişim;

Beyinde bir takım elektriksel faaliyetlerin var olduğunu, ilk defa, Richard Caton hayvanlar üzerinde yaptığı deneylerin sonucunda bulmuştur[13]. Caton bu aktiviteyi, sadece uyarıcı bir işarete karşı oluşan ve herhangi bir uyarıcı işaret olmadan beyin yüzeyinden elde edilen aktivite olmak üzere ikiye ayırmıştır. O yıllarda bu aktivitenin sadece beyin yüzeyinden algılanabileceği sanılıyordu.

1929 yılında Hans Berger [14] hazırladığı bir düzenele insan beynindeki elektriksel aktiviteyi kafatası yüzeyine yerleştirdiği elektrotlar vasıtasıyla kaydetmiştir. Berger, 1930'da Elektroensefalogram adı verilen bu işaretlerin gözün açılıp kapanmasıyla değiştiğini göstermiş ve bu biyopotansiyel işaretleri inceleyerek frekans aralığı 8-13 Hz arasında değişen bir temel aktivite olduğunu tespit etmiştir.

Modern uyku araştırmalarının başlangıcı, 1930'lu yıllarının başlarında elektroensefalografın icadı ile başlamıştır. 1937 yılında, bütün gece süren uykunun homojen olmayan aşamalardan oluştuğunu ilk gözlemleyen ve EEG yardımıyla uykunun bu safhalarını tanımlayan Loomis'tir [15]

EEG işaretlerinin bilimsel olarak ortaya konması, ancak elektronikteki gelişmeler sonucunda olmuştur. Adrian ve Matthews, 1934'te elektrotlarla alınan EEG işaretlerini kuvvetlendirip kaydedilmesini sağlamışlardır. P. A. Davis, 1939'da, uyanık bir insanın EEG'sinde, sese karşı uyarılan yanıtların olduğunu bulmuştur[16].

İnsan uykusunun mikro yapısını sınıflandırmak için yeni bir puanlama sistemi Terzano tarafından geliştirilmiş, Cyclic Alternating Pattern Sequences (CAPS) [17]. Mikro yapı kısa süreli geçici olaylar üzerine temellendirilmiştir. Bu olayların çoğu R&K kriterlerinde göz ardı edilmiştir.

Akın [18], beyinden alınan işaretin genliğinin, zamana göre değişiminin bilgisayara gerçek zamanda kaydedilmesi için bir arabirim ünitesi gerçekleştirmiştir. Kaydedilen işaretin spektral analizi için bir program geliştirilmiştir. Spektral analiz yöntemi olarak Hızlı Fourier Dönüşümü kullanılmıştır. Sonsuz uzunlukta bir işaret dizisi ile çalışmak ve yorumlamak zor olduğundan pencere fonksiyonları kullanılmıştır. Elde edilen spektrumlar hem kendi aralarında, hem de EEG işareti ile karşılaştırılıp irdelemeler yapılmıştır.

Hu ve Knapp [19], EEG işaretlerinden uyku evrelerini sınıflandırmak için bir bulanık mantık yaklaşımı sunmuşlardır. Bu yaklaşımda bir EEG işaretinden her epok için frekans ve genlik özelliklerinden oluşan bir özellik vektörü çıkarılmış, bu vektör uyku evrelerinin her birinin temel özelliklerini temsil etmiştir. Her evrede, her epok

içinde üyelik fonksiyonları hesaplanmış ve her evre maksimum üyelik derecesi ile ölçeklenip sınıflandırılmıştır. Sistem C programlama dili kullanılarak gerçekleştirilmiş ve yaklaşık 1101 epöğün analizi yapılarak, program ve uzman arasında toplamda %77 lik bir uyum sağlanmışır.

Hazarika ve arkadaşları [20], EEG işaretlerini sınıflandırmak istemiş ve bu iş için yapay sinir ağıları kullanmışlardır. EEG işareti önce AR ve Dalgacık dönüşümüyle ön işlemeden geçirilmiş ve daha sonrada yapay sinir ağılarıyla sınıflamaya tabi tutulmuştur. Sonuçta her yöntemin sınıflandırma başarısı yüzdeler şeklinde verilmiştir.

Ping jung “EEG Güç Spektrumundan Uyanıklık Tahmini” adlı çalışmasında EEG’de uyanıklık seviyesini araştırmıştır. Yine yaklaşık yarım yüzyıldan fazladır, uyanıklık, uyanma ve uyku gibi durumlarla ilgili işaret değişimlerinin EEG’de bulunduğu bilinmektedir. Ancak gerçek zamanda bu bilgilerin çok az bir kısmı elde edilmiştir. Bu çalışmada çok kanallı EEG verisi kullanılarak, bir operatörün genel uyanıklık seviyesindeki salınımları sürekli, doğru, dolaylı yoldan ve gerçek zamana yakın bir şekilde tahminin yapılabilirliği araştırılmıştır. Dikkat isteyen konularda, insan uyanıklığı dakika/zaman çizelgesinde değişmektedir. İşte bu uyanıklık seviyelerini EEG spektrumundaki dalgalanmalar içermektedir. Güç spektrum tahmininin birleştirilmesiyle, temel eleman analizi ve yapay sinir ağıları bir operatörün global uyanıklık seviyesinin kafa merkezinden alınan EEG kayıtlarından sürekli, doğru, dolaylı ve gerçek zamana yakın tahmininin yapılabilir olduğu gösterilmiştir. Bu gösterim insan operatörlerinin idrak etmeye ilişkin durumlarını dolaylı olarak görüntülemeye yol açabilir denilmektedir [21].

Merica ve Blois [22] derin uyku olarak tanımlanan NREM’deki farklı frekansların enerjisini, uyku esnasındaki REM (hızlı göz hareketleri) evreleriyle ve gece boyunca uyku verileriyle karşılaştırmışlar. NREM evrelerinde enerji beta bandı karşılıklı olarak daha yavaş banda (delta, teta) doğru değişir. REM’den önceki son çeyrekte beta dışındaki tüm bantlarda enerji düşer ve beta bandının enerjisi artar. Alfa, teta ve delta enerjileri, REM evresinin ilk %30’luk diliminde devam eder ve sonra enerji sabitlenir. Beta bandının enerjisi, NREM evresinin sonunda aynı seviyede kalır. Gece

boyunca, NREM boyunca daha yavaş frekans bantlarının (alfa, teta ve delta) enerjisi azalır. Delta bandının enerjisi dengeleme sürecine göre azalır.

Pereda ve arkadaşları [23] uyku safhaları boyunca, C3/A2 ve C4/A1 kanallar arasındaki bağımlılığı araştırmak için lineer olmayan zaman serilerinin analizinde çoklu olasılıksal değişken uygulamışlardır. Sonuçlar, kullanılan parametrelere çok duyarlı olduğundan, sonuçların değeri seçilmiş veriler ile test edilmiştir. Sonuçlara göre, bu kanallar arasındaki bağımlılık uykunun derinliği ile artmaktadır ve çoğunlukla doğrusal tiptedir.

Shimada ve arkadaşları [24] bir uyku evresi teşhis sinir ağı ve bir ifadeye bağlı sinir ağı bileşiminden oluşan çıkışı, Uyku EEG Tanıma sinir ağı ile ilgili bir makale yayınlamıştır. Raporunda, önceki performans %65'lere düşebilirken geliştirilen yöntemin performansının daha tutarlı bir şekilde %80 olduğunu iddia etmişler.

Pacheco ve arkadaşları [25] bir uyku evresini tanımlamak üzere 3 EEG kanalı, 2 EOG kanalı ve 2 EMG kanalı kullanılarak veriler elde edilmiştir. Önce bu kanallardan bir evre için elde edilen verilerden özellikler çıkarılmış, daha sonra bağımsız sınıflandırma ile bu verileri sınıflandırdılar.

Oropesa ve arkadaşları [26] yaptıkları bir çalışmada, yapay sinir ağı ve wavelet analizi kullanan bir otomatik uyku evresi sınıflayıcı sistemi sunmuşlar. Sistemleri geçmişe ait doğrulukta %90'lara ve geleceğe ait doğrulukta ise %77.6'ya ulaşmışlar.

Flexer ve arkadaşları [27] 2000 yılında yaptıkları bir çalışmada, Hidden Markov Modeli (HMM) kullanan sürekli bir uyku evreleme sistemi yapmışlar. Bu noktada sistem, uyanık ve derin uyku evreleri (Evre 3 ve Evre 4) için yaklaşık %80, sadece REM uyku evresi için ise %26'lık bir performans göstermiştir. Daha sonra 2002 yılında aynı kişiler REM uyku evresini algılama oranını %68'e kadar geliştirmişler [28].

Van Hese ve arkadaşları [29], Hjorth parametreleri, harmonik parametreler ve her bir bandın enerji yoğunlukları oranı özellikleri ile k-mean sınıflandırma kullanmıştır. Yayınları herhangi belirli bir sonuç içermemiştir.

Herrmann ve arkadaşları [30], EEG'nin rutin klinik otomatik analizi için, spektral analiz ve uzman sistemler içeren, hibrit bir sistem önerisinde bulunmuşlardır. Adaptif frekans ayrıştırması ile ham EEG verisi frekans uzayına taşınmış, elde edilen frekans bileşenleri bulanıklaştırma yoluyla pseudo-linguistik değerlere dönüştürülmüştür. Son olarak da, nörologlarca formüle edilen sembolik kurallar, bir uzman sistem kullanılarak çıkartılan EEG özellikleri değerlendirilmiştir. Sistem bozucu etkileri belirleyip, frekansla, genlikle alfa ritmini ve kararlılığı tanımlamıştır.

Kıymık ve arkadaşları [31], EEG'den uyanıklık seviyesi belirlemek üzere yapmış oldukları çalışmada, uyku, uykuya geçiş evresi ve uyanıklık durumlarının belirlenmesi için ayrık dalgacık dönüşümü ve yapay sinir ağları kullanmışlardır. Ayrık dalgacık dönüşümü ile işaret alt bantlara ayrılmış daha sonrada bu işaretlerle ağ eğitilmiştir. Daha sonra ağa değişik veriler verilmek suretiyle ağın değişik uyku safhalarını belirlemesi sağlanmıştır. Yaklaşık yüzde doksanlar seviyesinde başarı elde edildiği belirtilmektedir.

Madan ve arkadaşları [32] yazdıkları makalede, EEG işaretinin tanımlayıcısı olarak, güç spektrum yoğunluğuna dayanan özellikleri kullanmayı önermişler. Bu çalışmanın sonuçları, spektral özelliklerin daha önce kullanılan özelliklerden elde edilen sonuçlar ile karşılaştırıldığında, daha iyi bir uyku EEG sınıflandırılması sağladığını ve homojen kümelerin oluşmasına daha çok yardımcı olduğunu göstermiştir. Altı uyku EEG sınıfının manuel skorlanması ile karşılaştırıldığında, bütün evrelerin ortalama uyumu %68,5'dir. Daha önce kullanılan özelliklerden elde edilen ortalama uyum değeri olan % 62.7'ye göre bu bir gelişmedir. Bu çalışmada bilgisayar sınıflandırması için elde edilen sonuçlar, sadece bir kanaldan alınan EEG bilgisi kullanılmıştır. Bu sonuçlar uyku EEG'sinin ilave bilgilere dayanarak yapılan manuel sınıflandırmaya benzemektedir.

Pinero ve arkadaşları [33] yaptıkları bu çalışmada, uyku evrelerini sınıflandırmak için zeki sistem sunmuşlardır. Sistemleri, uyku evreleri kayıtlarından oluşan hipnogram tabanlıdır ve dört farklı modüle ayrılmıştır: Birinci modül, elektro-fizyolojik işaretlerin işlenmesi ve ilgili parametrelerin tanımlanması, ikinci modül, sınıflandırma işlemi süresince kullanılacak bulanık kurallarının çıkarılması, üçüncü modül ise bir bulanık model uygulayarak bir sonuç çıkarma modülüdür. Son olarak, sistem, hastaların hipnogramını oluşturarak farklı çıkışlar sağlamıştır. Farklı uyku sorunları olan hastaları sınıflandırmak üzere hazırlanan sisteme uygulayarak elde edilen sınıflandırma sonuçlarını sunmuşlardır.

Subasi [34], 2005 yılında yaptığı çalışmada EEG işaretleri kullanarak uyku çalışması gerçekleştirmiştir. Ön işleme amacıyla dalgacık yöntemi kullanmıştır. Yapay sinir ağını eğitmek için dalgacık katsayılarını ağa uygulamış ve uyku, uyanıklık ve uyuklama durumlarının belirlenmesine çalışmıştır. Yüzde doksanlar civarında başarı elde edildiği gösterilmiştir.

He ve arkadaşları [35] yaptıkları çalışmada sekiz sağlıklı yetişkinin uyku EEG'sinin spektrum entropisini (SE), yaklaşık entropisini (ApEn) ve "Lem-Ziv karmaşıklığı (LZC)" değerlerini özellik olarak kullanmış ve sınıflandırma yapmışlar. Elde ettikleri istatistiksel sonuçlar, bu üç doğrusal olmayan özelliğin hepsinin uyku evrelerini açıkça yansıtabileceğini göstermiştir. Bunlar arasında ApEn, daha karmaşık olmasına karşın daha iyi gerçekleştirmiş, SE hesaplamak için kolay ve değişen uyku periyotlarını yeterli ve sürekli olarak izlemekte, ve LZC ise basittir fakat ön-işlemesinde orijinal ölçüm verilerinin bilgi detayları kaybolmaktadır. Etkinlik ve fayda açısından SE'nin gerçek zamanlı uyku evrelerinin izlenmesi için iyi bir özellik olabileceğini ifade edilmiştir.

Held ve arkadaşları [8], 6 aylık ve sonrası yaşlarda sağlıklı bebekler için uyku-uyanıklık durumları ve uyku evrelerinin sınıflandırılması için bir neuro-fuzzy sınıflandırıcısı (NFC) geliştirilmiştir. NFC, polisomnograftan (PSG) elde edilen kayıtlarlardan 20 saniyelik epoklar alınmıştır. Bu epoklar önceden tanımlı 5 giriş örüntüsü ve onları beş muhtemel çıkıştan biri olarak atanmıştır: Uyanık, REM uykusu, NREM Uykusu Evre 1, Evre 2 ve Evre 3 ve 4. Veri kümesi, toplam 6021

epoktan oluşmaktadır. Eğitimin denetlenmesi sırasında sistem, girişler ve sınıflandırmanın yapılması, eğitim kümesinden bilginin çıkarımı ve ilgisiz kuralların budanması için gereken kurallar ile ilgili bulanık kavramları belirlemiştir. Bu sistem ile uzmanlar arasında %83.9 uyumun olduğu ve bu sonuçlar ile NFC'nin bir uyku-uyanıklık otomatik sınıflandırıcı gerçekleştirmek için önemli bir araç olabileceği ifade edilmiştir.

Maeda ve çalışma arkadaşları [7], bir dalga şekli tanımaya dayalı bir insan uyku EEG evrelerini otomatik ayırt etme sistemi geliştirmişler. Geliştirdikleri bu sistem ayrık evreleri algılayabilmektedir. Bununla beraber, sistem daha detaylı bilgi çıkarmak için yeterli değildir. Bu yüzden uyku evreleri için daha kesin bilgi çıkarmak için Gabor waveletleri tabanlı bir sürekli wavelet dönüşümü uygulayarak zaman-frekans uzayında uyku EEG'sini analiz etmeyi denemişler. Bu çalışmalarında bir değiştirilmiş wavelet dönüşüm metodu sunmuşlar. Gabor waveletlerin katsayılarından oluşan özellik bir sigmoid fonksiyonu ile değişmektedir. Yaptıkları deneylerde uyku EEG'sinin frekans bileşenlerini analiz etmek için değiştirilmiş wavelet dönüşümü metodunun yeterli frekans çözünürlüğüne sahip olduğunu iddia etmişlerdir.

Doroshenkov ve arkadaşları [6], yaptıkları çalışmada Hidden Markov Modelleri kullanarak EEG işaret işleme tabanlı insan uyku evrelerini sınıflandırma metodu sunmuşlar. Bu metod EEG, EOG ve EMG işaretlerini algılamayı içerir. Bu işaretler uyku evrelerini tanımlamak için kullanılır. Metod, Hidden Markov Modelleri tabanlı, oldukça doğru ve uykunun ana evrelerini ayırmakta güvenilir bir tanımlama sağlamıştır. Otomatik sınıflandırma sonuçları R&K uluslararası sisteme dayalı uzmanların sınıflandırma sonuçları ile uyumlu olmuştur. Bu çalışmada maksimum doğruluk tipik derin uykuda elde edilmiştir. Evre 4 için R&K ile karşılaştırıldığında %92 sınıflandırma başarısı göstermiş. En kötü sınıflandırma doğruluğu %5'ten daha az ile Evre 1 olmuştur. Evre 1 çoğunlukla Evre 2 (%48) veya REM evresi (%47) olarak sınıflandırılmıştır. Bu çalışmada uyanık evresinin sınıflandırma başarı yüzdesi %74 olmuştur.

BÖLÜM 2. ELEKTROENSEFALOGRAM İŞARETLERİ

2.1. Giriş

İnsan beyninde elektriksel aktivitenin varlığını ilk bulan Hans Berger olmuştur. Hans Berger 1929 yılında yaptığı çalışmada beyindeki elektriksel aktiviteyi, bir galvanometreye bağlı elektrotları kafa üzerine yerleştirerek incelemeyi başarmıştır. Kafa üzerine yerleştirilen elektrotlar ile alınan ve beyinde oluşan bu dalgalara Elektroensefalogram (EEG) adı verilmektedir. Berger 1930 yılında yaptığı çalışmayla EEG işaretlerinin gözün açılıp kapanmasıyla değiştiğini göstermiştir. Elektronikteki gelişmelerin ve bu gelişmelerin tıpta kullanılması sonucu olarak EEG işaretlerinin varlığı bilimsel olarak kesinlik kazanmıştır [16]. Günümüzde klinik olarak epilepsi, Parkinson, şizofreni gibi hastalıkların teşhisinde EEG işaretleri yaygın olarak kullanılmaktadır. Bununla beraber psikiyatri, pedagoji, pediatri gibi alanlarda EEG işaretlerinin kullanımı gün geçtikçe artmaktadır.

Beyinde milyarlarca sinir hücresi vardır ve her bir sinir hücresi yüzlerce veya binlerce farklı sinir hücresiyle bağlantılıdır. EEG işaretleri, bu sinir hücrelerinin birbiriyle elektriksel etkileşimi sonucu ortaya çıkmaktadır. Sinirler arası bağlantıların bazıları uyarıcı, bazıları söndürücü işleve sahiptir. Beynin elektriksel aktivitesi ölçülürken tek bir sinir hücresinin faaliyetlerini gözlemlemek mümkün değildir. EEG işaretleri ancak birçok sinir hücresinin etkileşiminin bileşkesi olarak incelenebilir. Bu yönüyle EEG işaretleri genel anlamda, öngörülemeyen işaretler olarak kabul edilir. İnsan beyni canlı olduğu sürece gece veya gündüz, uyanık veya uyku halinde her zaman elektriksel anlamda aktiftir.

Beynin elektriksel aktivitesini izlemek için kullanılan EEG işaretleri kafatasına yerleştirilen elektrotlar yardımıyla elde edilirler. Ölçüm sonucu elde edilen işaret, çok küçük genlikli gerilim değişiklikleridir ve değişimler nöronlardan geçen akımlar

sonucunda oluşmaktadır. EEG işaretlerinin genliği beynin farklı bölgelerindeki aktivitenin derecesini gösterir. Tablo 2.1’de insan kafatasının çeşitli bölgelerinden alınan ve tıpta çeşitli hastalıkların teşhisinde kullanılabilen bazı EEG işaretleri ve kısa özellikleri verilmiştir [36, 37, 38].

Tablo 2.1. Polisomnograftan elde edilen bazı EEG işaretleri

BİYOELEKTRİK İŞARET	KULLANILAN DÖNÜŞTÜRÜCÜ	FREKANS ARALIĞI	DİNAMİK SINIRLAR	ÖLÇÜM VE OLUŞUM ŞEKLİ	
Elektrookülogram (EOG)	Yüzey elektrotlar	DC – 100 Hz	10 μ V–5 mV	Durgun kornea-retinal potansiyeli	
Elektromiyogram (EMG)	İğne elektrot	500 Hz – 1kHz	1-10 mV	Tek bir kas fiberindeki aksiyon potansiyeli	
E E G	Yüzey	Yüzey elektrotlar	0.5 – 100 Hz	2 –100 μ V	Çok kanallı kafa potansiyeli
	Delta	Yüzey elektrotlar	0.5 – 4 Hz		Gençlerde derin uyku ve patolojik durumlarda
	Teta	Yüzey elektrotlar	4 – 8 Hz		Alarm durumlarında şakak ve merkezde
	Alfa	Yüzey elektrotlar	8 – 13 Hz		Gözler kapalı, dinlenirken, uyanırken
	Beta	Yüzey elektrotlar	13 – 22 Hz		
	İğcikler	Yüzey elektrotlar	6 – 15 Hz	50 –100 μ V	
	K-kompleksleri	Yüzey elektrotlar	12 – 14 Hz	100 –200 μ V	
-Uyarılmış Potansiyeller (EP)	Yüzey elektrotlar		0.1–20 μ V	Uyarıya karşı insan beyninin cevap potansiyeli	

2.2. EEG İşaretlerinin Frekans İçeriği

EEG işaretlerinin frekans bileşenleri son derece önemli bilgiler taşır. Bununla beraber beynin farklı bölgelerinden alınmış benzer karakteristikleri gösteren EEG işaretleri arasındaki faz ilişkileri de oldukça önemlidir. Bu bilgiler sayesinde, EEG'nin kaynağı incelenebilmekte ve beynin çalışması hakkında ilave bilgiler elde edilmesi sağlanmaktadır. EEG işaretlerinin incelendiği çeşitli çalışmalar sonucunda EEG dalgaları frekans aralıklarına göre beş ana gruba ayrılmış ve bunlar alfa, beta, teta, delta ve gama olarak adlandırılmıştır. Bir dönem, beyindeki elektriksel aktivitenin algılanıp kaydedilmesi sonucunda beynin fonksiyonlarının tam olarak anlaşılacağı ve buna bağlı olarak psikiyatrik hastalıkların bile tedavi edilebileceği

düşünülse de bunun yanlış bir kanı olduğu anlaşılmıştır. Çünkü EEG dalgalarının incelenmesi, yorumlanması ve hastalık teşhisinde kullanılması kolay bir süreç değildir. EEG işaretlerinde beyin aktiviteleri ile ilgili birçok bilgi bulunmakla beraber bu bilgilerin ayrıştırılıp kullanılabilir hale getirilmesi ve elde edilen sonuçların uzmanlara sunulması çok zordur.

Kafa üzerinden elde edilen EEG işaretlerinin genlik aralığı tepeden tepeye 1-100 μV arasında ve frekans bandı ise 0,5 – 100 Hz arasındadır. Klinik olarak bu frekans bandının 0-35 Hz aralığı ile ilgilenilir. EEG işaretleri, EKG ve EMG işaretlerinde olduğu gibi şekil bakımından değil kapsadığı frekanslara göre değerlendirilmektedir. EEG işaretleri periyodik işaretler olmadığından, genlik, faz ve frekansı sürekli değişir. Beyinden uyku, dinlenme ve çalışma gibi farklı durumlarda alınan EEG işaretlerinin birbirinden farklılıklar gösterdiği tespit edilmiştir. Bu nedenle, anlamlı bir veri elde edebilmek için, ölçümlerin oldukça uzun bir sürede yapılması gerekir. Yapılan araştırmalar sonucunda EEG işaretlerinin içerdiği frekans bantlarının beş ayrı frekans aralığında yoğunlaştığı belirlenmiş ve bu bantlara: i) Delta Dalgaları (0.5-4 Hz), ii) Teta Dalgaları (4-8 Hz), iii) Alfa Dalgaları (8-12 Hz), iv) Beta Dalgaları (12-35 Hz), v) Gama Dalgaları (35-50 Hz) şeklinde özel isimler verilmiştir [16, 26, 29, 37, 39]. Alfa ve beta dalgaları beyindeki elektriksel aktiviteyi ilk gösteren Berger tarafından 1929'da ortaya konmuştur. Jasper ve Andrew (1938) 30 Hz üzerindeki frekansa sahip beyin dalgalarını tanımlamak üzere “gama” terimini kullanmışlardır. 1936 yılında Walter tarafından Delta ritmi, alfa dalgaları frekans aralığı altındaki bütün frekanslar için tanımlandı. Walter aynı zamanda 4 – 7.5 Hz arasındaki frekanslara sahip teta dalgalarını da tanımladı [40]. Bir teta dalgası kavramı 1944'te Wolter ve Dovey tarafından ortaya atıldı [41]. Şekil 2.1'de aşağıda detayları anlatılan EEG işaretlerinin içerdiği frekans bantlarına ve frekans bantlarının görüldüğü durumlara birer örnek verilmiştir.

2.2.1. Delta dalgaları

4 Hz'in altında frekansa sahip beyin dalgaları delta dalgaları olarak adlandırılır. Genellikle 0.5 – 4 Hz aralığı olarak tanımlanırlar. Bu aralıktaki frekansa sahip beyin dalgaları yenidoğan ve bebek EEG işaretlerinde ve derin uyku halindeki yetişkin

EEG işaretlerinde görülür. Yavaş aktivite delta dalgası kendi kendine görüldüğü gibi, uyanık yetişkin EEG'lerinde beyin hasarlarında da görülür. Delta dalgalarının genlikleri tepeden - tepeye 100 μ V'tan düşüktür [16, 36, 42].

2.2.2. Teta dalgaları

Teta dalgalarının frekans aralığı 4 ile 8 Hz arasında değişir, bu dalgalar ağırlıklı olarak bebeklerde ve çocuklarda görülür. Uyanık bir yetişkinin normal EEG işareti teta dalgalarından çok bileşen içerir. Bu dalgalar yetişkinlerde daha çok uyuklama ve uyku durumlarında görülür. Eğer uyanık yetişkin EEG işaretlerinde Teta dalgasının bileşenleri daha çok ise bu anormal bir durumdur ve patolojik bir rahatsızlığın var olduğunun göstergesidir [42]. Teta dalgalarının genlikleri tepeden - tepeye 100 μ V'tan düşüktür [16].

2.2.3. Alfa dalgaları

Bu dalgaların frekansı 8-13 Hz arasında değişir. Alfa dalgaları sinüzoidal karakteristiğe sahip monoritmik dalgalardır. Bu ritmik dalgalar genellikle başın yan ve arka bölgelerinde açık bir şekilde görülürler. Tüm sağlıklı insanlarda dinlenme halinde görülebilir. Uyku esnasında bu dalgalar tamamen kaybolur. Alfa dalgalarının genliği 20-200 μ V arasındadır. Uyanık bir kişinin dikkati belli bir fikri faaliyet üzerinde yoğunlaştığı zaman alfa dalgalarının yerini genliği daha düşük, frekansı daha yüksek olan beta dalgaları alır [16].


2.2.4. Beta dalgaları

Bu beyin dalgalarının frekansı 14 Hz' in üzerindedir. Bu beyin dalgaları daha yoğun olarak saçlı derinin ön ve merkez bölgelerinden elde edilir. Beta aktivitesi hemen hemen her sağlıklı yetişkinde bulunur. Frekans spektrumu 25 Hz'e kadar ve hatta nadir hallerde 50 Hz frekansa kadar ulaşabilir. Bu dalgalar kendi içinde Beta-I (BI) ve Beta-II (BII) diye ikiye ayrılır. BII dalgaları, BI dalgalarının iki katı frekansa sahiptir. BII dalgaları, alfa dalgalarında olduğu gibi zihinsel aktivitenin artması ile ortadan kaybolurlar. Bu durumda bu dalgaların yerlerine düşük genlikli asenkron

işaretler oluşur. Uyku esnasında alfa, teta ve delta dalgaları en düşük seviyededir. BII dalgaları, merkezi sinir sisteminin kuvvetli aktivasyonunda veya gerginlik hallerinde ortaya çıkar. Beta dalgalarının gerilim genliği alfa dalgalarının genliğinden daha düşüktür. Bu dalgaların genliği nadiren 30 μV değerini aşabilir [16].

2.2.5. Gamma dalgaları

Diğer dört temel dalgadan farklı olarak gama dalgaları genliği düşük ve frekansı daha yüksek bir karakteristiğe sahiptir. Gama dalgalarının frekansları 35-50 Hz arasındadır. Bu dalgaların genliği, tepeden - tepeye 2 μV 'tan düşüktür. Araştırmacıların bir kısmı tarafından bu terim kullanılmaktadır. Diğer bir kısım araştırmacılar ise bu dalgaların yerine Beta-II dalgalarını kullanmaktadır. Şiddetli bir uyarının arkasından kortekste, özellikle beynin üst bölgesinde gözlenirler. Bu dalgalar uykunun karakteristik belirtisini taşırlar [29, 37].

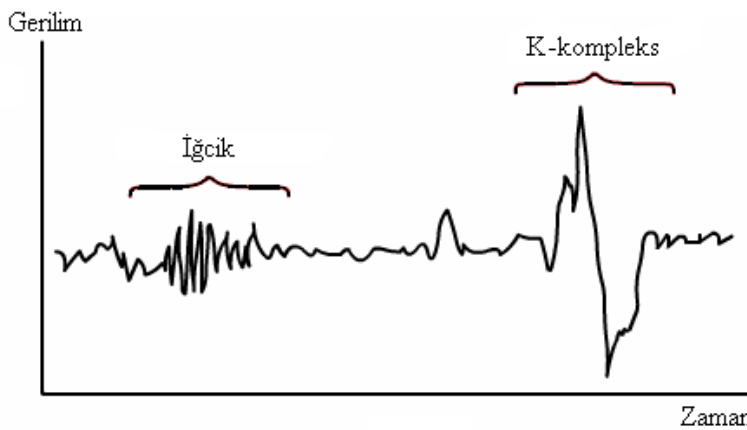


Şekil 2.1. EEG işaretinden alınmış frekans bantlarına örnekler [43]

2.3. Diğer Önemli Beyin Aktivitesi İşaretleri

Uyku içciği, 0.5 saniyeden daha fazla süren ve alfanın yüksek seviyesi ile betanın düşük seviyesi arasında frekans değişimine sahip aktivitelerdir. Uyku içciklerinin frekans aralığı 12-16 Hz arasındadır [44]. Genellikle simetriklerdir. Uyku içciği gerilim genlikleri genellikle 20 ile 100 μV arasındadır. Dakikada 5 sn'ye kadar sürebilir [45]. Bu gruptaki dalgalar uyku evrelerinden Evre 2'yi tanımlayan EEG özelliklerinden biridir, Evre 3 ve Evre 4'te de görülebilir fakat REM evresinde görülmezler. Şekil 2.2'de dalga şekli daha iyi görülmektedir.

K Kompleksi, yaklaşık $-56 \mu\text{V}$ negatif keskin bir gerilim ve onu izleyen yaklaşık 15 μV daha yavaş pozitif bir gerilim arasında ve 0.5 saniyeden daha uzun süren sıklıkla Evre 2'de görülen bir EEG dalga şeklidir [45]. Tepeden tepeye ölçülen gerilim 75 μV 'u aşmalıdır. K kompleksi negatif keskin bir dalga ile takip edilen daha yavaş bir pozitif dalgadan oluşur. Genel bir kural olarak, K kompleksleri bir grup olarak meydana gelirler [46], K kompleksleri sık sık bir EMG aktivitesindeki geçici artışlarla birlikte oluşur ve bu, aynı zamanda onları yavaş dalgalardan ayırmaya yardımcı olur.



Şekil 2.2. Uyku İçciği ve K-Kompleks örneği

Ayrıca araştırmacılar tarafından tanımlanan aşağıdaki beyin ritimleri de vardır [40]:

Fi (ϕ) ritmi: Gözün kapalı olduğu 2 saniye içerisinde meydana gelen 4 Hz'den düşük frekanslı dalgalardır. Fi ritmi Daly tarafından tanımlandı [47].

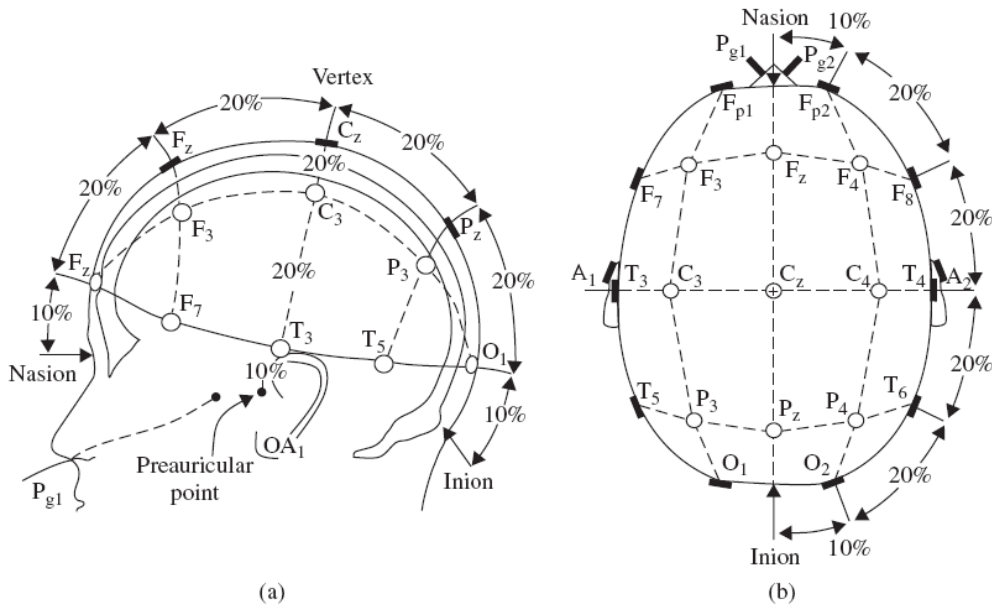
Kapa (κ) ritmi: Ön şakak kemiği üzerinden alınan alfa ritmine benzer bir ritimdir. Göz küresinin ayırık yan titreşimlerinin oluşturduğuna inanılır ve artifakt bir işaret olarak kabul edilir.


To (τ) ritmi: yan bölgelerdeki alfa aktivitesini belirtir.

Lambda (λ) dalgaları daha çok, uyanık hastalarda göze çarpar, fakat çok yaygın değildir.

2.4. EEG Elektrot Sistemi ve EEG'nin Kaydedilmesi

EEG tamamen ağrısız ve zararsız olarak saçlı kafa derisi üzerinden kayıt edilir. Normalde çok zayıf olan bu elektriksel potansiyeller saçlı kafa derisi üzerine yerleştirilen elektrotlar ile algılanıp yükselteçlerle güçlendirilerek kaydedilir. Otomatik EEG kayıtlarında genellikle uluslararası standart olarak kabul edilmiş 10-20 sistemi kullanılır. Bu sistemde Şekil 2.3'de görülen 21 elektrot başın yüzeyine yerleştirilir.






Şekil 2.3. Referans elektrotu ile birlikte 75 elektrot için 10-20 elektrot sisteminin grafiksel gösterimi: (a) ve (b) üç-boyutlu ölçümleri gösterir ve (c) elektrot sisteminin iki-boyutlu görünüşünü gösterir ([48] tarafından yeniden çizildi.)

Uluslararası 10-20 sisteminin yanında baş üzerinden elektrik potansiyeli ölçmek için birçok elektrot sistemi ortaya atıldı. The Queen Square elektrot yerleşim sistemi klinik testlerde uyarılmış potansiyellerin örüntülerini kaydetmede bir standart olarak önerildi [42, 49].

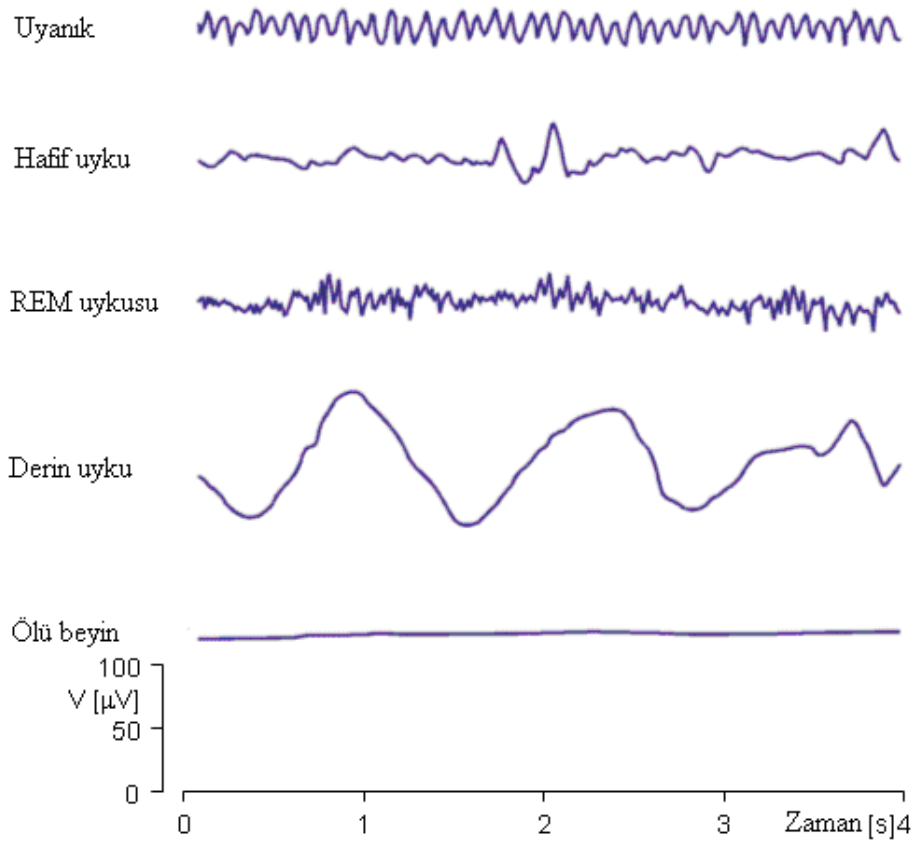
EEG'nin bilgisayarla analizi, elektrotlar vasıtasıyla alınan EEG işaretlerinin sürekli işarettten sayısal işarete çevrilmesi ile başlamaktadır. Bu işlem bir analog-dijital çevirici tarafından yapılır. Sürekli işaret Nyquist kriterine uygun olarak örneklenir. Analog-dijital çeviriciler işaretlerin gerilim cinsinden olmasına gereksinim duyduklarından bu işlemden önce EEG sinyalleri yükselteçlerle yükseltilir [39, 50]. EEG işaretlerinin kaydedilme sistemleri Şekil 2.4'te görüldüğü gibi analog-dijital zamanlama, giriş ve çıkış gibi birçok seçenekleri içermektedirler [37]. Burada kullanılan sistemlerin birçoğu programlanabilir kanallara sahip olup, örnekleme, çevirme modu her bir kanal için ayrı ayrı kazanç, analog ve dijital tetikleme gibi özelliklerle donatılmışlardır. Bu sistemler elde edilen işareti gerçek zamanda işlerler, aynı zamanda çok yüksek performansa sahiptirler.



Şekil 2.4. EEG işaretlerinin ölçümünün blok şeması

2.5. EEG Teşhisinin Temel Prensipleri

Normal bir EEG sinyali birçok frekansı içerse de, herhangi bir anda belirli bir frekans bölgesi karakteristik olarak alınır. Burada bir evre tanımlanırken aslında bütün evrelerin özelliklerini taşıyan işarete en baskın hangi evre ise evreye onun ismi verilir. Beynin aktivite düzeyi arttıkça EEG işareti daha yüksek baskın frekansa ve daha düşük genliğe kayar. Belirgin frekanslar yaşla beraber yükselir. Gözler kapandığında alfa dalgaları EEG işaretinde baskın olmaya başlar. İnsan uyuduğunda baskın olan EEG işaretinin frekansı azalır. Uykunun belli bir fazında, REM uykusu diye adlandırılan hızlı göz hareketleri fazında, insan rüya görür ve karakteristik bir EEG işareti olarak görülebilen gözlerin aktif hareketlerine sahiptir. Derin uykuda EEG işareti, delta dalgaları olarak adlandırılan geniş ve yavaş sapmalara sahiptir. Tamamen ölü beyinli bir hastadan beyin aktivitesi sezilmez. EEG dalgaları değerlendirilirken en önemli parametre “frekans” daha sonraki parametre ise “genlik” tir. EEG işaretlerinden alınan ve uyku ile EEG işareti arasındaki ilişkiyi belirten dalga şekillerine ait örnekleri Şekil 2.5’te gösterilmiştir. Şekilde görülen dalga şekilleri beynin şuur seviyesine göre EEG işaretinin davranışını göstermektedir.



Şekil 2.5. Şuurun seviyesine bağlı EEG aktivitesi [40]

BÖLÜM 3. UYKU EEG'Sİ VE UYKU EVRELERİ

3.1. Giriş

Son zamanlarda, uyku ile ilgili hastalıkları ve uyku sorunları belirlemek ve belirlenen bu sorunların teşhis ve tedavisi için modern cihazlarla donatılmış uyku laboratuvarları kurulmaktadır. Bu laboratuvarlarda bir insanın uyku kalitesi ölçülebilmektedir. Bir insan normalde uykusunun en az dörtte birini derin uykuda geçirmelidir ki yeterli uyku uyuyabilsin ve dinlenmiş olarak uyanınsın.

Günümüzde en sık rastlanılan uyku hastalıkları; uykusuzluk hastalığı, derin uyku hali, uyku apnesidir. Uykusuzluk hastalığı uykuya dalamama veya gece uyuduktan sonra sık sık uyanma olarak kendini gösterir. Uyuyamama ve uykudan sık sık uyanma derin uyku süresini kısaltacağından uyuyan kişinin dinlenmeden uyanmasına sebep olur. Uyku apnesi uyku esnasında soluk durması olarak tanımlanmış. Uyku apnesi teşhisi için hasta bütün gece uyku laboratuvarında kalarak vücudun çeşitli yerlerine bağlı elektrot vasıtasıyla alınan veriler değerlendirilerek bir sonuca varılır ve tedavi için gerekli müdahaleler yapılır. Tıpta yapılan uyku araştırmaları, bu rahatsızlıkların tespitinde oldukça önemlidir. Uyku boyunca, insan beyni göreceli olarak dengeli çeşitli psikofizyolojik seviyelere girer. Uyku esnasında birçok sinir merkezi aktif olmadığından, uykuda beyin daha az karmaşık bir sistem haline gelir ve matematiksel modelleme için daha uygundur.

3.2. Uyku Fonksiyonu

İnsanoğlu uykunun yaşam için ne kadar gerekli olduğunu, uykunun fonksiyonu ve nedenini anlamak için birçok teori ortaya atmıştır. Bu teorilerin bir kısmı bazı gerçeklere dayandırıldığı için tatmin edici olarak kabul edilmekle beraber, çok büyük bir kısmı sadece teori olarak kalmıştır. Çünkü ortaya atılan bu teoriler şimdiye kadar

gerçekleşmemiş olağandışı deney ve durumları açıklamaktadır. Aşağıda sadece temel teorilere değinilmiştir:

1. Enerji tasarrufu: Uyku esnasında enerjinin saklandığı düşünülduğünden enerji tasarrufu ana tartışma konularından birini oluşturmaktadır. Uyku süresinin yeterli olmadığı durumda enerji tüketimi artar. Uyku boyunca bazal metabolizma %5-25 yavaşlar [51].
2. Doku ve büyüme onarımı: Uykunun ilk saatlerinde büyüme hormonu salgılanır. Mitoz hücre bölünmesi ve protein sentezi artar. Büyüme sırasında veya ağır bir gündün sonra NREM (derin uyku) uykusunun miktarı artar. Fakat J. Horne [52] bu teoriyi eleştirmiştir. Ona göre mitoz hücre bölünmesi, gıda alımından bir kaç saat sonra meydana gelir ve insanın biyolojik ritmiyle ilişkilidir. Yavaşlayan metabolizma, yüksek enerji gerektiren protein sentezlemesi ile uyuşmaz, aynı zamanda fiziksel aktivite sonrası baş bölgesinde artan sıcaklık, yavaş dalga uykusu (SWS, slow wave sleep)'nun artmasına neden olmaktadır.
3. Isının düzenlenmesi: Fareler üzerinde yapılan deneyler, uzun dönem uykusuz bırakılan farelerin ısısının 10 derece yükseldiğini göstermiştir [51]. Sonuç olarak uyku büyük ihtimalle ısıyı düşürmektedir.
4. Duyguların düzenlenmesi [51]: İnsanlarda, uykusuzluk duygusal davranışlarda (örnek: konsantrasyon, açık hedeflere olan ilgi) bozukluklarına neden olur. Özellikle yavaş dalga uykusunun (SWS) eksikliği depresyon veya kuruntuya neden olmaktadır. Sonuç olarak, NREM uyku bu duyguların düzenlenmesi ve ayarlanması ile ilgilidir. Bu teori klinik gözlemler tarafından da desteklenmektedir. Depresif hastalarda NREM uyku süreci düşüktür ve metabolizma hızı ile NREM uykusu boyunca duyguları kontrol altına alan beyindeki nöronal boşalım yüksektir. Bu durum uyanıklık durumunun aksi seyretmektedir.
5. Sinirsel olgunlaşma: Uyku fonksiyonları hakkındaki teorilerin bir bölümü REM uykusu ile ilgilenmektedir. REM uykusunun toplam uyku süresine yüzdelik oranı

yaş ilerledikçe azalır. Doğum öncesi devrenin 6. ayına kadar çocuklar uykularının %80'ini REM uykusunda harcarlar. Fakat genç yetişkinlerde bu oran sadece %25 tir. [51] Sonuç olarak REM uykusu boyunca beynin olgunlaşması ve sinir liflerinin gelişmesinin devam ettiği varsayılmaktadır.

6. Hafıza ve öğrenme: NREM ve REM uykunun çeşitleri öğrenme ve hafıza birleştirmede önemli rol oynar. Uyku boyunca beyin zarı ve hipokampus arasında bilgi transferi mevcuttur. Bu transfer sayesinde hafıza bağlantıları onarılır veya REM uykusu sırasında önemsiz bağlantılar silinir. Bu işlemler öğrenme süreçleri ile de ilgilidir. Bazı araştırmalar, uykudan hemen sonra algıda ve motor sinir sisteminde gelişme kaydedildiğini belirtmektedir [53, 54]. Gelişme direkt uykuya bağlı olup zaman aralığı veya biyoritmden bağımsızdır.


3.3. Uyku Evreleri

Uykunun ana evreleri, uyanıklık, REM uykusu ve NREM uykusudur. NREM uykusu, en hafif uyku Evre 1 ve en derin uyku Evre 4 olmak üzere 4'e bölünmüştür. 3. ve 4. uyku evreleri yavaş dalga uykusu (SWS) olarak adlandırılmıştır. İnsan uykusu NREM ve REM Uyku evrelerinin dağılım sıklığı gece boyunca değişir. Uykunun başlangıç saatlerinde SWS baskın olmasına karşılık REM uykusu, daha çok uykunun ikinci bölümünde baskındır. REM uykusunun dağılımı gece boyunca yaşa göre değişir. Örneğin, yeni doğmuş bebeklerde REM uykusunun oranı %50, yetişkinlerde %20'dir.

İnsan uykusunun incelenmesinde, basit ve klinik araştırmalarda kullanılan temel yöntem polisomnografidir. Bu yöntem, temel olarak EEG, EOG ve EMG değerlerinin ölçülmesinden oluşmaktadır. Elektroansefalografi, beyinsel aktiviteleri kusursuz ölçebilen ve elektriksel hareketliliği gözlemleyebilen basit bir yöntemdir. EEG'nin ölçüm kalitesi, bazı teknik parametrelere bağlıdır.

Uykunun evreleri, 1968 yılında A. Rechtschaffen ve A. Kales tarafından yönetilen bir komitenin hazırladığı, "İnsan Uyku Evrelerinin Standart Terminolojisi, Teknikler ve Skorlama Sistemleri Elkitabı" isimli araştırma temel alınarak

değerlendirilmektedir [55, 56]. Uyku çalışmalarında tek elden çıkma ve standart kriterler kullanılmasının ana nedeni, farklı uyku laboratuvarlarında yapılan araştırmaların ve elde edilen sonuçların sağlıklı bir şekilde birbirleriyle karşılaştırılabilmesi ihtiyacından meydana gelir. Bu elkitabı, polisomnografik cihaz kayıtlarının dalga yapılarını, inceleme tekniklerini ve uyku evrelerinin parametrelerini detaylı ve örneklerle sunmaktadır. Genellikle uyku çalışmalarında iki kanal EEG, iki kanal EOG ve bir kanal EMG kaydedilmektedir. Bunun yanı sıra solunum, vücut sıcaklığı v.s. bilgilerde kayıt altına alınarak teşhis ve tedavide yararlanılmaktadır. EEG kayıtları, 10-20 elektrot yerleşim sistemine göre en çok C4/A1 veya C3/A2 elektrotlarından elde edilmektedirler. Göz hareketleri 1cm yukarıdan, bir gözün dış canthus bölgesinin yanından ve 1cm aşağıdan ikinci gözün dış canthus yanından takip edilir. İki göz içinde referans elektrotları aynı yöndeki kulak veya mastoid üzerine takılır. EMG çenenin altından kaydedilir (bilinç, bilinçaltı). Polisomnografik ölçüm için elektrotların nasıl yerleştirilmesi gerektiği Şekil 3.1’de gösterilmiştir. Uykunun evreleri epok-epok yaklaşımı ile yapılır ve her bir epok genellikle 30 s sürer.



Şekil 3.1. EEG kaydında elektrotların yerleşimi

Uyku evrelerinin skorlanması halen Rechtschaffen ve Kales’in editörlüklerini yaptığı grubun belirlediği prensipler esas alınarak yapılmakta olup bu güne kadar önemli bir değişiklik yapılmamıştır. Ancak AASM’nin (American Academy of Sleep Medicine) oluşturduğu bir çalışma grubu, bu konuda kökten değişikliklerin yapıldığı bir

çalışmayı sonuçlandırmak üzere olup, raporun yakında yayınlanması beklenmektedir [57].

Bununla beraber, Japon Uyku Araştırmaları Topluluğu'nun (JSSR) yaptıkları bir çalışmada halen kullanılan uluslararası uyku evrelerini skorlama kriterleri ve standartları (İnsan Uyku Evrelerinin Standart Terminolojisi, Yöntem ve Skorlama Elkitabı) için tamamlayıcı öneriler ve iyileştirme tanımları önerileri sunmuşlardır [58].

Tablo 3.1'de Rechtschaffen ve Kales'in editörlüklerini yaparak belirledikleri uluslararası standartlara göre çıkarılan EEG işaretlerinin frekans ve genlik özellikleri ve genellikle hangi uyku evresinde yaygın olarak görüldükleri özet olarak verilmiştir. Tablo 3.2'de ise uyku evreleri ve bu evrelerin genel karakteristik özellikleri özet olarak gösterilmiştir. Bu bilgiler ışığında uyanıklık, hareket zamanı ve uyku evrelerinin özellikleri aşağıdaki gibi sıralanabilir. Açıklamalarda verilen örnek grafikler ve yapılan bazı açıklamalar "İnsan Uyku Evrelerinin Standart Terminolojisi, Yöntem ve Skorlama Elkitabı" isimli kitaptan yararlanılmıştır [56].

Tablo 3.1. EEG özelliklerinin frekans, genlik ve zaman karakteristikleri

Özellik	Frekans	Genlik	Zaman
Alfa (α)	8-13 Hz	20-60 μ V	Uyanık, Evre I ve REM 'de görülür
Beta (β)	13+ Hz	2-20 μ V	Uyanırken baskındır
Teta (θ)	4-8 Hz	50-75 μ V	Evre I, II, III ve IV 'te görülür
Delta (δ)	0-4 Hz	75+ μ V	Evre III ve IV 'te görülür
Uyku İğcikleri (ζ)	12-14 Hz		Evre II (0.5-1.5s) 'de görülür
K-kompleksleri (κ)	0.4-1.5 Hz		Evre II 'de görülür


Tablo 3.2. Uyku evreleri ve her evrenin genel karakteristiği [59]

Uyku Evresi	Beyin Dalgası		Genel Karakteristiği
	Frekans	Tip	
Evre 1 (NREM)	4-8 Hz	Alfa ve teta	<ul style="list-style-type: none"> • Uyku ve uyanıklık arasındaki geçiş durumudur • Teta dalgasının çoğunu kapsar (yüksek genlik, düşük frekans) • Kısa periyotlarla alfa dalgası görülür • Sadece birkaç dakika sürer
Evre 2 (NREM)	8-12 Hz	Teta, iğcikler, K-kompleksleri	<ul style="list-style-type: none"> • Beyin dalgalarının peakleri yükseldikçe yükselir (uyku iğcikleri) • İğcikleri K-kompleksleri (peakler birden şiddetle düşer ve tekrar geri yükselir) izler. • Bu evre de sadece birkaç dakika sürer.
Evre 3 (NREM)	2-4 Hz	Delta, teta	<ul style="list-style-type: none"> • Derin uyku veya delta uykusu olarak da adlandırılır • Delta dalgaları olarak adlandırılan çok yavaş beyin dalgaları (teta dalgalarından daha düşük frekans) • Beyin dalgalarının %20 - %50'si delta dalgaları, geri kalanı teta dalgalarıdır.
Evre 4 (NREM)	0.5-2 Hz	Delta, teta	<ul style="list-style-type: none"> • Derin uyku veya delta uykusu olarak da adlandırılır • Beyin dalgalarının %50'sinden fazlası delta dalgaları, geri kalanı teta dalgalarıdır • REM evresinden önce uyku evrelerinin sonuncusudur (ve en derin uykusudur); evreler biter ve REM evresi başlar
REM evresi	> 12 Hz	Beta	<ul style="list-style-type: none"> • Beta dalgaları yüksek frekansa sahip ve beyin oldukça aktif olduğunda hem REM evresi hem de uyanık iken meydana gelir • Arasına meydana gelen kas hareketleri boyunca sık sık hızlı göz hareketleri olur • Kalp biraz daha hızlı çarpar, nefes alma yüzeysel ve hızlı olur • Rüyaların çoğu bu evrede meydana gelir

3.3.1. Uyanıklık (evre W)

Uyanıklık tanımlaması çok kolay bir evredir. Gözleri açık uyanık bir kişide EEG, çok düşük bir gerilim ve yüksek frekans davranışı gösterir. Frekans çok düzensiz ve son derece değişkendir. Tamamen uyanık bir kişide gerilim, 10 – 30 μ V aralığında, oldukça düşüktür. Gözleri kapalı uyanık bir kişinin EEG işaretinde Alfa aktivitesi baskın olabilir. Bu evrede göz hareketleri kontrollüdür ve hızlı kaymalar ve göz kırpmaları içerir.

Bu sürekli hızlı göz hareketleri, kas gerilim artifaktları ve nispeten sürekli alfa aktivitesinin eşlik ettiği uyanık evresine ilişkin örnek grafikler Şekil 3.2'de verilmiştir.




Şekil 3.2. Uyanık evresine ait örnekler

3.3.2. Hareket zamanı

Bir epoğun yarısından daha uzun süre boyunca, EMG ve EEG'nin sinyalleri, amlifikatör engelleme veya kas hareketleri nedeniyle tam tanımlanamıyorsa, evre uyku veya uyanıklık değil, hareket zamanı olarak tanımlanır. Bir epok hareket zamanı olarak skorlandığında, bir daha bulunmayacak şekilde kayıttan tamamen silinir. Bu hareketler, daha kısa olan münferit vücut hareketleriyle karıştırılmamalıdır. Uyku veya hareket zamanında vücut hareketleri gözlemlenebilir.

Şekil 3.3'te epoğun sonuna doğru net bir yüksek genlikli yavaş dalga aktivitesi olmasına rağmen epoğun büyük bir kısmı hareket artifaktı ile örtülmüştür ve o sebeple herhangi bir evre yerine hareket zamanı olarak skorlanır.




Şekil 3.3. Örnek bir hareket zamanı grafiği

3.3.3. Evre 1

Evre 1, 2-7 Hz aralığındaki EEG'nin karma frekansının en yüksek genliği ve düşük gerilim ile tanımlanmıştır. Tüm uykunun %3-8'ni Evre 1 kapsar. Dalgaların zirve noktasının genliği yaklaşık $200\mu\text{V}$ civarında oluşabilir. Evre 1'de uyanıklığın hemen ardından diğer evrelere geçişte daha sıklıkla gözlemlenir. EMG'nin seviyesi

uyanıklıktan daha düşüktür. Her epokta alfa aktivitesi ile karma frekanslı EEG görüldüğünde ve alfa aktivitesi epogun %50'sinden az olduğunda da, evre için Evre 1 denilmelidir. EOG işaretlerinde, yavaş veya istemli göz hareketleri ya da göz kırpmaları hareketleri izlenir. Orta-yüksek genlikte bir EMG aktivitesi izlenir.




Şekil 3.4. Evre 1 örnekleri

3.3.4. Evre 2

Bu evre Evre 1'in oluşmasından yaklaşık 10-12 dakika sonra başlar ve toplam uykunun %45-55'ini oluşturur. Evre 2'nin karakteristik özelliği uyku iğciği dalga yapısı ve K komplekslerini içermesidir [60]. K kompleksi, yavaş pozitif dalga ile takip edilen negatif keskin bir dalgadır ve 0.5 saniyeden daha çok sürer. Uyku iğcikleri 12-14Hz frekans aralığında oluşur. Bu dalgaların süresi minimum 0,5 saniyedir. Eğer K komplekslerin veya uyku iğciğinin iki müteakip oluşumu arasındaki zaman 3 dakikadan az ise ve hareketlerin canlanması veya duraklamalar sözkonusu değilse, bu zaman Evre 2 olarak adlandırılır. Eğer zaman aralığı 3 dakikadan fazla ise Evre 1 olarak skorlandırılır. Evre 2'de önce küçük miktarda delta dalgaları görülebilir. Uyanıklık evresi ile karşılaştırıldığında EMG aktivitesi azalır.

Uyku kaydının çeşitli yerlerinden alınan Şekil 3.5'teki EEG işaretleri Evre 2'ye aittir. Bunlar özellikle seçilmişlerdir, çünkü yüksek genlikli yavaş dalga aktivitesinin yüzdesi Evre 3 olarak sınıflandırmaya çok yakın olmakla birlikte yeterli değildir. Her bir kayıttaki kabul edilebilir yüksek genlikli yavaş dalga aktivitesinin yüzdesi kayıtların sağ tarafına yazılmıştır.




Şekil 3.5. Evre 2 Örnekleri

3.3.5. Evre 3

Uyku evresinin Evre 3 olarak tanımlanabilmesi için, EEG kaydında ilgilenilen epoğun %20-%50'lik bir kısmı, 2 Hz veya daha yavaş dalgaları içermeli ve genlik 75 μ V'in üzerinde seyretmelidir. Sağlıklı bir insanda toplam uykunun %15-20'sini Evre 3 ve Evre 4 oluşturur, yavaş dalga uykusu olarak da adlandırılır. Evre 3'te uyku İğcikleri ve K kompleksleri oluşabilir.

Şekil 3.6'daki dört kopyanın ilk ikisinin seçilme sebebi Evre 3 olarak sınıflandırmaya ancak yetecek kadar yüksek genlikli yavaş dalga aktivitesi göstermeleridir. Evre 2 mi? Evre 3 mü? diye skorlamanın şüpheli olduğu sınır durumlarda, şüpheli kaydın bu kopyalarla karşılaştırılması karar vermeyi kolaylaştırabilir. Sonraki iki kopyanın seçilmesi yüksek genlikli yavaş dalga aktivitesinin Evre 4 ile karıştırılabilecek kadar yakın olmasıdır. Her kopyadaki altı çizilmiş kısımlar "kabul edilebilir" yüksek genlikli yavaş dalga aktivitesi olarak değerlendirilmiştir, örneğin, 2 Hz veya daha yavaş ve tepeden tepeye 75 μ V'dan daha büyük.




Şekil 3.6. Evre 3 örnekleri

3.3.6. Evre 4

Evre 4, Evre 3 ile aynı özelliğe sahiptir fakat dalgaları, genliği $75 \mu\text{V}$ 'den büyük, frekansı 2 Hz ve daha yavaştır. Epoğun %50'sinden fazlasında delta aktivitesi görülür. Evre 3 ile beraber, sağlıklı bir insanın toplam uykusunun %15-20'sini meydana getirir.

Şekil 3.7'de verilen örneklerde ilk grafik oldukça belirgin bir şekilde yüksek genlikli yavaş dalga aktivitesi (altı çizili kısımlar) içerdiğinden Evre 4 olarak skorlanır.




Şekil 3.7. Evre 4 örnekleri

3.3.7. REM uykusu (REM evresi)

REM uykusu normal bir insanın toplam uykusunun %20-25'inden oluşur. EEG kaydının REM uykusu süresince düşük genlikli bir gerilim, yavaş alfa ve teta dalgalarıyla beraber karışık bir frekans aktivitesi ile karakterize edilir. EEG, EMG ve EOG işaretlerinin karakteristiklerine bağlı olarak REM uykusu tonik ve fazik olmak üzere iki alt gruba ayrılır. Tonik REM uykusunun karakteristik özellikleri senkron olmayan EEG işaretleri, iskelete bağlı kas gruplarının ton yokluğu, monosinaptik ve polisınaptik reflekslerin bastırılmasıdır. Fazik REM uykusunun karakteristik özellikleri, kan basıncı ritmi, kalp atış hızı değişimleri, düzensiz solunum, dil hareketleri ve çene ve kol kaslarının miyoklonik seğirmeleri gibi bütün durumlardaki hızlı göz hareketleridir [61]. REM uykusu işareti teta bandında frekansa ve testere ağzının kesen kenarının görünümüne sahip testeredişi dalgalarına benzer bir yapıdadır. REM uykusu esnasında uyku apneası veya hipoapnea meydana gelebilir. REM uykusu evresinde rastgele hız göz hareketleri meydana gelir ve EMG en düşük seviyesine (derin dinlenmiş kaslar) iner.

Düşük gerilimli, karışık frekanslı EEG işaretleri verilen REM evresine ait grafikler Şekil 3.8'da verilmiştir.

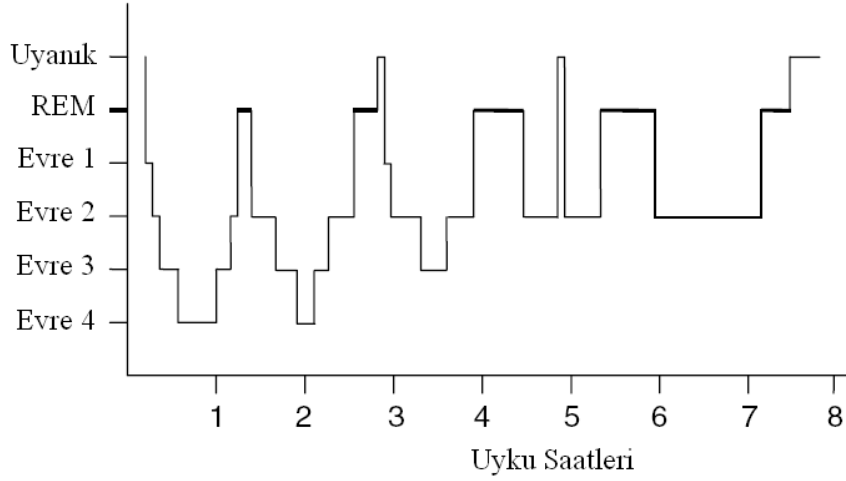


Şekil 3.8. REM evresi örnekleri

3.4. Hipnogram

İnsan uyku yapısının izlendiği tüm uyku süresi boyunca skorlanan polisomnogramdan elde edilen uyku evrelerini gösteren histograma hipnogram denir. Hipnogram epok denilen (genellikle 30sn) bir zaman birimine sahip ve uyku ile ilgili hastalıkları tespit etmek için nörologlar tarafından kullanılır. Bir nörolog bir hipnogram kullanarak uyku ile ilgili belli hastalıkları gerçekten teşhis edebilir. Uyku

sorunu olmayan normal yetişkin bir insanın 8 saatlik bir uyku için hipnogramı Şekil 3.9'da gösterilmiştir.



Şekil 3.9. Normal bir insanın uyku hipnogramı

3.5. Uyku Evreleri Standartlarının Sınırları

İnsan bilincinin bir sembolü olarak EEG işareti, sürekli ve kademeli değişimler ile karakterize edilir. Bununla beraber, uyku evreleri, insan uyku örüntüsünü kendi bilgi, beceri ve anlamalarına göre yapan nörofizyologlar tarafından tanımlanan ayrık sınıflandırmalardır. Bu yüzden, işaret parçaları içindeki yapay evreler ile doğal durumlar arasındaki uyum oldukça zayıftır. Uyku evrelerini skorlamak için Rechtschaffen ve Kales tarafından ortaya konan kurallar 35 yıldan uzun süredir kullanılmasına rağmen halen bazı eksiklik ve dezavantajlara sahiptir. Bu yüzden, uyku evrelerini sınıflandırırken dikkate alınması gerekir [62, 63, 64]:

1. Standart epok uzunluğu 30 saniyedir, fakat genellikle evreler bu 30 saniye içinde birkaç evre özelliği gösterebilir. Şekil 3.10 Uyanık ve Evre 1 evreleri arasındaki geçişi gösterir. Bu durumda epokun süresi içinde hangi evrenin özelliği en fazla ise, epok o evre ile skorlanır.
2. Bir evreden diğer evreye değişim karakteristiği olan genlik ve frekans değişimleri kademeli olabilir. Şekil 3.10 aynı zamanda evreler arasındaki kademeli değişimi de gösterir.

3. Uyku iğcikleri ve K kompleksleri gibi karakteristik özellikler sadece belli zamanlarda görünür. Mesela Uyku iğcikleri ve K kompleksleri Evre 2 için karakteristik özelliktir, fakat Evre 3'te de görülebilir. Bu durumları tespit etmek zordur.
4. Uyku evrelerine ayırma kuralları, özellikle belli durumlar (uyku iğciği, K-kompleksi, verteks dalgalar) meydana geldiğinde oluşan durumları, bilgisayar tarafından kabul edilen kurallara çevirmek zordur.
5. Kurallar sadece sağlıklı ve yetişkin insanlar için tanımlandılar ve bunun sonucu olarak hasta insanlara veya çocuklara ait tipik örüntüleri skorlamak mümkün değildir.
6. Elde edilen sonuçlar, eğitilmiş medikal uzmanlar tarafından sınıflandırılmış evreler ile karşılaştırılır fakat bu uzmanların gözlem uyumu %90'dan daha azdır [65].



Şekil 3.10. Uyanık evresinden Evre 1'e kademeli geçiş özelliği içeren bir epeğun ortası

BÖLÜM 4. UYKU EEG'SİNDE ÖZELLİK ÇIKARMA VE İŞARETLERİN ÖN-İŞLENMESİ

4.1. Giriş

Uyku evrelerinin skorlanması ve sınıflandırılmasında özellik çıkarma en önemli adımdır. Uyku evrelerinin skorlanması ve sınıflandırılması ile ilgili yapılan daha önceki çalışmalar, genellikle uyku EEG işaretinden belirlenen özelliklerin üç ana grupta toplanarak üzerine yapılmıştır. Bunlar, EEG işaretinin kendisinden hesaplanan zaman-uzayı özellikleri, EEG işaretinin frekans spektrumundan hesaplanan frekans-uzayı özellikleri, zaman ve frekans-uzayı özelliklerinin birlikte kullanılmasıyla oluşturulan hibrit özelliklerdir [7, 26, 29, 66-69]. Zaman kısıtlaması nedeniyle her grupta kullanılan tüm özellikleri incelemek mümkün değildir. Bu bölümde uyku evrelerinin sınıflandırılması çalışmalarında en sık kullanılan ve bu çalışmada incelenen özellik vektörlerinin kısa tanımları verilmiştir. Ayrıca özelliklerin hesaplanmasında kullanılan filtreleme ve spektral güç yoğunluğu hesaplanırken kullanılan Yule-Walker AR (Autoregressive) yöntemi anlatılmıştır. Çalışmada kullanılan veriler üzerinde örneklerle gösterilmiştir.

4.2. Zaman Uzayındaki Kullanılan Özelliklerin Çıkarılması

Zaman-uzayındaki özellikler, orijinal EEG işaretinden elde edilen özelliklerdir. Ortalama değer, standart sapma, medyan, aktivite, hareketlilik ve karmaşıklık olarak adlandırılan Hjorth parametreleri; iki EEG işareti arasındaki korelasyon katsayısı ve karesel ortalama sıklıkla kullanılan zaman-uzayı özellikleridir. Bu değerler, uykunun her bir evresi için farklı ve ayırt edici bir özelliktir. Yapılan çalışmada kullanılan medyan, korelasyon katsayısı ve karesel ortalama hariç diğer parametrelerin nasıl hesaplandığı ilerleyen kısımlarda anlatılmıştır. Denklemlerde elektrotlar vasıtasıyla alınan analog bir EEG işaretinin, epok olarak adlandırılan 30sn'lik segmentler

halinde kaydedildiği, analog işaretin Nyquist örnekleme teoremine uygun olarak örneklendiği varsayılmış ve örneklenmiş EEG işareti $nx1$ boyutunda bir x vektörü ile belirtilmiştir. Dolayısıyla x_i notasyonu, x vektörünün i . elemanını belirtmektedir. Ayrıca aktivite, hareketlilik ve karmaşıklığı tanımlayan denklemlerde σ_i notasyonu x vektörünün i . türevinin varyansını göstermektedir. Bir vektörün çeşitli derecelerden türevinin hesaplanmasında bilinen herhangi bir yöntem kullanılabilir [70].

4.2.1. Ortalama

EEG potansiyelinin (pozitif ve negatif) toplamı genellikle birkaç mikrovolt seviyesinde olduğundan analiz zamanı yeterince küçük iken ortalama aslında küçük bir değer olmasına rağmen sabittir. Ortalamanın değerindeki kaymalar bu nedenle, yükseltici sapmaları vb. gibi teknik kökenli olan potansiyeldeki değişimleri gösterir. Bir EEG işareti olan x vektörü için ortalama değer

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (4.1)$$

bağıntısı ile hesaplanır

4.2.2. Standart sapma

EEG işaretinin genlik dağılımının varyansı, bu işaretin toplam gücü ile doğrudan ilişkilidir. Mesela, geniş salımlı bir EEG işareti yüksek varyans değerleri verirken sabit bir EEG işareti düşük varyans değerleri verir. Karışıklıktan kaçınmak ve elektroensefalografılara daha yakın birimler kullanmak için standart sapma terimi sık kullanılır. Bir x EEG işaretinin standart sapması

$$(a) \quad s = \left(\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^{1/2} \quad (4.2)$$

$$(b) \quad s = \left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^{1/2} \quad (4.3)$$

bağıntılarından biri kullanılarak hesaplanır. Burada \bar{x} , x özellik vektörünün ortalama

değerini göstermektedir ve $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ dir.

4.2.3. Hjorth parametreleri

Bir x işaretinin bir kısmındaki varyans, birinci ve ikinci türevine dayanan Hjorth methodu EEG işaretini belirtmek için üç parametre çıkarır. Eğer x özellik vektörünün i 'inci türevinin varyansı σ_i (x özellik vektörünün varyansı σ_0 olur) olarak tanımlanırsa, daha sonra Hjorth parametreleri aşağıdaki gibi tanımlanır:

$$\text{Aktivite } A = \sigma_0^2 \quad (4.4)$$

$$\text{Hareketlilik } M = \frac{\sigma_1}{\sigma_0} \quad (4.5)$$

$$\text{Karmaşıklık } C = \sqrt{(\sigma_2 / \sigma_1)^2 - (\sigma_1 / \sigma_0)^2} \quad (4.6)$$

Bu parametreleri spektral yoğunluk fonksiyonu $P(f)$ etkisi ile ilişkilendirmek mümkündür, hareketlilik merkez frekansı ve karmaşıklık ise işaretin band genişliği için bir ölçümdür.

Hjorth parametreleri, aynı zamanda eğer EEG işareti sadece bir maksimumu olan simetrik bir olasılık yoğunluk fonksiyonuna sahipse geçerli bir tanım verir. Hesaplanabilen karışıklık parametresinin doğruluğunun sınırlı olduğuna dikkat edilmelidir. Bu yüzden yüksek gürültü frekanslarının etkisini azaltmak için EEG işareti band geçiren bir filtreden geçirilmelidir.

Her şeye rağmen, bu parametreler uyku kayıtlarından ve zaman işaretinden kolayca hesaplanabilen basit bir karakteristiğe sahip olup, analiz edilen işaretler, EEG işaretleri olduklarından, pratik bir analizde önemli olabilirler. Hjorth

parametrelerinin hesaplanması sonucunda her uyku evresi için 3 boyutlu bir vektör uzayı elde edilmektedir.

4.3. Frekans Uzayındaki Özelliklerin Çıkarılması

Tablo 4.1.'de tanımlanan frekans bantlarının her biri için, banttaki toplam spektral gücün (P_{PEB}) toplam spektral güce (P_{TPC}) oranı olarak tanımlanan bağıl spektral güç, harmonik parametreler, spektral kenar frekansı [71], Itakura mesafesi sık kullanılan frekans-uzayı özellikleri olup bunlardan Itakura mesafesi hariç diğer parametrelerin hesaplanması ilerleyen konularda verilmiştir. Denklemlerde $P(f)$ notasyonu, x ile belirtilen örneklenmiş EEG özellik vektöründen uygun bir spektral analiz yöntemi ile (Yule-Walker, Burg, Welch, Kovaryans, Değiştirilmiş Kovaryans vb. [72]) hesaplanmış güç spektrumunu, f_L , EEG işaretindeki mevcut en düşük frekansı (0.5 Hz), f_H , en yüksek frekansı (45Hz) belirtmektedir.

4.3.1. Bağıl enerji yoğunlukları

Bütün frekans özellikleri, spektral güç yoğunluğu içeren EEG işaretlerinin frekans spektrumundan çıkarılır. Bu analiz için 9. dereceden Yule Walker AR parametreleri kullanılarak spektral güç yoğunluğu $P(f)$ hesaplandı. $P(f)$ 'nin toplam spektral güç (TPC) hesaplanmalıdır. Tablo 4.1'de her bir bandın spektral güç yoğunluğu için frekans aralığı gösterilmiştir [26]. Bu şekilde $P(f)$ yedi farklı güç bandına ayrılır ve her bir frekans bandı için (PEB) sırasıyla hesaplanır. Bağıl yüzde spektral güç yoğunluğu (RPEB) aşağıdaki gibi tanımlanır:

$$RPEB = \frac{PEB}{TPC} \times 100 \quad (4.7)$$

Tablo 4.1. EEG işaretlerinin Spektral Enerji Bandları

<i>Band</i>	<i>Band Genişliği (Hz)</i>
Delta 1	0.5-2.5
Delta 2	2.5-4
Teta 1	4-6
Teta 2	6-8
Alfa	8-12
Beta 1	12-20
Beta 2	20-45

4.3.2. Harmonik parametreler

Harmonik parametreler, Hjorth parametrelerinin frekans versiyonlarıdır, bunlar; merkez frekans, band genişliği ve merkez frekansındaki spektral güç değeridir. Bu parametreler f_L ve f_H , sırasıyla 0.5 ve 45Hz olmak üzere aşağıdaki gibi tanımlanır:

$$f_c = \frac{\int_{f_L}^{f_H} f \cdot P(f) df}{\int_{f_L}^{f_H} P(f) df} \quad (4.8)$$

$$f_\sigma = \sqrt{\frac{\int_{f_L}^{f_H} (f - f_c)^2 \cdot P(f) df}{\int_{f_L}^{f_H} P(f) df}} \quad (4.9)$$

$$P_{fc} = P(f_c) \quad (4.10)$$

$P(f)$ fonksiyonu ayrık değerlerden oluştuğu için, yukarıdaki formülleri aşağıda gösterilen toplamlar şeklinde hesaplamak mümkündür:

$$\text{Merkez frekansı : } f_c = \frac{\sum_{f=f_L}^{f_H} f \cdot P(f)}{\sum_{f=f_L}^{f_H} P(f)} \quad (4.11)$$

$$\text{Bant genişliği : } f_{\sigma} = \sqrt{\frac{\sum_{f=f_L}^{f_H} (f - f_c)^2 \cdot P(f)}{\sum_{f=f_L}^{f_H} P(f)}} \quad (4.12)$$

$$\text{Merkez frekansındaki güç : } P_{f_c} = \hat{P}(f_c') \quad (4.13)$$

Yukarıdaki formüllerde f indisi, 0.5Hz den 45 Hz e kadar olan frekansları kapsar. f_c' değeri f_c ye en yakın f değerine eşittir. $\hat{P}(f_c')$ değeri de, denklem (4.10) verilen f_c' 'ye en yakın f frekansındaki güç değerini göstermektedir.

4.3.3. Spektral kenar frekansı

Spektral kenar frekansı, toplanmış spektral değerlerin ilk %90 a ulaştığı frekans değerine denir. Diğer bir ifade ile yaptığımız çalışmada frekans spektrumu hesaplanan EEG işaretinin her bir frekansa karşılık gelen spektral gücün toplamının, tüm spektrumdaki frekanslara karşılık gelen spektral gücün toplamına oranının %90 olduğu frekans değerine spektral kenar frekansı denir.

$$\text{Spektral kenar frekansı } f_{spe} : \frac{\sum_{f=f_L}^{f_{spe}} P(f)}{\sum_{f=f_L}^{f_H} P(f)} = 0.9 \quad (4.14)$$


Denklem (4.14)'deki ifadeyi sağlayan en küçük f_{spe} frekans değeri spektral kenar frekansı olarak tanımlanır [71].

4.4. İşaretlerin Ön-işlenmesi

4.4.1 Butterworth bant geçiren filtreleme

İşaret işlemede kullanılan veri işaretleri sensörler vasıtasıyla alındıkları için orijinal işaret üzerinde, sensörlerdeki elektronik elemanlar ve olumsuz çevre şartlarından

kaynaklanan ve istenmeyen parazitler oluşabilir. İşaretler üzerindeki bu istenmeyen parazitleri yok etmek veya etkilerini en aza indirmek filtreler yardımıyla olur. Filtreler analog olarak tasarlanabildikleri gibi sayısal olarak da tasarlanabilirler [73]. İstenen örnekleme frekansı ile sayısal işarete dönüştürülen analog işaret Matlab programı ile işlenebilir. Şekil 4.1’de bir analog işaretin filtreleme işlem basamakları gösterilmiştir. $x(t)$ işareti uygun bir örnekleme frekansı ile $x(n)$ sayısal işarete dönüştürülür. Daha sonra sayısal $x(n)$ işareti filtre karakteristiklerini içeren a , b parametreleri yardımıyla filtreleme işlemi yapılarak, filtrelenmiş $y(n)$ işareti elde edilir. $y(n)$ işareti istenirse bir dijital - analog dönüştürücü ile tekrar orijinal işarete dönüştürülebilir.



Şekil 4.1 Filtreleme işlemi

Analog sistemler, matematiksel model olarak fark denklemleri ile ifade edilirler. Darbe veya impuls dizisi şeklindeki zamanda süreksiz işaretler ve bu işaretlerin işlendiği sayısal filtreler, fark denklemleri ile modellenilebilir. n örnekleme sayısı ve T örnekleme periyodu olmak üzere fark denklemleri, ayrık zaman bölgesinde $f(nT)$ gibi bir fonksiyon ile tanımlanır. Sürekli zaman işaretlerinde giriş ve çıkış fonksiyonları $x(t)$ ve $y(t)$ olarak gösterilirken fark denklemlerinde, bu fonksiyonlar $x(n)$ ve $y(n)$ şeklinde gösterilir. Fark denklemleri [73] genel olarak

$$a_1y(n) + a_2y(n-1) + a_3y(n-2) + \dots + a_My(n-M) = b_1x(n) + b_2x(n-1) + b_3x(n-2) + \dots + b_Nx(n-N) \quad (4.15)$$

ile ifade edilirler. Burada x , giriş işaretini; y , çıkış işaretini; a_i , $i=1, 2, \dots, M$ ve b_i , $i=1, 2, \dots, N$ sırasıyla geri ve ileri besleme katsayılarını temsil etmektedir; $y(n)$, şu an ki çıkış değerine; $y(n-1)$, bir periyot önceki çıkış değerine karşılık gelmektedir. Fark denklemlerinin derecesi en büyük M ve N ile belirlenir. a ve b katsayıları Denklem (4.16)’deki gibi vektör şeklinde gösterilebilir.

$$\begin{aligned} a &= [a_1 \ a_2 \ a_3 \ \dots \ a_M] \\ b &= [b_1 \ b_2 \ b_3 \ \dots \ b_N] \end{aligned} \quad (4.16)$$

Sayısal filtreler, fark denklemlerinin yanı sıra transfer fonksiyonları ile de tanımlanabilirler [74, 75]. Transfer fonksiyonu kısaca sistem çıkışının sistem girişine oranı ile belirlenir. z - bölgesinde, filtrelerin kesirli polinom şeklindeki genel transfer fonksiyonu Denklem (4.17)' de verilmiştir. Bu denklemde z^{-1} birim gecikmeyi, a ve b katsayıları da filtre karakteristiklerini göstermektedir. Burada a_1 terimi mutlaka 1 sayısına eşit olmalıdır, eğer 1 değilse tüm sayılar bu terime bölünerek normalize edilmelidir.


$$H(z) = \frac{B(z)}{A(z)} = \frac{b_1 + b_2 z^{-1} + b_3 z^{-2} + \dots + b_n z^{-(n-1)}}{a_1 + a_2 z^{-1} + a_3 z^{-2} + \dots + a_n z^{-(n-1)}} \quad (4.17)$$

Sayısal filtre tasarımı için, istenilen filtre karakteristiğinin a ve b katsayılarını hesaplamak gerekir. a ve b katsayıları istenilen genlik cevabı yardımıyla elde edilebilir. Bu katsayılar, istenilen filtre özelliğini gösterecek şekilde Matlab programı işaret işleme toolbox'ı içinde kolayca hesaplanabilir.


Bu çalışmada, her bir uyku evresine ait sürekli işaretler 100Hz örnekleme frekansı ile dijital işarete çevrildikten sonra, 6. dereceden bir bant geçiren Butterworth filtresi tasarlanmıştır. Bant geçiren filtrenin kesim frekansları, EEG işaretlerinde genellikle sınır frekanslar olarak verilen 0.5Hz ve 45Hz olarak belirlendi. Filtrenin karakteristik katsayıları olan a ve b katsayıları Matlab programı kullanılarak hesaplandı. Burada bu filtrenin kullanılmasının nedeni, literatürde kullanılan bir filtre olması ve bu sayede elde edilen sonuçları literatürde elde edilen sonuçlar ile karşılaştırma imkanı sağlamasıdır.

Uyku EEG'sinde her bir uyku evresine karşılık gelen verilere uygulanan filtrenin karakteristiği Şekil 4.2'de gösterilmiş ve a ve b karakteristik katsayıları aşağıdaki gibi hesaplanmıştır.


$a=[1 \ -0.5638 \ -2.1661 \ 0.755 \ 1.7559 \ -0.2816 \ -0.4992]$
 $b=[0.7066 \ 0 \ -2.1197 \ 0 \ 2.1197 \ 0 \ -0.7066]$



Şekil 4.2. Uyku EEG'si için tasarlanan filtre karakteristiği



Şekil 4.3. Filtrelenmemiş bir Evre 1 epöğü



Şekil 4.4. Filtrelenmiş bir Evre 1 epöğü

4.4.2. Yule-Walker AR yöntemi

Modern spektral analiz yöntemlerinde güç spektrumunun hesaplanmasında tepe frekansı, band genişliği veya güç içeriği gibi çeşitli parametreler hesaplandığından, bu yöntemlere model tabanlı (parametrik) analiz yöntemleri denir. Model tabanlı güç spektrum tahmin yöntemleri, spektral kaçak problemlerini ortadan kaldırdığı için daha iyi bir frekans çözünürlüğü sunar. Modern spektral analiz yöntemlerinde spektral güç tahmininde AR (Auto Regressive) yöntemi yaygın olarak kullanılmaktadır. Bu yöntemin en önemli avantajları, orijinal spektruma daha yakın olması ve kısa bir örnekleme süresi gerektirmesi olarak sayılabilir.

Herhangi bir işareti uygun bir şekilde modellemek için işaretin özelliklerinin göz önünde bulundurulması gerekmektedir. Mesela AR modeli, frekans spektrumunda ani pikleri bulunan işaretler için uygundur. Moving Average (MA), bunun tam tersine keskin pikleri olmayan işaretler için kullanılır. Autoregressive Moving Average (ARMA) ise her iki işaret türü için kullanılabilir. EEG işaretlerinin yapısında belirli frekans aralıklarında pikler bulunduğundan AR veya ARMA tercih

edilir. AR yöntemi ARMA'ya göre işlem yükü açısından daha avantajlıdır. AR yöntemiyle spektral analiz yapılmasında, Yule-Walker eşitliğinden yararlanılarak oluşturulan Levinson - Durbin yöntemi kullanılmaktadır [76, 77].

Yule-Walker AR spektral tahmin yönteminde, AR parametreleri verilen işaretin özilişki matris fonksiyonunun ön tahmini yapılarak ve ileri doğru tahmin hatalarının en küçük kareler yöntemi ile minimumlaştırılarak hesaplanır. Özilişki fonksiyonunun ön tahmini, kullanılacak özilişki matrisinin pozitif-tanımlı olmasını (yani matrisin tersinin alınabilir olmasını) ve matrisin çözümünün olmasını sağlar. Ayrıca özilişki matrisi hesaplanan AR parametreleri, her zaman kararlı bir tüm-kutup model yapısındadır. Yule-Walker eşitlikleri, özilişki matrisinin Toeplitz yapısı avantajını kullanan Levinson algoritması ile verimli bir şekilde çözülebilir [75, 77]. $\{x(0), x(1), \dots, x(N-1)\}$ verisinin gözlemlendiği varsayalım. Yule-Walker veya özilişki yönteminde, AR parametreleri tahmin hatasının minimizasyonu ile hesaplanır.

$$\hat{\rho} = \frac{1}{N} \sum_{n=-\infty}^{\infty} \left| x(n) + \sum_{k=1}^p a(k)x(n-k) \right|^2 \quad (4.18)$$

Denklem 4.18'de, $x(n)$ sürecinde gözlenmeyen ($0 \leq n \leq N-1$ aralığında olmayan) örnekler sıfır kabul edilirler. Tahmin edilen kestirim hatası, Denklem 4.18'in $a(k)$ 'lerin gerçel ve sanal kısımlarına göre türevi alınmasıyla minimize edilir. Bu, kompleks eğim kullanılarak yapılabilir. Bu durumda,

$$\frac{1}{N} \sum_{n=-\infty}^{\infty} \left(x(n) + \sum_{k=1}^p a(k)x(n-k) \right) x^*(n-1) = 0 \quad l=1,2,\dots,p \quad (4.19)$$

elde edilir. İfade matris biçiminde yazılırsa,

$$\begin{bmatrix} \hat{r}(1) \\ \cdot \\ \cdot \\ \cdot \\ \hat{r}(p) \end{bmatrix} + \begin{bmatrix} \hat{r}(0) & \cdot & \cdot & \cdot & \hat{r}(-p+1) \\ \cdot & & & & \cdot \\ \cdot & & & & \cdot \\ \cdot & & & & \cdot \\ \hat{r}(p-1) & \cdot & \cdot & \cdot & \hat{r}(0) \end{bmatrix} \begin{bmatrix} \hat{a}(1) \\ \cdot \\ \cdot \\ \cdot \\ \hat{a}(p) \end{bmatrix} = \begin{bmatrix} 0 \\ \cdot \\ \cdot \\ \cdot \\ 0 \end{bmatrix} \quad (4.20)$$

veya

$$\hat{\mathbf{r}}_p + \hat{\mathbf{R}}_p \hat{\mathbf{a}} = 0 \quad (4.21)$$

olur, burada

$$\hat{r}(k) = \begin{cases} \frac{1}{N} \sum_{n=0}^{N+k} x^*(n)x(n+k), & k=0, 1, \dots, p \\ \hat{r}^*(-k), & k=(-p+1), (-p+2), \dots, -1 \end{cases} \quad (4.22)$$

Denklem (4.21)'den tahmin edilen AR parametreleri aşağıdaki gibi bulunur.

$$\hat{\mathbf{a}} = -\hat{\mathbf{R}}_p^{-1} \hat{\mathbf{r}}_p \quad (4.23)$$

Beyaz gürültü varyansı σ^2 aşağıda verildiği gibi, ρ_{\min} olarak bulunur.


$$\hat{\sigma}^2 = \hat{\rho}_{\min} = \frac{1}{N} \sum_{n=-\infty}^{\infty} \left| x(n) + \sum_{k=1}^p \hat{a}(k)x(n-k) \right|^2 \quad (4.24)$$

sonuç, Denklem (4.18) kullanılarak bulunur.


$$\hat{\sigma}^2 = \hat{r}(0) + \sum_{k=1}^p \hat{a}(k)\hat{r}(-k) \quad (4.25)$$

AR parametrelerinin tahminlerinden güç spektral yoğunluğu aşağıdaki gibi oluşturulur [78, 79].


$$\hat{P}_{YW}(f) = \frac{\hat{\sigma}^2}{\left| 1 + \sum_{k=1}^p \hat{a}(k)e^{-j2\pi fk} \right|^2} \quad (4.26)$$




Şekil 4.5. Evre 1 için Yule-Walker AR parametreleri ile elde edilen güç spektrumları




Şekil 4.6. Evre 2 için Yule-Walker AR parametreleri ile elde edilen güç spektrumları




Şekil 4.7. Evre 3 için Yule-Walker AR parametreleri ile elde edilen güç spektrumları



Şekil 4.8. Evre 4 için Yule-Walker AR parametreleri ile elde edilen güç spektrumları



Şekil 4.9. REM Evresi için Yule-Walker AR parametreleri ile elde edilen güç spektrumları



Şekil 4.10. Uyanık Evresi için Yule-Walker AR parametreleri ile elde edilen güç spektrumları

Şekil 4.5 – Şekil 4.10’da, sağlıklı bir kişiden alınan normal uyku EEG’si işaretleri ve bu işaretlerin Yule-Walker yöntemiyle elde edilen AR spektrumu görülmektedir. Ayrıca Burg AR, kovaryans ve değiştirilmiş kovaryans yöntemleri ile çalışmalarda elde edilen spektrumlar incelendiğinde aralarında çok küçük farkların olduğu görülmüştür. Özellikle Burg ve Yule-Walker yöntemiyle elde edilen güç spektrumları kıyaslandığında görsel olarak birbirlerine çok yakın oldukları görülmektedir. Simülasyonlar kısmında kullanılan güç spektrum hesaplamalarında Yule-Walker AR kullanılmıştır.

BÖLÜM 5. UYKU EVRELERİNİ GRUPLAMA VE SINIFLANDIRMA YÖNTEMLERİ

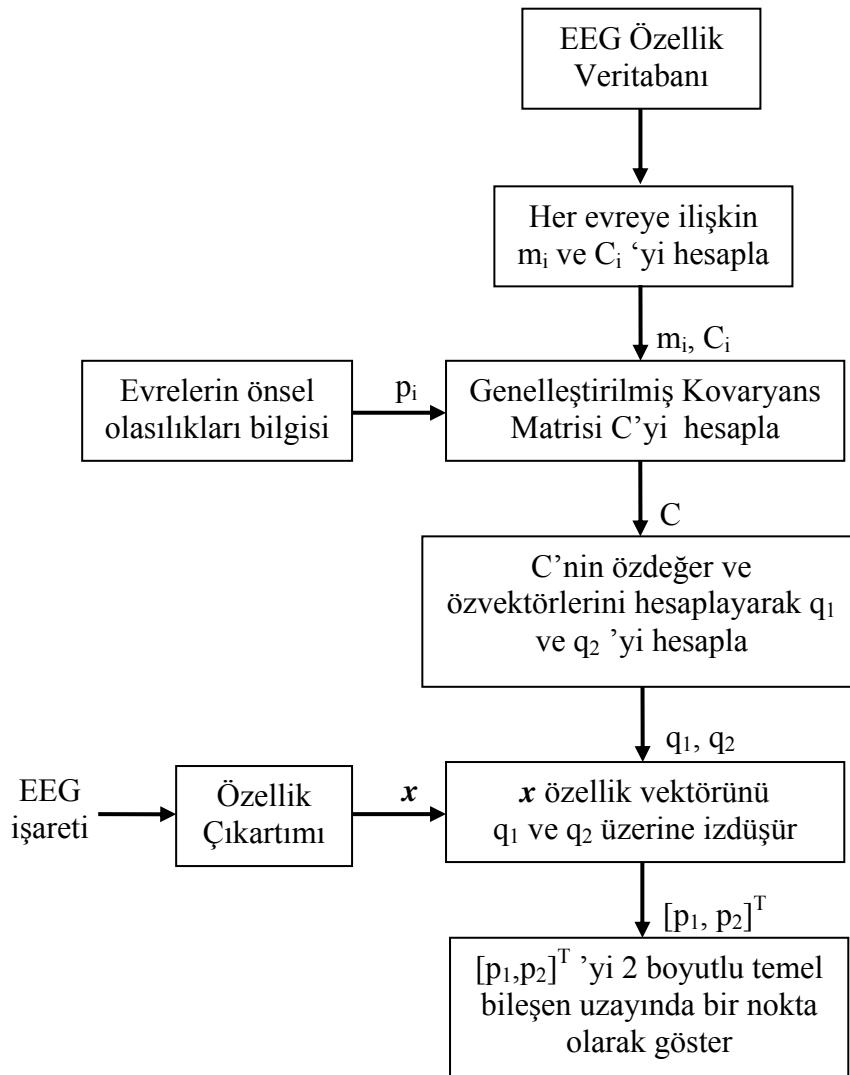
5.1. Giriş

Uyku evrelerini sınıflandırmada sıklıkla kullanılan özellik vektörlerinin boyutu genelde üçten büyük olduğundan, bir özellik vektörünün özellik uzayında bir nokta olarak göz önünde canlandırılması mümkün değildir. Özellik vektörünün özellik uzayında bir nokta olarak göz önünde canlandırılabilmesi için, içerdiği bilgide çok fazla kayıp olmadan boyutunun üç veya daha aza indirgenmesi gereklidir. Bu işlem yapılırken sınıflandırma için en önemli iki veya üç bilgi seçilmelidir.

Boyut azaltımı amacıyla kullanılan işlem temel bileşen analizidir (PCA) [80, 81]. Temel bileşen analizinin kullanılmasındaki amaç, sınıflandırma amacıyla faydalı bilgi yönünde yeni bir koordinat sistemi tanımlamaktır. Özellik vektörleriyle aynı boyuta sahip, yeni koordinat sistemini belirleyen iki vektör öyle seçilmelidir ki aynı uyku evrelerine karşılık gelen özellik vektörleri bu iki vektör üzerine izdüşürüldüğünde elde edilen noktalar dar bir bölgede kümelenirken farklı uyku evrelerine karşılık gelen izdüşümler farklı bölgelerde kümelenmelidir.

5.2. Temel Bileşen Analizi (PCA)

Bu çalışmada sunulan PCA yönteminde, özellik vektörlerini iki boyutlu uzayda bir nokta olarak temsil etmek amacıyla kullanılan iki vektör uyku evrelerinin ortalama özellik vektörlerinden hesaplanan kovaryans matrislerinin ağırlıklı toplamı olarak belirlenen genelleştirilmiş bir kovaryans matrisinin genliği en büyük iki özdeğerine karşılık gelen özvektörler olarak seçilmiştir. Geliştirilen yöntem Şekil 5.1’de blok diyagram olarak verilmiş ve detayları aşağıda açıklanmıştır [82, 83].



Şekil 5.1. Temel bileşen analizi yöntemi blok diyagramı

EEG işaretlerinden çıkarılan her uyku evresine ait özelliklerin oluşturduğu veritabanının bir kısmı genelleştirilmiş kovaryans matrisini hesaplamak için kullanılır. Bir özellik vektörünün $px1$ boyutuna sahip olduğunu, Uyanık, REM, Evre 1, Evre 2, Evre 3, Evre 4 evrelerinden sırasıyla N_1, N_2, \dots, N_6 adet özellik vektörüne sahip olduğumuzu varsayalım. Her bir uyku evresine karşılık gelen $px1$ boyutunda ortalama özellik vektörü m_i ve pxp boyutunda kovaryans matrisi C_i

$$m_i = \frac{1}{N_i} \sum_{m=1}^{N_i} \chi_{i,m} \quad i=1, 2, \dots, 6 \quad (5.1)$$

$$C_i = \frac{1}{N_i} \sum_{m=1}^{N_i} (\chi_{i,m} - m_i) \cdot (\chi_{i,m} - m_i)^T \quad i=1, 2, \dots, 6 \quad (5.2)$$

ilişkileri kullanılarak hesaplanır. Yukarıdaki denklemlerde $x_{i,m}$ notasyonu i . evreye ($i=1, 2, \dots, 6$) ilişkin m . ($1, 2, \dots, N_i$) özellik vektörünü belirtmektedir. Denklem (5.1) ve Denklem (5.2) kullanılarak her uyku evresine ait bir ortalama değer (m_i) ve bir kovaryans matrisi (C_i) hesaplanmış olur. Her bir uyku evresinin görülme sıklığını ifade eden uyku evrelerinin önsel olasılıkları p_1, p_2, \dots, p_6 olmak üzere, altı evreye ilişkin kovaryans matrislerinin ağırlıklı toplamı olarak tanımlanan genelleştirilmiş kovaryans matrisi (C) Denklem (5.3) kullanılarak hesaplanır:

$$C = \sum_{i=1}^6 p_i C_i \quad (5.3)$$

Denklem (5.3)'te bütün uyku evrelerine ait daha önce hesaplanmış kovaryans matrisleri ve bunların önsel olasılıkları kullanılarak genelleştirilmiş bir kovaryans matrisi hesaplanır. Bu matris bütün uyku evrelerinin kovaryans matrislerinin ağırlıklı bir toplamı olduğundan bütün uyku evrelerinin özelliklerini yansıtmaktadır. Hesaplanan genelleştirilmiş kovaryans matrisinin özdeğer ve özvektörleri hesaplanır. Genliği en büyük iki özdeğere karşılık gelen özvektörler ya da temel bileşenler q_1, q_2 ile belirtilsin. Verilen bir özellik vektörü x 'i iki boyutlu temel bileşenler uzayında bir nokta olarak temsil etmek için özellik vektörü q_1 ve q_2 üzerine

$$p_1 = \langle x, q_1 \rangle = x^T q_1 \quad (5.4)$$


$$p_2 = \langle x, q_2 \rangle = x^T q_2 \quad (5.5)$$

denklemleri kullanılarak izdüşürülür. İzdüşüm değerleri, özellik vektörünün en önemli iki temel bileşen yönündeki enerjisinin şiddetini belirtmektedir. İki boyutlu temel bileşen uzayında q_1 yatay eksen ve q_2 düşey eksen belirtmek üzere, $[p_1, p_2]^T$ ile verilen bir noktaya karşılık geleceğinden, bir özellik vektörü bir nokta ile temsil edilmiş olacaktır.

Bir uyku evresinin kovaryans matrisi bu sınıfa ait özellik vektörlerinin sınıfın ortalama özellik vektörü etrafındaki savrukluğunu belirlerken genelleştirilmiş kovaryans matrisi farklı uyku evreleri arasındaki savrukluğu belirlemektedir. Sınıflandırmada kullanılan özellik vektörü uyku evrelerini ayırt edebilen bir özellik vektörü ise bir uyku evresinin savrukluğu küçük iken farklı uyku evrelerine karşılık gelen savrukluğunun kesişimi mümkün olduğunca küçük olmalıdır.

5.3. Kernel Tabanlı Temel Bileşen Analizi

Kernel tabanlı temel bileşen analizi, doğrusal olarak ayrıştırılamayan özellikleri doğrusal olarak ayrıştırılabilir hale getirmek için geliştirilmiş bir yöntemdir. Yöntemin arkasındaki temel fikir uygun bir kernel fonksiyonu seçmek ve özellik vektörlerini daha fazla boyutlu vektörlere dönüştürmektir [84, 85]. PCA ve kernel PCA temel fikirleri Şekil 5.2’de görülmektedir. Kernel PCA yöntemi aşağıda kısaca tanıtılacaktır.



Şekil 5.2. PCA ve kernel PCA temel fikirleri

$k=1, 2, \dots, M$ ve $x_k \in \mathbb{R}^N$ olmak üzere ortalama değeri sıfır olan M adet x_k gözlemi verilsin, yani $\sum_{k=1}^M x_k = 0$. İlk önce PCA'nın bir özetini vermek iki yöntemin farkını anlamayı kolaylaştıracaktır. PCA yönteminde ilk adımda

$$C = \frac{1}{M} \sum_{j=1}^M x_j x_j^T \quad (5.6)$$

eşitliği kullanılarak kovaryans matrisi oluşturulur. İkinci adımda C 'nin özdeğerleri $\lambda \geq 0$ ve bu özdeğerlere karşılık gelen özvektörler $v \in \mathbb{R}^N \setminus \{0\}$, Denklem (5.7) kullanılarak tespit edilir:

$$\lambda v = Cv \quad (5.7)$$

Denklem (5.7)'nin sağ tarafında gözüken C için Denklem (5.6) kullanılırsa,

$$Cv = \frac{1}{M} \sum_{j=1}^M (x_j \cdot v) x_j^T \text{ elde edileceğinden Denklem (5.7),}$$

$$\lambda (x_k \cdot v) = (x_k \cdot Cv) \quad k = 1, 2, \dots, M \quad (5.8)$$

olarak yeniden düzenlenebilir. Denklem (5.8)'deki $(x \cdot y)$ notasyonu vektör iç çarpımını, (yani $x^T y$) belirtmektedir.

Yukarıda verilen açıklamalar PCA yöntemini kısa bir özetini içermektedir. Aşağıda özetlenecek kernel PCA yönteminde, kernel fonksiyonları aracılığıyla, özellik vektörlerini daha fazla boyutlu vektörlere dönüştürmeden tüm hesaplamaları orijinal özellik uzayında gerçekleştirmek mümkün olmaktadır. O halde, verilen bir özellik vektörünün bir nokta olarak temsil edilmesi için, eğitim amacıyla kullanılacak veriden bir kez hesaplanacak genelleştirilmiş kovaryans matrisinin özdeğer ve özvektörlerinin hesaplanması yeterlidir.

N - boyutlu özellik uzayı \mathbb{R}^N 'den, daha yüksek boyutlu bir F uzayına tanımlanmış Denklem (5.9)'da verilen bir Φ fonksiyonu ele alalım:

$$\begin{aligned}\Phi : \mathbb{R}^N &\rightarrow F, \\ x &\mapsto X\end{aligned}\tag{5.9}$$

F özellik uzayı keyfi olarak çok büyük boyutludur. Bundan sonraki tartışmamızda, büyük harfler F özellik uzayı elemanlarını, küçük harfler \mathbb{R}^N uzayı elemanlarını gösterecektir.

Temel bileşen analizinde olduğu gibi verilerin ortalama değerinin sıfır olduğu varsayılacaktır. Bu varsayımın geçerli olmadığı durumlarda hesaplamaların nasıl yapılacağı Kısım 5.3.1’de tartışılmıştır. Orijinal özellik uzayındaki bir χ_j vektörü, F uzayında $\Phi(\chi_j)$ vektörüne dönüştürüldüğünden, F- uzayında kovaryans matrisini hesaplamak için Denklem (5.10) kullanılabilir:

$$\bar{C} = \frac{1}{M} \sum_{j=1}^M \Phi(\chi_j) \Phi(\chi_j)^T\tag{5.10}$$

PCA yönteminde olduğu gibi, \bar{C} ’nin özdeğerleri $\lambda \geq 0$ ve bu özdeğerlere karşılık gelen özvektörler $V \in F \setminus \{0\}$

$$\lambda V = \bar{C} V\tag{5.11}$$

eşitliği kullanılarak hesaplanır. Özvektörler $\Phi(\chi_1)$, $\Phi(\chi_2)$, ..., $\Phi(\chi_M)$ ’nin doğrusal kombinasyonu olmalıdır. Bu gözlemin iki önemli sonucu vardır. Birincisi Denklem (5.11)’in her iki tarafı $\Phi(\chi_k)$ $k = 1, 2, \dots, M$ ile çarpılırsa Denklem (5.12)’de verilen eşitlik elde edilir.

$$\lambda(\Phi(\chi_k) \cdot V) = (\Phi(\chi_k) \cdot \bar{C} V) \quad k = 1, 2, \dots, M\tag{5.12}$$

İkincisi, Denklem (5.13)’ü sağlayan α_i ($i=1, 2, \dots, M$) katsayıları vardır.

$$V = \sum_{i=1}^M \alpha_i \Phi(\chi_i). \quad (5.13)$$

Denklem (5.12)'de verilen V için, Denklem (5.13) kullanılırsa, $k = 1, 2, \dots, M$ için denklem (5.14) elde edilir.

$$\lambda \cdot \sum_{i=1}^M \alpha_i (\Phi(\chi_k) \cdot \Phi(\chi_i)) = \frac{1}{M} \sum_{i=1}^M \alpha_i (\Phi(\chi_k) \cdot \sum_{j=1}^M \Phi(\chi_j)) (\Phi(\chi_j) \cdot \Phi(\chi_i)) \quad (5.14)$$

eşitliği elde edilir. $M \times M$ boyutunda, elemanları F - uzayındaki vektörlerin iç çarpımı olan K matrisi elemanları

$$K_{ij} := (\Phi(\chi_i)) \cdot (\Phi(\chi_j)), \quad (5.15)$$

olarak tanımlansın. Ayrıca α sütun vektörünü $\alpha = [\alpha_1 \ \alpha_2 \ \dots \ \alpha_M]^T$ olarak tanımlansın. K matrisi ve α vektörü kullanılarak Denklem (5.14)

$$M\lambda K\alpha = K^2\alpha \quad (5.16)$$

şeklinde vektör – matris notasyonunda yazılabilir. K simetrik bir matris olduğundan, bütün uzayı geren bir özvektör kümesine sahiptir. O halde

$$M\lambda\alpha = K\alpha \quad (5.17)$$

eşitliği Denklem (5.16)'nın bütün α çözümlerini verir. K yarı kesin pozitif bir matristir. Bunu doğrulamak için K 'nın

$$(\Phi(\chi_1), \dots, \Phi(\chi_M))^T \cdot (\Phi(\chi_1), \dots, \Phi(\chi_M)), \quad (5.18)$$

ile verilen iç çarpımına eşit olduğuna dikkat ediniz. Denklem (5.19), tüm $X \in F$ için

$$(X \cdot KX) = \|(\Phi(\chi_1), \dots, \Phi(\chi_M))X\|^2 \geq 0. \quad (5.19)$$

Eşitsizliğin sağlanması gerektiğini belirtir.

Sonuç olarak, K matrisinin özdeğerleri sıfıra eşit veya daha büyük olacaktır ve Denklem (5.16)'nın çözümlerini verecektir. O halde sadece K matrisini köşegenleştirmeliyiz. $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_M$ özdeğerleri ve $\alpha^1, \alpha^2, \dots, \alpha^M$ özdeğerlere karşılık gelen özvektörler kümesini ve λ_p ($1 \leq p \leq M$) sıfırdan farklı ilk özdeğeri belirtsin. F uzayında karşılık gelen vektörler normalleştirilecek şekilde $\alpha^p, \dots, \alpha^M$ vektörlerini de normalleştiririz. Yani,

$$(V^k \cdot V^k) = 1 \quad k = p, \dots, M \quad (5.20)$$

Denklem (5.13) ve Denklem (5.17)'yi kullanarak Denklem (5.20)'de verilen normalleştirme koşulunu, $\alpha^p, \dots, \alpha^M$ vektörleri cinsinden

$$\begin{aligned} 1 &= \sum_{i,j=1}^M \alpha_i^k \alpha_j^k (\Phi(\chi_i) \cdot \Phi(\chi_j)) \\ &= \sum_{i,j=1}^M \alpha_i^k \alpha_j^k K_{ij} \\ &= (\alpha^k \cdot K \alpha^k) \\ &= \lambda_k (\alpha^k \cdot \alpha^k) \end{aligned} \quad (5.21)$$

şeklinde yeniden düzenleyebiliriz. Temel bileşen çıkartımı için, F uzayında V^k ($k = p, \dots, M$) özvektörleri üzerine izdüşümlerin hesaplanması gerekir. x , F -uzayındaki karşılığı $\Phi(\chi)$ olan bir test noktası olsun. O halde, Denklem (5.22) ile verilen ifade, test noktasının Φ 'ye karşılık gelen doğrusal olmayan temel bileşenleri olarak adlandırılabilir:

$$(\mathbf{V}^k \cdot \Phi(\chi)) = \sum_{i=1}^M \alpha_j^k (\Phi(\chi_i) \cdot \Phi(\chi)) \quad (5.22)$$

Özet olarak, temel bileşenleri hesaplamak için aşağıdaki adımlar gereklidir: ilk önce, Denklem (5.15) ile tanımlanan iç çarpım matrisi \mathbf{K} 'yi hesapla, daha sonra, \mathbf{K} 'nın özvektörlerini hesapla ve bunları F uzayında normalleştir, son olarak, Denklem (5.22)'yi kullanarak bir test noktasının özvektörler üzerindeki izdüşümlerini hesapla.

Basitlik olması açısından, yukarıdaki işlemlerde gözlemlerin ortalama değerinin sıfır olduğu varsayılmıştır. Gözlemlerin (özellik vektörlerinin) ortalama değerini sıfır yapmak orijinal giriş uzayında kolaydır, ancak F uzayındaki vektörlere sahip olmadığımızdan, bu işlemi F - uzayında yapmak zordur. Bununla birlikte, bu işlemi gerçekleştirmek için bir yöntem sonraki kısımda açıklanmıştır.

5.3.1. Çok boyutlu uzayda vektörlerin ortalamasının sıfır yapılması

Kısım 5.3'te, F uzayındaki verilerin ortalamasının sıfır, yani

$$\sum_{n=1}^M \Phi(\chi_n) = 0 \quad (5.23)$$

olduğu varsayılmıştır. Şimdi bu varsayımı ortadan kaldıracağız. İlk olarak verilen herhangi bir Φ ve x_1, x_2, \dots, x_M gözlemleri için,

$$\bar{\Phi}(\chi_i) := \Phi(\chi_i) - \frac{1}{M} \sum_{i=1}^M \Phi(\chi_i) \quad (5.24)$$

ile verilen noktaların sıfır ortalama değere sahip olacağına dikkat ediniz. Ancak Denklem (5.24)'te verilen vektörlere sahip olmadığımızdan bunlardan yola çıkarak kovaryans matrisi hesaplayamayız. Bu nedenle, F uzayında $\bar{\mathbf{K}} = \bar{\Phi}(\chi_i)^T \bar{\Phi}(\chi_j)$

ile tanımlanan iç çarpım matrisinin bir şekilde Kısım 5.3'te tanımlanan K matrisi cinsinden hesaplanması gerekmektedir. Burada da amacımız \bar{K} matrisinin

$$\bar{\lambda}\bar{\alpha} = \bar{K}\bar{\alpha} \quad (5.25)$$

ile verilen özdeğer ($\bar{\lambda}$) ve özvektörleri ($\bar{\alpha}$) hesaplamaktır. $\bar{\alpha}$, F uzayındaki bir özvektörün

$$\bar{V} = \sum_{i=1}^M \bar{\alpha}_i \bar{\Phi}(\chi_i) \quad (5.26)$$

ile verilen açılım katsayılarıdır.

Aşağıdaki tartışmada $K(\chi_i, \chi_j) = \Phi(\chi_i)^T \Phi(\chi_j)$ olarak kullanılacak, buna ek olarak tüm i ve j için $1_{ij} = 1$ notasyonu kullanılacaktır. İlk olarak, \bar{K}_{ij} 'nin aşağıdaki gibi yazılabileceğine dikkat ediniz:

$$\begin{aligned} \bar{K}_{ij} &= \bar{\Phi}(\chi_i)^T \bar{\Phi}(\chi_j) = (\Phi(\chi_i) - \sum_{m=1}^M \Phi(\chi_m))^T (\Phi(\chi_j) - \sum_{n=1}^M \Phi(\chi_n)) \\ &= \Phi(\chi_i)^T \Phi(\chi_j) - \frac{1}{M} \sum_{m=1}^M \Phi(\chi_m)^T \Phi(\chi_j) - \frac{1}{M} \sum_{n=1}^M \Phi(\chi_i)^T \Phi(\chi_n) + \frac{1}{M^2} \sum_{m,n=1}^M \Phi(\chi_m)^T \Phi(\chi_n) \\ &= K_{ij} - \frac{1}{M} \sum_{m=1}^M 1_{im} K_{mj} - \sum_{n=1}^M K_{in} 1_{nj} + \frac{1}{M^2} \sum_{m,n=1}^M 1_{im} K_{mn} 1_{nj} \end{aligned} \quad (5.27)$$

$(1_M)_{ij} := 1/M$ matrisi kullanılarak Denklem (5.28)'deki kısa ifade elde edilir:

$$\bar{K}_{ij} = K - 1_M K - K 1_M + 1_M K 1_M \quad (5.28)$$

Böylece, K matrisinden \bar{K} matrisi hesaplanabilir ve Denklem (5.25)'deki özvektör problemi çözülebilir. Denklem (5.21)'deki gibi, F uzayında karşılık gelen \bar{V}^k vektörler normalleştirilerek $\bar{\alpha}^k$ çözümleri normalleştirilir. Bu normalleştirme koşulu

$$\bar{\lambda}_k (\bar{\alpha}^k \cdot \bar{\alpha}^k) = 1 \quad (5.29)$$

eşitliğine eşdeğerdir. Özellik çıkartımı için, t test vektörlerinin Φ fonksiyonu altında dönüştüğü, ortalama değeri sıfırlanmış vektörlerin \bar{K} matrisinin özvektörleri üzerine izdüşümünü hesaplarız:

$$\begin{aligned} (\bar{V} \cdot \Phi(t)) &= \sum_{i=1}^M \bar{\alpha}_j^k (\bar{\Phi}(\chi_k) \cdot \bar{\Phi}(t)) \\ &= \sum_{i=1}^M \bar{\alpha}_j^k \bar{K}(\chi_k, t) \end{aligned} \quad (5.30)$$

t_1, t_2, \dots, t_L ile verilen test vektörleri kümesini ele alalım ve Denklem (5.31) ve Denklem (5.32) ile tanımlanan $L \times M$ boyutunda iki iç çarpım matrisi $\bar{K}_{ij}^{\text{test}}$ ve K_{ij}^{test} tanımlayalım:

$$K_{ij}^{\text{test}} = (\Phi(t_i) \cdot \Phi(\chi_j)) \quad (5.31)$$

$$\bar{K}_{ij}^{\text{test}} = \left(\left(\Phi(t_i) - \frac{1}{M} \sum_{m=1}^M \Phi(\chi_m) \right) \cdot \left(\Phi(\chi_j) - \frac{1}{M} \sum_{n=1}^M \Phi(\chi_n) \right) \right) \quad (5.32)$$

Denklem (5.28)'e benzer olarak, \bar{K}^{test} matrisini K^{test} matrisi cinsinden ifade edebilir

$$\bar{K}^{\text{test}} = \bar{K}^{\text{test}} - 1'_M K - \bar{K}^{\text{test}} 1_M + 1'_M K 1_M \quad (5.33)$$

sonucunu buluruz. Denklem (5.33)'te $1_M'$ notasyonu bütün elemanları $1/M$ 'ye eşit olan $L \times M$ boyutunda bir matristir.

5.3.2. Kernel fonksiyonları

Kernel fonksiyonları [86] olarak kullanılabilen fonksiyonlar polinomik kerneller, radyal taban fonksiyonları ve sinir ağı türü kerneller olup bunlar sırasıyla Denklem (5.34), (5.35) ve (5.36)'da verilmiştir.

$$k(x,y) = (x.y+1)^d \quad (5.34)$$

$$k(x,y) = \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right) \quad (5.35)$$

$$k(x,y) = \tanh((x.y)+b) \quad (5.36)$$

Bu üç tip kernel fonksiyonu, birbirine yakın performansa sahip polinomik sınıflandırıcı, radyal taban fonksiyonu sınıflandırıcı ve destek vektör algoritmaları sinir ağlarının oluşturulmasına imkan verir. Ek olarak, bu fonksiyonların hepsi karar fonksiyonlarını destek vektörler [87] olarak adlandırılan eğitim verisinin az sayıda elemanından oluşan bir alt kümesinden oluşturur.

Yukarıda verilen kernellerin yanında, doğrusal olmayan problem tiplerine uydurmak için kullanılabilen değişik kernel fonksiyonları mevcuttur. Meraklı okuyucu detayları [84]'de bulabilir.

5.4. Olasılıksal Sinir Ağları

PCA veya kernel PCA yöntemiyle elde edilen özellik vektörlerinin uyku evrelerini sınıflandırma başarısını belirlemek amacıyla bu çalışmada olasılıksal sinir ağları (probabilistic Neural Networks, PNN) kullanılmıştır. Olasılıksal sinir ağlarının diğer sinir ağları türüne tercih edilmesinin nedeni aşağıda detaylı olarak açıklanmıştır. Sınıflandırma amacıyla sinir ağlarından başka yöntemlerde mevcuttur. Ancak

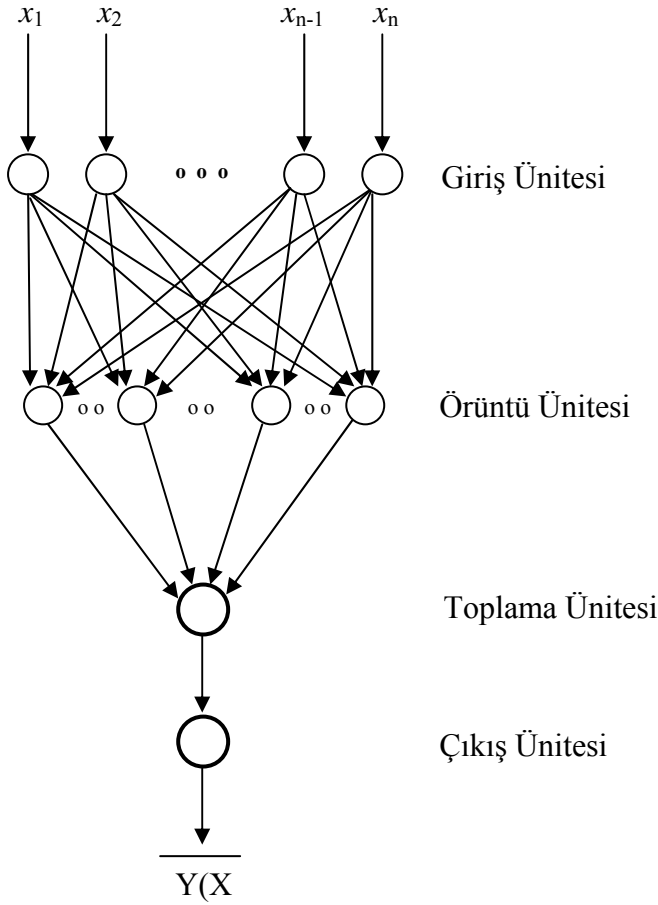
çalışmanın amacı EEG işaretlerinden hesaplanan parametrelerden oluşan özellik vektörlerinin iki boyutlu uzayda nasıl kümelendiklerini gösteren yöntemler geliştirmektir. Böyle bir yöntem, sınıflandırma adımını gerçekleştirmeden seçilen özelliklerin uyku evrelerini ne ölçüde ayrıştırabildiği hakkında ön bilgi verecektir. Asıl amaç, sınıflandırma olmadığından sadece bir sınıflandırıcı kullanılmıştır.

Cherkassky, Friedman and Wechsler'in [88, 89]'de güzel bir üslupla ifade ettiği gibi, algoritmaları veya analitik fonksiyonları tasarlarken farklı altyapı ve farklı amaçlara sahip oldukları için sinir ağları araştırmacıları ve istatistikçiler arasında bölünmüşlük vardır. Olasılıksal yöntemler verinin yapısı üzerine bina edilirken sinir ağları yöntemleri için verinin yapısı ikinci plandadır. Bu nedenle, olasılıksal yöntemler için ihtiyaç duyulan verilerin miktarı yapay sinir ağları yaklaşımı için duyulan verilerin miktarından oldukça azdır. Çoğu sinir ağı yöntemi yaklaşık olarak iyidir [88], ancak bunların büyük çoğunluğunun ciddi eksikliği vardır. Örneğin, geriyayılımlı sinir ağları (GYSA) oldukça fazla sayıda eğitim örneklerine ve ağırlık değerlerine kademeli olarak yaklaşmak için uzun zamana ihtiyaç duyar. Yeni bir bilgi eklenmesi, eğitim adımının yeniden yapılmasını gerektirir. Hesap yükü açısından oldukça maliyetli olan GYSA'ya karşın olasılıksal sinir ağlarının hesap yükü fazla değildir. PNN tahmin algoritmasının sadece birkaç eğitim örneği ile çalışması gibi büyük bir özelliğe sahiptir. Diğer büyük bir üstünlük ise, çok esnek olmaları ve yeni bilgilerin eğitim adımının neredeyse tekrarlanmadan eklenebilmesidir.

PNN, eğitim için ayrılan örneklerden öğrenmeye dayalı örüntü sınıflandırmada sıkça kullanılan bir sınıflandırma yöntemidir. PNN, örüntü sınıflandırma yaparken, parametrik olmayan bir teknik olarak bilinen Parzen pencerelerini kullanan Bayes ölçütünü kullanır [90, 91]. Bayes Ölçütü hakkında daha geniş bilgi için [89, 91]'e bakılabilir. Farklı kurallar, öğrenme örneklerinden örüntü olasılıklarını hesaplamaya imkan verir.

Diğer yandan GYSA, olasılıksal olmayan yöntemlere dayalıdır. GYSA, kademeli olarak esas fonksiyona yaklaşıma kadar uzun bir zamana, fazla tekrara ve geribeslemeye ihtiyaç duyar [92]. GYSA, sonuçta istenen parametrelere belli bir değerde yaklaşıma kadar işlemin tekrarlanması gerektirir. "Örüntü Sınıflandırma için

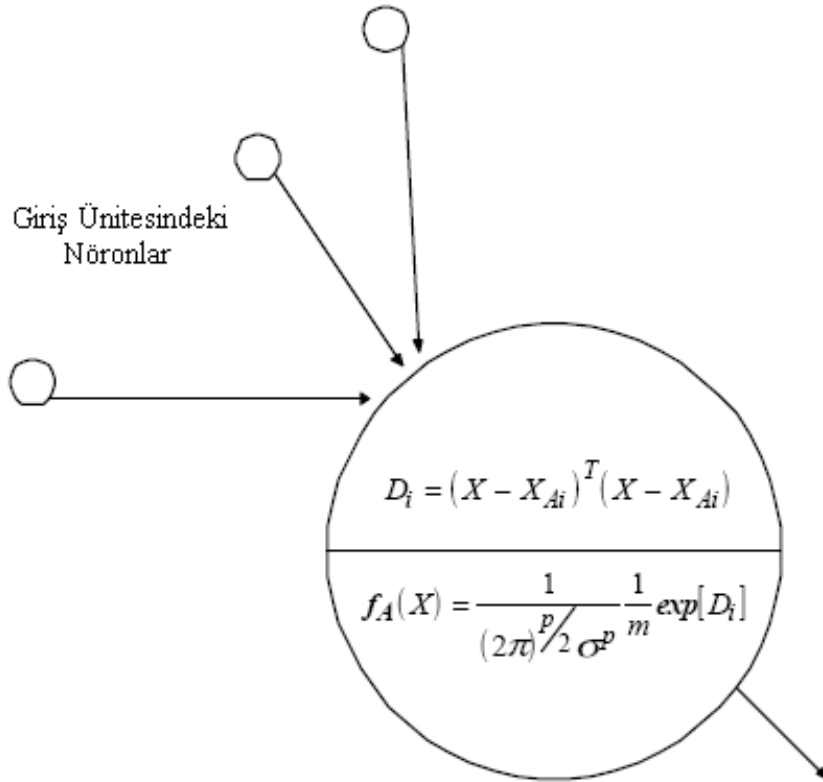
Bayern Stratejisi” karakteristikleri, esas fonksiyon hakkındaki eğitim örneklerinden çıkarılır. PNN çok fazla ilave giriş gerektirmez ancak sonuçları yorumlanabilir değildir. PNN, oldukça basit bir yapıya ve dolayısıyla oldukça kararlı işlemlere sahiptir. PNN, sadece birkaç eğitim örneğinin mevcut olmasında bile iyi çalışır ve eğitim örnekleri arttıkça sınıflandırma performansı artar. Bir olasılıksal sinir ağının genel yapısı Şekil 5.3’te verilmiştir.




Şekil 5.3. Bir olasılıksal sinir ağı blok diagramı

Olasılıksal sinir ağlarının genel yapısı GYSA'nın yapısı ile aynıdır. Bir PNN bir giriş katmanı, iki gizli katman ve bir çıkış katmanından oluşur. Hatanın geriye yayılım algoritmasıyla en küçük yapıldığı ileri beslemeli bir ağdan en temel farkı, olasılıksal sinir ağının eğitim setini sadece eğitim adımında kullanmasıdır [93]. İlk gizli tabaka örüntü birimlerini içerir. Örüntü birimleri önceden tartışılmış olan önemli fonksiyonel birimler içerir. Örüntü birimlerindeki hesaplamalar Şekil 5.4'de gösterilmiştir. Her örüntü, bir eğitim örüntüsü üzerindeki bilgiyi gösterir. Her örüntü

birimi, giriş vektörünün örüntü birimini ne kadar iyi tanımlandığının veya örüntü birimine ne kadar uygun olduğunun olasılığını hesaplar. İkinci gizli tabakada, sadece birinci gizli tabakadaki birimlerin toplamı vardır. Bu aşamada her giriş vektörünün son olarak sahip olduğu örüntü biriminin bireysel sonuçları hakkında karar verilir. Çıkış birimi, fiziksel anlamı olan bir çıkış üretmek için tekrar uygulanır. Bir olasılıksal sinir ağı için çoklu çıkışlara sahip olmak her zaman mümkün değildir. Bir geriyayılımlı sinir ağı ve olasılıksal sinir ağı arasında varolan bir büyük fark, sinirlerin içerisindeki işlem farkıdır. Bir olasılıksal sinir ağı “Örüntü Sınıflandırma için Bayes Stratejisi” nden sonuçlanan bilgiye dayanan fonksiyonlar kullanır. Böylece, bir olasılıksal sinir ağının etkinliği veriyi en iyi şekilde tanımlayan ağırlıkların seçimi değildir. Bir olasılıksal sinir ağının etkinliğini nöronun içinde kullanılan fonksiyon belirler.




Şekil 5.4. Bir nöronda kullanılan fonksiyonlar [89]



Şekil 5.5. Olasılık yoğunluk fonksiyonu [89]

Bir örüntü biriminin sınırında kullanılan fonksiyon, Şekil 5.5'te gösterildiği gibi bir olasılık yoğunluk fonksiyonudur. Olasılık yoğunluk fonksiyonu meydana gelmesi gereken çıkışı hesaplamaya yönelik tahminin olduğu örnekleme noktası ve Şekil 5.5'te görüldüğü gibi $X_{Ai} - X$ arasındaki pozisyon mesafesine ihtiyaç duyar. Her örüntü biriminin çıkışı, toplama biriminde toplanır ve fiziksel anlamlı bir sonuca çevrilir.

PNN 'nin temelini teşkil eden fikir Parzen pencerelerini kullanarak bilinmeyen şart yoğunluklarını tahmin etmektir. Parzen'in tekniği verilen bir kategorinin her bir eğitim vektörü çevresinde n-boyutlu bir Gauss fonksiyonu merkezlemektir. Verilen kategorinin doğru olasılık yoğunluk fonksiyonlarının bir tahmini olarak bu bireysel gauss servislerinin üstüne konan, ölçekleme (bölüntü) ile ayrılır. n artırımı ile, tahmin edilen olasılık yoğunluk fonksiyon yaklaşımları doğru olasılık yoğunluk fonksiyonunu verir.



Şekil 5.6 Eğitim örneği ve tahmin noktası arası uzaklık [89]

“Sınıflandırma için Bayes Stratejisi” ayrık değerler için kullanılabilceği gibi sürekli değerler içinde geçerlidir [94]. Bundan dolayı bu yöntemle sürekli çıkışları tahmin etmek mümkündür.

Bir test vektörü PNN’ye verildiğinde, kararda güvenilir bir tahmin kadar iyi olan kazanan kategori çıkışı oluşturur. Bu güvenilir tahmin Bayes karar kuralı kullanılarak, tahmin edilen şart yoğunluklarından hesaplanan sonrasal olasılık ile verilir.

BÖLÜM 6. SİMÜLASYON UYGULAMALARI

6.1. Giriş

Çalışmada kullanılan EEG işaretleri uluslararası veritabanı PhysioNet uyku kayıtlarından elde edilmiştir. [85]. 21 – 35 yaş arası kişilerden alınmış veriler test edilmiştir. Veritabanını oluşturan uyku kayıtları iki dosyadan oluşmaktadır. Uzantısı *edf* olan dosya, iki EEG (Fpz-Cz ve Pz-Oz), bir EOG, bir EMG, bir solunum kanalı, bir vücut sıcaklığı kanalı ve motor aktivite kanalı içermektedir. EEG ve EOG işaretlerinin örnekleme frekansı 100Hz; EMG ve diğer verilerin örnekleme frekansı 1Hz'dir. Uyku kayıtları 30sn'lik epoklar şeklinde alınmış, kayıt süresi 24 saattir. Uzantısı *hyp* olan ikinci dosya ise uzmanlar tarafından derlenen Rechtschaffen ve Kales (R&K) hipnogramını içermektedir. Hipnogram sınıflandırma sonuçlarının grafiksel sunumu için çizilir. Bu dosya, kişinin 24 saatlik uyku kaydının sınıflandırılmış uyku evrelerini toplu halde görmemizi sağlar. Hipnogramda 0, 1, 2, 3, 4, 5 rakamları kullanılmakta ve bu rakamlar sırasıyla Uyanık, Evre 1, Evre 2, Evre 3, Evre 4 ve REM evresine karşılık gelmektedir. Ayrıca Hipnogram kaydında 6 ve 9 rakamı kullanılmakta bunlar da sırasıyla hareket zamanı ve sınıflandırılmayan evreleri göstermektedir.

Zaman-uzayı özellik vektörleri Bölüm 4'te tanımlanan bir EEG işaretinin ortalama değer, standart sapma ve Hjorth parametrelerinden oluşan 5x1 boyutunda vektörlerdir. Frekans-uzayı özellik vektörleri ise yine Bölüm 4'te tanımlanan bağlı enerji yoğunlukları, merkez frekansı, band genişliği ve merkez frekansındaki güç ve spektral kenar frekansından oluşan 10x1 boyutunda vektörlerdir. Dolayısıyla zaman ve frekans-uzayı (hibrit) özellik vektörlerinin boyutu 15x1 olacaktır.

EEG işaretlerinde gürültü gibi istenmeyen bozunumları yok etmek için örneklenmiş EEG işaretlerinden özellik vektörleri hesaplanmadan önce işaretler geçirme bandı

0.5Hz - 45Hz olan 6. dereceden sayısal Butterworth band geçiren bir filtreden geçirilmiştir. Daha sonra frekans uzayı özelliklerini hesaplamak için gerekli olan güç spektrumunu hesaplamak için 9. dereceden bir Yule-Walker algoritması kullanılmıştır. Elde edilen Uyku evrelerinin ortalama özellik vektörü ve kovaryans matrislerinin hesaplanmasında ve özellik vektörlerinin uyku evrelerini ayırıştırma yeteneğini test etmek amacıyla hangi evreden kaç adet özellik vektörü kullanıldığı Tablo 6.1’de verilmiştir.

Tablo 6.1. Eğitim ve test amacıyla kullanılan özellik vektörleri sayıları

	Uyanık	REM	Evre 1	Evre 2	Evre 3	Evre 4
Eğitim	60	40	15	70	20	40
Test	240	160	40	280	70	160
Toplam	300	200	55	350	90	200

Bölüm 5.’te geniş bir şekilde anlatıldığı üzere genelleştirilmiş kovaryans matrisinin en büyük iki özdeğerine karşılık gelen özvektörleri eğitim için belirlenen veri setinden bir defaya mahsus hesaplanır. Test için ayrılan veri kümesindeki özellik vektörleri hesaplanan bu özvektörlerin üzerine izdüşürülerek elde edilen iki değer uzayda bir nokta ile gösterilir. Aynı evreye ait izdüşüm değerleri bir araya kümelenirken farklı evrelere ait izdüşüm değerleri farklı bölgelerde kümелendiği görülür. Bu işlem her bir veri kümesi (zaman-uzayı, frekans-uzayı ve hibrit) için ayrı yapılır.

Simulasyonlar üç aşamadan oluşmaktadır. Birinci çalışma zaman-uzayı, frekans-uzayı ve hibrit özellik vektörlerinin kümelenmelerinin temel bileşen analizi ile tespit edilmesi, ikinci çalışma yeni veriler üzerinde temel bileşen analizi ve kernel tabanlı temel bileşen analizi ile verilerin kümelenmelerinin incelenmesi, üçüncü çalışma olarak olasılıksal sinir ağları vasıtasıyla sınıflandırma yaparak kümelenmelerin doğruluklarının ve literatürle uyumunun araştırılması.

Birinci çalışmada temel bileşen analizinin eğitimi ve testi için Tablo 6.1’de görüldüğü gibi farklı sayılarda uyku evresi örneği alınarak zaman-uzayı, fekans-uzayı ve hibrit özellik vektörlerinin ayrışması incelendi. Ancak kernel tabanlı temel bileşen analizinde yüksek boyutlu bir uzay söz konusu olduğundan her evrenin önsel

olasılıklarının eklenmesi ilave hesap gerektirdiğinden uyku evre örnekleri aynı sayıda alınmıştır. Karşılaştırmanın kolay yapılması açısından temel bileşen analizi, kernel tabanlı temel bileşen analizi ve olasılıksal sinir ağları bu eşit sayıdaki uyku evreleri örnekleri ile simülasyonlar yeniden yapılmıştır. Simülasyonlarda daha iyi sonuç verdiği için sadece hibrit özellik vektörleri değerlendirilmiştir. Tablo 6.2’de kullanılan yeni özellik vektörleri sayıları verilmiştir.


Tablo 6.2. Eğitim ve test amacıyla kullanılan özellik vektörleri yeni sayıları

	Uyanık	REM	Evre 1	Evre 2	Evre 3	Evre 4
Eğitim	25	25	25	25	25	25
Test	50	50	50	50	50	50
Toplam	75	75	75	75	75	75


6.2. Temel Bileşen Analizi Simülasyon Sonuçları

6.2.1. Zaman-uzayı özellikleri simülasyon sonuçları

Zaman-uzayı özellik vektörlerinin uyku evrelerini ayırıştırma yeteneği Şekil 6.1 ve Şekil 6.2’te verilmiştir. Yorumlamanın kolay olması açısından şekillerde üç evreye ilişkin kümelenmeler gösterilmiştir. Şekil 6.2 REM ve Uyanık evrelerine karşılık gelen izdüşüm değerlerinin oldukça iyi bir şekilde ayrıştığını gösterirken Evre 2’ye karşılık gelen izdüşüm değerlerinin REM ve Uyanık evreleri ile az da olsa karıştığını göstermektedir. Şekil 6.1’de Evre 2 ve Evre 4 evrelerine karşılık gelen izdüşüm değerlerinin gayet iyi ayrışmasına karşılık Evre 3’e ait izdüşüm değerlerinin hem Evre 2 hem de Evre 4 ile karıştığını görülmektedir. Dolayısıyla, bu özellik vektörleri kullanılarak sınıflandırma yapılması durumunda sınıflandırıcının başarısının Evre 2, Evre 3 ve Evre 4 için sınıflandırma yapıldığında Evre 2 ve Evre 4’ü karıştırmayacağı fakat Evre 3’ü Evre 2 veya Evre 4 ile karıştıracığı yani sınıflandırmanın iyi olmayacaktır. Aynı zamanda REM ve Uyanık evreleri için sınıflandırma sonucunun çok iyi olacağı söylenebilir. Literatürde yapılmış çalışmalarda yalnız zaman-uzayı özellik vektörleri kullanılmamıştır, zaman-uzayı özellik vektörleri frekans-uzayı özellik vektörleri ile birlikte (hibrit özellik) kullanılmışlardır. Bu yüzden bu özelliklerin yalnız başlarına dağılımı üzerinde fazla durulmamıştır. Bu çalışmada ilgi daha çok frekans-uzayı özellikleri ve hibrit özellikler üzerinde olmuştur.




Şekil 6.1. Zaman-uzayı özelliklerinin uyku evrelerini ayırma yeteneği (birbirine karışan evreler)



Şekil 6.2. Zaman-uzayı özelliklerinin uyku evrelerini ayırma yeteneği (nispeten ayrılan evreler)


6.2.2. Frekans-uzayı özellikleri simülasyon sonuçları

Frekans-uzayı özellik vektörlerinin kullanılması durumunda uyku evrelerinin ne oranda ayrıştığı Şekil 6.3 ile Şekil 6.6 arasındaki grafiklerde gösterilmiştir. Şekil 6.3'te görüldüğü gibi Evre 2 ile Evre 4 birbiriyle yeterince ayrışırken Evre 3 bu evrelerin ikisi ile de karışmaktadır.




Şekil 6.3. Frekans-uzayı özelliklerinin uyku evrelerini ayırma yeteneği (birbirine karışan evreler)

Şekil 6.4'te Evre 2, REM Evresi ve Uyanık evrelerinden elde edilen izdüşüm değerleri farklı bölgelerde kümelenmesine rağmen birbirinin içine giren kısımlarının çok olduğu görülmektedir.

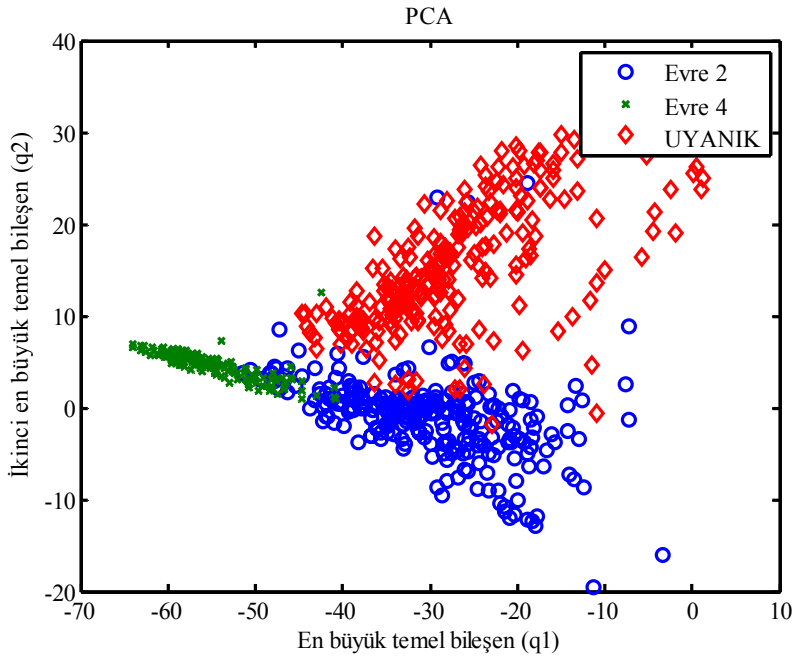


Şekil 6.4. Frekans-uzayı özelliklerinin uyku evrelerini ayırma yeteneği (birbirine karışan evreler) Evre 3, Evre 4 ve REM evrelerinden elde edilen özellik vektörlerinin izdüşüm değerleri Şekil 6.5’de gösterilmiştir. Evre 3 ve Evre 4’ten oluşturulan izdüşüm değerleri literatürle uyumlu olarak birbiri ile karışırken REM evresi onlardan oldukça iyi ayrılmaktadır.



Şekil 6.5. Frekans-uzayı özelliklerinin uyku evrelerini ayırma yeteneği (birbiri ile ayrılan evreler)

Evre 2, Evre 4 ve uyanık evrelerinin özellik vektörlerinden oluşturulan izdüşüm değerleri Şekil 6.6'de verilmiştir. Şekilden de görüldüğü gibi evreler arasında az sayıda birbirinin içine giren izdüşüm değerleri olmasına rağmen yeterince ayrıştıkları söylenebilir.




Şekil 6.6. Frekans-uzayı özelliklerinin uyku evrelerini ayrıştırma yeteneği (birbiri ile ayrışan evreler)


Frekans-uzayı özelliklerinin kullanılmasıyla yapılan simülasyon sonuçları incelendiğinde elde edilen sonuçların uyku evrelerinin sınıflandırılması ile ilgili çalışmalar oldukça uyumlu olduğu gözlemlenmektedir. Bununla beraber zaman-uzayı özellik vektörlerini içeren Şekil 6.1 ve frekans-uzayı özellik vektörlerini içeren Şekil 6.6 birbirleriyle karşılaştırıldığında frekans-uzayı özellik vektörlerinin zaman-uzayı özellik vektörlerine göre izdüşüm değerlerini iki boyutlu özellik uzayında daha dar bir bölgeye kümelediği gözlemlenmektedir. Diğer bir ifadeyle, yalnız frekans-uzayı özellik vektörleri kullanıldığında elde edilecek sınıflandırma başarısının yalnız zaman-uzayı özellik vektörleri durumundaki sınıflandırma başarısından daha iyi olacağı söylenebilir. Uyku evrelerinin sınıflandırma ile ilgili çalışmalarını incelendiğinde elde edilen bu sonuçların da doğru olduğu ve ayrıştırmanın kabul edilebilir seviyede olduğu görülür.

6.2.3. Hibrit özellik özellikleri simülasyon sonuçları

Son olarak Şekil 6.7 ile Şekil 6.12 arasında hibrit özellik vektörleri kullanıldığı durumda izdüşüm değerlerinden oluşturulan kümelenmeler Evre 1, Evre 2, Evre 3 Evre 4, REM ve Uyanık evreleri için belirtilmiştir. Önceki iki duruma benzer bir şekilde Şekil 6.7’de Evre 1’e ait izdüşüm değerleri Evre 2 ve REM evresiyle oldukça karışmış olduğu görülmektedir. Bununla beraber, Şekil 6.8’da gösterilen Evre 2, Uyanık ve REM evrelerine ilişkin kümelenmeler farklı olmalarına rağmen birbirinin içine giren kısımlar olduğu gözlenmektedir. Diğer bir ifadeyle bu özellik vektörlerini kullanarak Evre 2, Uyanık ve REM evrelerini yüksek doğrulukta sınıflandırmak mümkün olmayacaktır. Bu sonuçlar incelendiğinde hibrit özellik vektörleri ile elde edilen izdüşüm değerlerinin frekans-uzayı özellik vektörlerinin izdüşüm değerlerinden daha dar bir alanda kümelendiği gözlemlenmektedir. Diğer bir ifade ile aynı evrelerden alınan frekans-uzayı özellik vektörlerinin izdüşüm değerleri ile hibrit özellik vektörlerinin izdüşüm değerlerinin grafikleri karşılaştırıldığında hibrit özellik vektörlerinin izdüşüm değerleri daha iyi ayrılmaktadır.




Şekil 6.7. Hibrit özelliklerin uyku evrelerini ayırma yeteneği (birbirine karışan evreler)




Şekil 6.8. Hibrit özelliklerin uyku evrelerini ayırma yeteneği (birbirine karışan evreler)

Şekil 6.9 incelendiğinde Evre 3 ve Evre 4 iç içe geçmesine rağmen REM evresi oldukça ayrılmaktadır. Dolayısıyla yapılacak bir sınıflandırma işleminde bu özellik vektörleri kullanıldığında Evre 3 ve Evre 4 için çok başarılı olmayacak fakat REM evresi için çok başarılı olacaktır.



Şekil 6.9. Hibrit özelliklerin uyku evrelerini ayırma yeteneği (birbiri ile ayrılan evreler)

Şekil 6.10'te görüldüğü gibi Evre 2, Evre 4 ve Uyanık evrelerine ait özellik vektörlerinin izdüşüm değerleri gösterilmiştir. Az sayıda izdüşüm değerinin birbiri içine girmesine rağmen burada evreler oldukça iyi ayrılmış sayılır. Dolayısıyla kullanılacak bir sınıflandırıcının başarısı bu evreler için oldukça yüksek olacaktır.




Şekil 6.10. Hibrit özelliklerin uyku evrelerini ayırma yeteneği (birbiri ile ayrılan evreler)

Yapılan tüm zaman-uzayı, frekans-uzayı ve hibrit özellik vektörlerinden oluşturulan izdüşüm değerlerinin simülasyonları incelendiğinde hibrit özelliklerinin simülasyon sonuçları frekans-uzayı özelliklerinden daha iyi sonuç verdiği gözlenmiştir. Benzer uyku evresine ilişkin simülasyon sonuçlarında hem zaman-uzayı özellik vektörleri hem de frekans-uzayı özellik vektörleri birlikte kullanıldığında daha iyi sonuç verdiği görülmüştür.

6.3. Yeni Veriler ile Temel Bileşen Analizi Simülasyon Sonuçları


Şekil 6.11'de Evre 1, Evre 2 ve REM evresine ilişkin PCA sonuçları verilmiştir. Şekilden de görüldüğü üzere bu evreler birbirleriyle benzer özelliğe sahip olduklarından oldukça karışmış durumdadır. Bu yüzden kullanılacak bir sınıflandırma algoritması bu evreleri karıştıracağı açıktır. Bu özellik vektörlerinin

yanında otomatik sınıflandırma dışında görsel olarak yeniden incelenmesi gerekmektedir.




Şekil 6.11 PCA'nın uyku evrelerini ayırma yeteneği (birbirine karışan evreler)

Şekil 6.12'de Uyanık evresine ait izdüşümler farklı alanda kümelenirken REM ve Evre 2 az sayıda da olsa birbirine karışmaktadır. O halde sınıflandırma esnasında uyanık evresi diğerlerine karışmamalıdır.




Şekil 6.12 PCA'nın uyku evrelerini ayırma yeteneği (nıpeten karışan evreler)

Şekil 6.13'te Evre 3 ve Evre 4 birbirlerine oldukça yakın kümelandiklerinden sınıflandırıcı algoritması bu evreleri karıştırabilecektir. Ancak REM evresi bunlardan oldukça farklı kümelandiğinden sınıflandırıcının bu evreyi Evre3 ve Evre 4 ile karıştırmaması beklenir.



Şekil 6.13 PCA'nın uyku evrelerini ayırma yeteneği (birbirine ayrılan evreler)

Şekil 6.14'te Evre 2, Evre 4 ve Uyanık evreleri birbirleriyle hiç karışmayacaktır.




Şekil 6.14 PCA'nın uyku evrelerini ayırma yeteneği (birbirine ayrılan evreler)

6.4. Yeni Veriler ile Kernel Tabanlı Temel Bileşen Analizi Simülasyonu Sonuçları

6.4.1 Polinomik kernel PCA simülasyonu sonuçları

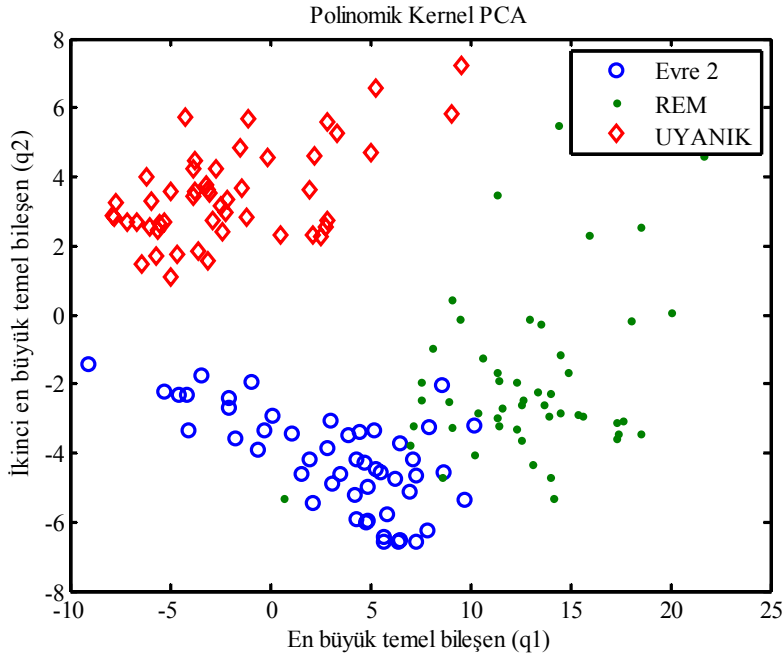
Kernel tabanlı PCA’da kernel fonksiyonu olarak Denklem (5.34) kullanılarak ve kernel parametresi d ’nin çeşitli değerleri için simülasyonlar yapılmıştır. Parametrenin evreleri en uygun ayıran değeri için grafikler gösterilmiştir. PCA ile karşılaştırma yapılması için aynı evreler Polinomik tabanlı Kernel PCA için yeniden çizdirilmiştir.

Şekil 6.15’de Evre 1, Evre 2 ve REM evresi PCA’da olduğu gibi karışmaktadır. Dolayısıyla Polinomik tabanlı Kernel PCA da bu evreler için ayırt edici olmamaktadır. Sınıflandırma algoritmasının bu evreler için başarılı bir sonuç vermemesi beklenmektedir. Sınıflandırma işleminde bu evreler birbirlerinin yerine geçeceği söylenebilir yani Evre 1 olması gereken evre, Evre 2 veya REM olarak sınıflandırılabilir. Bu evreler otomatik skorlanırken dikkatli olmak gerekir.




Şekil 6.15. Polinomik Kernel PCA’nın uyku evrelerini ayırma yeteneği (birbirine karışan evreler)

Şekil 6.16'da Uyanık evresi REM ve Evre 2'den oldukça iyi ayrılmaktadır. REM ve Evre 2 ise az sayıda karışmaktadır.




Şekil 6.16. Polinomik Kernel PCA'nın uyku evrelerini ayırma yeteneği (nispeten ayrılan evreler)

Yukarıdakine benzer bir durum Şekil 6.17'de REM evresi ile Evre 3 ve Evre 4 arasında görülmektedir. Evre 3 ve Evre 4 karışmalarına rağmen REM evresi bunlardan oldukça iyi ayrılmaktadır.



Şekil 6.17. Polinomik Kernel PCA'nın uyku evrelerini ayırma yeteneği (nispeten ayrılan evreler)

Polinomik Kernel tabanlı PCA’da Evre 2, Evre 4 ve Uyanık evreleri Şekil 6.18’de de görüldüğü gibi birbirleriyle hiç karışmamaktadırlar. Evre 4 varyansı çok düşük olduğu görülmektedir. Bu durum Evre 4’ ün sınıflandırılmasında hatanın olmayacağı veya çok küçük bir hatanın olacağını göstermektedir.




Şekil 6.18. Polinomik Kernel PCA’nın uyku evrelerini ayırıştırma yeteneği (birbiri ile ayrılan evreler)

6.4.2. Radyal Kernel PCA simülasyon sonuçları


Kernel tabanlı PCA’da Denklem (5.35) kernel fonksiyonu olarak kullanılacaktır. Kernel parametresi olan σ^2 ’nin çeşitli değerleri için simülasyonlar yapılmıştır. Parametrenin evreleri ayırt edici en uygun değeri için ayıran grafikler çıkarılmıştır. PCA ve Polinomik tabanlı Kernel PCA ile karşılaştırma yapılması için aynı evreler Radyal tabanlı Kernel PCA için yeniden çizdirilmiştir.

Şekil 6.19’de Evre 1, Evre 2 ve REM evresi PCA ve Polinomik Kernel PCA’da olduğu gibi karışmaktadır. Sınıflandırma algoritmasının bu evreler için başarılı bir sonuç vermesi beklenmemektedir. Sınıflandırma işleminde bu evrelerin birbirleri ile karıştırılabileceği öngörülebilir.




Şekil 6.19. Radyal Kernel PCA'nın uyku evrelerini ayırma yeteneği (birbirine karışan evreler)

Şekil 6.20'de Evre 2 ve REM evresi az sayıda da olsa karışmaktadır. Bu evrelerin sınıflandırma esnasında da karışacağı açıktır. Bununla beraber uyanık evresi farklı bölgede kümelenmesine rağmen bu evrelere çok yakın olduğundan sınıflandırmada bir karışma söz konusu olabilir.




Şekil 6.20. Radyal Kernel PCA'nın uyku evrelerini ayırma yeteneği (nispeten ayrılan evreler)

Şekil 6.21’de Evre 3, Evre 4 ve REM evrelerinin aslında bir iki tanesi dışında birbirlerine karışmadığı görülmektedir. Ancak dağılıma bakıldığında birbirlerine çok yakın bir dağılım gösterdiklerinden sınıflandırma karışabilecekleri göz önünde bulundurulmalıdır. Şekil 6.22’de görüldüğü gibi evreler birbirleriyle karışmamaktadırlar. Burada da Evre 2 ve Uyanık evresi birbirlerine çok yakındır. Sınıflandırıcı bu evreleri karıştırabilir.



Şekil 6.21. Radyal Kernel PCA’nın uyku evrelerini ayırma yeteneği (nispeten ayrılan evreler)



Şekil 6.22. Radyal Kernel PCA’nın uyku evrelerini ayırma yeteneği (birbiri ile ayrılan evreler)

6.5. Olasılıksal Sinir Ağları Simülasyon Sonuçları

6.5.1. Hibrit özellikleri PNN simülasyon sonuçları

İlk olarak mevcut verilerin direk zaman ve frekans – uzayı özellik vektörlerinden oluşan hibrit özellikleri giriş olarak kullanılmıştır. Tablo 6.3.’te hibrit özelliklerin kendisi kullanıldığında evrelerin ne oranda ayrıştığı ve hangi evrenin hangi evre ile karıştığı görülmektedir. Simülasyon sonucu incelendiğinde sınıflandırmada oldukça başarılı olduğu söylenebilir. Hibrit özellikleri ile PNN simülasyonunda en iyi sınıflandırma başarısı PNN yayılım parametresi 1.83 ile 2.08 arasında iken elde edilmiştir. Sınıflandırma başarısı bütün evrelerde eğitim verisinde %98 ve test verisinde % 85.33 elde edilmiştir. Evrelere göre sınıflandırma başarısı Tablo 6.3’te görülmektedir.

Tablo 6.3. Hibrit özellikler PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	40	3	0	0	7	0
Evre 2	7	35	1	0	7	0
Evre 3	0	10	39	1	0	0
Evre 4	0	0	0	50	0	0
REM	7	1	0	0	42	0
Uyanık	0	0	0	0	0	50

6.5.2 PCA bileşenleri PNN simülasyon sonuçları

Tablo 6.4. ile Tablo 6.7. arasındaki tablolarda ise temel bileşen analizinin en büyük 5, 6, 7 ve 8 bileşeninin eğitim ve test verileri üzerine izdüşürülerek elde edilen özellik vektörleri giriş olarak kullanıldığı olasılıksal sinir ağları sonuçlarını içermektedir. Temel bileşen analizinin en büyük 5, 6, 7 ve 8 bileşeni eğitim ve test verileri üzerine izdüşürüldüğünde PNN’de kullanılmak üzere sırasıyla 5, 6, 7 ve 8 giriş meydana gelir. Burada simülasyon sonuçları birbirlerine oldukça yakın olmalarına rağmen en iyi sonucu Tablo 6.7.’de verilen temel bileşen analizinin en büyük 8 bileşeninden meydana geldiği görülmektedir.

Temel bileşen analizi simülasyonları yapılırken olasılıksal sinir ağı yayılım katsayısı değiştirilerek en iyi sonuç elde edilmeye çalışılmıştır. Bu durumda Tablo 6.4 ve Tablo 6.5’de verilen PCA’nın en büyük 5 ve 6 bileşeni için PNN yayılım parametresi 1.82 – 2.20 arasında değiştirildiğinde en iyi sınıflandırma başarısı elde edilmektedir. Bu girişler için sınıflandırma başarısı bütün evreler için eğitim verisi için % 98, test verisi için % 83.33 olmuştur. Tablo 6.6 ve Tablo 6.7’de ise PCA’nın en büyük 7 ve 8 bileşeni için PNN yayılım parametresi 2.22 – 2.28 arasında en yüksek sınıflandırma başarısı göstermektedir. Bu girişler için sınıflandırma başarısı eğitim verisi için % 97.33 ve test verisi için % 84.67 olmuştur. Bu durumda PCA’nın en büyük 7 ve 8 bileşeninin oluşturduğu PNN girişleri hibrit özelliklere oldukça yakın bir sınıflandırma başarısı göstermiştir.

Tablo 6.4. PCA ile en büyük 5 temel bileşen PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	39	3	0	0	8	0
Evre 2	7	35	1	0	7	0
Evre 3	0	13	36	1	0	0
Evre 4	0	0	0	50	0	0
REM	8	1	0	0	41	0
Uyanık	1	0	0	0	0	49

Tablo 6.5. PCA ile en büyük 6 temel bileşen PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	39	3	0	0	8	0
Evre 2	7	35	1	0	7	0
Evre 3	0	10	39	1	0	0
Evre 4	0	0	0	50	0	0
REM	8	1	0	0	41	0
Uyanık	0	0	0	0	0	49

Tablo 6.6 PCA ile en büyük 7 temel bileşen PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	39	3	0	0	8	0
Evre 2	7	35	1	0	7	0
Evre 3	0	9	40	1	0	0
Evre 4	0	0	0	50	0	0
REM	8	1	0	0	41	0
Uyanık	0	0	0	0	0	50

Tablo 6.7. PCA ile en büyük 8 temel bileşen PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	39	3	0	0	8	0
Evre 2	7	35	1	0	7	0
Evre 3	0	9	40	1	0	0
Evre 4	0	0	0	50	0	0
REM	8	1	0	0	41	0
Uyanık	0	0	0	0	0	50

6.5.3. Polinomik Kernel PCA bileşenleri PNN simülasyon sonuçları

Polinomik Kernel PCA'nın sınıflandırma başarısını tespit etmek için Denklem (5.34)' verilen Kernel fonksiyonunda Kernel parametresi (d) 0.1, 0.2, 0.3, 0.4 ve 0.5 alınarak simülasyonlar yapılmıştır. Ayrıca her bir Kernel parametresi için de en büyük 5, 6, 7 ve 8 temel bileşen için bu simülasyonlar tekrarlanmıştır. Yapılan simülasyonlarda sınıflandırma başarısı Polinomik Kernel PCA'nın en büyük 5, 6, 7 ve 8 bileşeni için aynı sonucu vermiştir. Kernel parametresi 0.1, 0.2 ve 0.4 olduğunda test verisinde % 80'lik bir sınıflandırma başarısı sağlanmıştır. Kernel parametresinin 0.3 ve 0.5 olduğu durumda ise sınıflandırma başarısı % 79'dur. Tablo 6.8 ile Tablo 6.11 arasındaki tablolar Polinomik Kernel PCA'nın 5, 6, 7 ve 8 bileşeninin oluşturduğu sınıflandırma başarısını göstermektedir. Bu tablolar Kernel parametresi 0.4 iken alınan simülasyon sonuçlarıdır. Bunların seçilmesinin nedeni eğitim verisindeki en yüksek sınıflandırma başarısı ve PCA'ya olan benzer dağılımdır. Kernel parametresi 0.1, 0.2, 0.3 ve 0.5 iken eğitim verisinde sınıflandırma başarısı % 90 ile % 95 arasında değişmekte, Kernel parametresi 0.4 iken bu başarı % 97.33 olmuştur.

Tablo 6.8. Polinomik Kernel PCA ile en büyük 5 temel bileşen PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	32	5	0	0	13	0
Evre 2	4	36	2	0	8	0
Evre 3	0	17	30	3	0	0
Evre 4	0	0	0	50	0	0
REM	4	2	0	0	44	0
Uyanık	2	0	0	0	0	48

Tablo 6.9. Polinomik Kernel PCA ile en büyük 6 temel bileşen PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	32	5	0	0	13	0
Evre 2	4	36	2	0	8	0
Evre 3	0	17	30	3	0	0
Evre 4	0	0	0	50	0	0
REM	4	2	0	0	44	0
Uyanık	2	0	0	0	0	48

Tablo 6.10. Polinomik Kernel PCA ile en büyük 7 temel bileşen PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	32	5	0	0	13	0
Evre 2	4	36	2	0	8	0
Evre 3	0	17	30	3	0	0
Evre 4	0	0	0	50	0	0
REM	4	2	0	0	44	0
Uyanık	2	0	0	0	0	48

Tablo 6.11. Polinomik Kernel PCA ile en büyük 8 temel bileşen PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	32	5	0	0	13	0
Evre 2	4	36	2	0	8	0
Evre 3	0	17	30	3	0	0
Evre 4	0	0	0	50	0	0
REM	4	2	0	0	44	0
Uyanık	2	0	0	0	0	48

6.5.4. Radyal Kernel PCA bileşenleri PNN simülasyon sonuçları

Radyal tabanlı Kernel PCA için Denklem (5.35)'deki Kernel fonksiyonun parametresi olan σ^2 değiştirilerek simülasyonlar yapılmıştır. σ^2 Kernel parametresi eğitim ve test verilerine uygun olarak 1000, 2000, 3000, 4000 ve 5000 alınmıştır. Ayrıca her bir parametre değeri için Radyal Kernel PCA'nın en büyük 5, 6, 7 ve 8 bileşeni için ayrıca tekrarlanmıştır. Polinomik Kernel PCA'da olduğu gibi burada da temel bileşen sayısının sınıflandırma başarısı üzerinde bir etkisi olmamıştır. Bütün bileşenler için sınıflandırma başarısı aynı olmuştur. Yalnız bu başarıyı yakalamak için PNN yayılım parametresi farklı olmuştur. Yapılan simülasyonlar sonunda verilere en uygun Kernel parametresi 1000 olduğu tespit edilmiştir. Kernel parametresi 1000 ve PNN yayılım parametresi 0.360 – 0.376 arasında iken elde

edilen sınıflandırma başarısı eğitim verileri için % 94 ve test verileri için % 61.33 olmuştur. Diğer Kernel parametrelerinde ise eğitim verisi için sınıflandırma başarısı % 90 - % 94 arasında iken test verilerindeki sınıflandırma başarısı % 58 ile % 60 arasında değişmektedir. Kernel parametresi 1000 iken elde edilen sonuçlar Tablo 6.12 ile Tablo 6.15 arasında gösterilmiştir.

Tablo 6.12. Radyal Kernel PCA ile en büyük 5 temel bileşen PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	17	10	4	7	13	0
Evre 2	1	22	3	0	24	0
Evre 3	0	19	31	0	0	0
Evre 4	10	0	0	40	0	0
REM	18	4	0	0	28	0
Uyanık	2	0	0	0	2	46

Tablo 6.13. Radyal Kernel PCA ile en büyük 6 temel bileşen PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	17	10	4	7	12	0
Evre 2	1	22	3	0	24	0
Evre 3	0	19	31	0	0	0
Evre 4	10	0	0	40	0	0
REM	17	5	0	0	28	0
Uyanık	2	0	0	0	2	46

Tablo 6.14. Radyal Kernel PCA ile en büyük 7 temel bileşen PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	17	10	4	7	12	0
Evre 2	1	22	3	0	24	0
Evre 3	0	19	31	0	0	0
Evre 4	10	0	0	40	0	0
REM	17	5	0	0	28	0
Uyanık	2	0	0	0	2	46

Tablo 6.15. Radyal Kernel PCA ile en büyük 8 temel bileşen PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	17	10	4	7	12	0
Evre 2	1	22	3	0	24	0
Evre 3	0	19	31	0	0	0
Evre 4	10	0	0	40	0	0
REM	17	5	0	0	28	0
Uyanık	2	0	0	0	2	46

BÖLÜM 7. SONUÇLAR VE ÖNERİLER

Bu çalışmada çeşitli uyku hastalıklarının teşhisinde kullanılan uyku evrelerinin görsel skorlanmasına karşılık bilgisayar tabanlı otomatik sınıflandırma sistemleri geliştirilmeye çalışılmıştır. Görsel skora 8 saatlik bir gece uykusu için oldukça uzun zaman almakta ve belli bir uzmanlık gerektirmektedir. Otomatik skora sistemlerinin geliştirilmesi sınıflandırmanın kritik olduğu durumlarda ve henüz uzman olmayan doktorlara bir yardımcı olarak tasarlanmaktadır. Doktorlar için hem zaman tasarrufu sağlamak hem de uzmanların görsel hatalarını azaltmaktadır.

Uyku evrelerinin sınıflandırılması amacıyla, EEG işaretlerinden hesaplanan ve en sık kullanılan özelliklerin ayrıştırma yeteneği sınıflandırma adımına geçilmeden belirlenmesi amacıyla bir yöntem geliştirilmiştir. Hesaplamaları yapmak için kullanılacak EEG veritabanına karar verildikten sonra bir kez hesaplanması gereken genelleştirilmiş kovaryans matrisinin belirlenmesi ve genliği en büyük iki özdeğerine karşılık gelen iki özvektörünün saklanması yeterlidir. Özellikler zaman-uzay, frekans-uzay ve hibrit olmak üzere üç sınıfta toplanmış, her sınıfın uyku evrelerini ayrıştırma yeteneği detaylı simülasyonlarla belirlenmiştir. Böyle bir analizin önemli iki sonucu vardır. Birinci olarak, sunulan yöntem sayesinde sınıflandırma adımının başarılı sonuç verip vermeyeceğini önceden belirlemek mümkündür. Dolayısıyla kullanılan özelliklerin tatmin edici ayrıştırma sonuçları vermemesi durumunda sınıflandırma başarısını görmek için sınıflandırma adımının kullanılmasına gerek kalmayacaktır. İkinci olarak, özelliklerin tatmin edici ayrıştırma sonuçları vermesi sınıflandırıcının başarısı için bir üst sınır belirleyecektir. Belirli bir sınıflandırıcı kullanılarak elde edilen sınıflandırma başarımının üst sınıra ne kadar yakın olduğunun belirlenmesi mümkün olacaktır. Sınıflandırma başarımının üst sınırdan uzakta olması kullanılan sınıflandırıcının parametrelerinin değiştirilmesi ya da farklı bir sınıflandırıcının kullanılması anlamına gelecektir.

Yapılan simülasyonlar uyku evrelerinin skorlanması ve sınıflandırılmasıyla ilgili daha önceki yapılan çalışmalarda oldukça uyumlu sonuçlar vermiştir. Simülasyonların detayları Bölüm 6. da verilmiştir. Uyku çalışmalarında uyku evreleri belli frekans bandlarında daha belirleyici özellikler içerdiğinden simülasyonlarda sadece zaman-uzayı özellik vektörlerinden oluşan sonuçlar üzerinde fazla durulmamıştır. Zaman-uzayı özellikleri frekans bandlarını desteklemek amacıyla kullanılmışlardır. Simülasyonlar incelendiğinde aynı evrelere ait hibrit özellikler kullanılarak elde edilen grafikler sadece frekans-uzayı özelliklerinin kullanıldığı grafiklerden daha iyi ayrıştığı görülmektedir. Bu sonuç bize kullanılacak sınıflandırıcının hibrit özellikler kullandığında daha iyi bir sonuç vereceğini göstermektedir. Nitekim yapay sinir ağları ile yapılan sınıflandırma çalışmalarında oldukça açık bir şekilde bu sonuç görülmektedir.

Uyku evrelerini ayırma üzerine yapılan önceki çalışmalar incelendiğinde evrelerin tümü için sınıflandırma başarısının % 68 - %83 olduğu görülmektedir. Örnek olarak, sadece frekans uzayı özellikleri kullanıldığında elde edilen sonuçlar [68] Uyanık için % 88, Evre 1 için % 0, Evre 2 için % 84, Evre 3 için % 3, Evre 4 için % 95 ve REM evresi için % 88 bir başarı elde edilmiştir. Burada özellik vektörü olarak her bandın enerji yoğunluğu ve harmonik parametreler kullanılmış ve yapay sinir ağları ile sınıflandırma yapılmıştır. Bir diğer benzeri çalışmada hibrit özelliklerin kullanıldığı çalışmadır [95] ki burada Uyanık için % 84.0, Evre 1 için % 38.6, Evre 2 için % 88.9, Evre 3 için % 80.5, Evre 4 için % 93.4 ve REM evresi için % 72.5 başarı sağlanmıştır. Aynı zamanda bu çalışmada sınıflandırıcının hangi evreleri karıştırdığı Tablo 7.1'de verilmiştir. Evrelerin dağılımı incelendiğinde yapılan simülasyonlarla benzer olduğu görülmektedir.

Tablo 7.1. [95]'deki uyku evreleri için simülasyon sonucu

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	787	695	5	0	144	408
Evre 2	589	8242	201	1	86	157
Evre 3	3	147	955	79	0	3
Evre 4	1	3	27	439	0	0
REM	113	389	0	0	1827	190
Uyanık	319	130	8	2	28	2560

Bu çalışmada aynı zamanda evrelerin kümelenmesini görmek için iki farklı yöntem kullanılmıştır. Birincisi temel bileşen analizi, diğeri Kernel tabanlı temel bileşen analizidir. Daha sonra Olasılıksal sinir ağları ile bu yöntemlerin performansları incelenmiştir.

Çalışma da önce hibrit özelliklerin kendisi olasıksal sinir ağına giriş olarak verilmiştir. Burada elde edilen sonuç Uyanık için % 100, Evre 1 için % 80, Evre 2 için % 70, Evre 3 için % 78, Evre 4 için % 100 ve REM evresi için % 84 başarı sağlanmıştır. Bütün evreler için sınıflandırma başarısı % 85.33 olmuştur. Bu performans önceki çalışmalara nazaran oldukça iyi bir sonuç vermiştir.

Aynı veriler kullanılarak PCA'nın en büyük 5, 6, 7 ve 8 bileşeninin eğitim ve test verileri üzerine izdüşürülerek hazırlanan yeni olasıksal sinir ağı girişleri ile simülasyonlar yapıldığında bu sonuçlar; en büyük 5 ve 6 bileşen için aynı olmakta ve Uyanık için % 98, Evre 1 için % 78, Evre 2 için % 70, Evre 3 için % 72, Evre 4 için % 100 ve REM evresi için % 82'lik bir başarı olmuştur, en büyük 7 ve 8 bileşen için de aynı olmakta ve Uyanık için % 100, Evre 1 için % 78, Evre 2 için % 70, Evre 3 için % 80, Evre 4 için % 100 ve REM evresi için % 82'lik bir başarı elde edilmiştir. En büyük 5 ve 6 bileşen için toplam sınıflandırma başarısı % 83.33, en büyük 7 ve 8 bileşen için sınıflandırma başarısı % 84.67 olmuştur.

Yine aynı veriler Kernel tabanlı PCA'nın polinomik ve radyal fonksiyonlarından elde edilen 5, 6, 7 ve 8 temel bileşeni üzerine izdüşümlerine uygulandığında temel bileşenlerin hepsinde aynı sınıflandırma başarısı elde edilmektedir. Polinomik kernel PCA için simülasyon sonuçları Uyanık için % 96, Evre 1 için % 64, Evre 2 için % 72, Evre 3 için % 60, Evre 4 için % 100 ve REM evresi için % 88'lik bir başarı elde edilmiştir. Radyal Kernel için bu sonuçlar Uyanık için % 92, Evre 1 için % 34, Evre 2 için % 44, Evre 3 için % 62, Evre 4 için % 80 ve REM evresi için % 56 olmuştur.

Simülasyon çalışmalarının sonuçları Tablo 7.2'de verilmiştir. Bu tablo incelendiğinde hibrit özelliklerin kendisi, PCA'nın 5-8 arasındaki temel bileşenlerinin izdüşümleri ve Polinomik Kernel PCA'nın 5-8 arasındaki temel bileşenlerinin izdüşümleri olasıksal sinir ağı ile sınıflandırmada oldukça iyi

performans göstermiştir. Radyal Kernel PCA'nın 5-8 arasındaki temel bileşenlerinin izdüşümleri ise olasılıksal sinir ağı ile uyank ve Evre 4 için başarılı sonuç vermesine rağmen toplam sınıflandırmada başarılı bir performans göstermemiştir.


Tablo 7.2 Evreler için sınıflandırma başarısı (%)

	Hibrit Özellikler	PCA 5-6 bileşen	PCA 7-8 bileşen	Polinomik Kernel PCA	Radyal Kernel PCA
Evre 1	80	78	78	64	34
Evre 2	70	70	70	72	44
Evre 3	78	72	80	60	62
Evre 4	100	100	100	100	80
REM	84	82	82	88	56
Uyank	100	98	100	96	92
Toplam	85.33	83.33	84.67	80	61.33


Yapılan diğer bir çalışma da evrelerin uzaydaki farklı bölgelerde kümelenmeleridir. Burada da PCA ve Kernel PCA ile PNN arasında oldukça uyumlu sonuçlar elde edilmiştir. Birkaç örnekle açıklamak gerekirse; temel bileşen analizinin uyku evrelerinin karışık olduğu Şekil 7.1 ile evrelerin çok iyi ayrıştığı Şekil 7.2 incelendiğinde bu şekillere ait olan ve Tablo 7.3'de verilen olasılıksal sinir ağı sonuçları ile oldukça uyumlu oldukları görülecektir. Mesela, Şekil 7.1'de Evre 1, Evre 2 ve REM evrelerinin birbiri ile karışmış durumda oldukları görülmektedir, Tablo 7.3 incelendiğinde Evre 1'in 3 tanesi Evre 2 ve 8 tanesi REM evresi, Evre 2'nin 7 tanesi Evre 1 ve 7 tanesi REM evresi, REM evresinin de 8 tanesi Evre 1 ve 1 tanesi Evre 2 olarak hatalı sınıflandırılmıştır. Şekil 7.2'de ise Evre 2, Evre 4 ve Uyank evreleri oldukça iyi ayrılmış oldukları görülmektedir. Tablo 7.2 incelendiğinde Evre 2'nin olduğu satırda Evre 4 ve Uyank sıfır olduğu, aynı şekilde Evre 4 ve Uyank evresinin olduğu satırlar incelendiğinde diğerlerinin sıfır olduğu, yani bu evreleri doğru sınıflandırıldığı sonucuna varılmıştır.

Tablo 7.3. PCA bileşen izdüşümleri ile PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyank
Evre 1	39	3	0	0	8	0
Evre 2	7	35	1	0	7	0
Evre 3	0	9	40	1	0	0
Evre 4	0	0	0	50	0	0
REM	8	1	0	0	41	0
Uyank	0	0	0	0	0	50




Şekil 7.1 PCA'nın uyku evrelerini ayırma yeteneği (birbirine karışan evreler)




Şekil 7.2. PCA'nın uyku evrelerini ayırma yeteneği (birbiri ile ayrılan evreler)

Yukarıdakine benzer şekilde Polinomik Kernel PCA'ya ilişkin Şekil 7.3 ve Şekil 7.4 ve bu şekillere ait olasılıksal sinir ağı sonuçlarının gösterildiği Tablo 7.4 incelendiğinde yukarıdakine benzer durum olduğu görülecektir. Bu şekilde diğer bütün evrelerin karışma ve ayrışma durumları incelendiğinde çok iyi ayrılan evreleri

PNN'de çok iyi tahmin etmiştir. Birbirine karışmış olan evrelerde ve uzaydaki kümelenmeleri ayrı da olsa birbirine çok yakın olan evrelerde ise hataların olduğu yani sınıflandırıcının hatalı sonuç verdiği görülmüştür.



Şekil 7.3. Polinomik Kernel PCA'nın uyku evrelerini ayırma yeteneği (nispeten ayrılan evreler)



Şekil 7.4. Polinomik Kernel PCA'nın uyku evrelerini ayırma yeteneği (birbiri ile ayrılan evreler)

Tablo 7.4. Polinomik Kernel PCA bileşen izdüşümleri ile PNN simülasyon sonuçları

	Evre 1	Evre 2	Evre 3	Evre 4	REM	Uyanık
Evre 1	32	5	0	0	13	0
Evre 2	4	36	2	0	8	0
Evre 3	0	17	30	3	0	0
Evre 4	0	0	0	50	0	0
REM	4	2	0	0	44	0
Uyanık	2	0	0	0	0	48

Bu tez çalışmasının, bu alanda yapılacak diğer çalışmalara temel bir ön bilgi oluşturması yönüyle yapılacak diğer bilimsel araştırmalara katkı sağlayacağı düşünülmektedir. Tezde kullanılan olasılıksal sinir ağları sınıflandırıcısının yanında diğer sınıflandırıcılarda da özellik vektörleri ile en iyi sınıflandırma performansı elde edilebilmesinin mümkün olacağı görülmüştür. Literatürde oldukça çok sayıda sınıflandırıcı mevcuttur. Bunlardan bazıları örüntü eşleştirme, istatistiksel, yapısal ve sinir ağlarıdır. Her bir sınıf kendi bünyesinde çeşitli yöntemleri barındırmaktadır. Bu nedenle bütün yöntemleri gerçekleştirmek yerine her bir sınıfı temsil eden en iyi bir veya birkaç yöntemin gerçekleştirilmesi daha uygun olacaktır.

Ayrıca, EEG işaretlerinden hesaplanabilecek yeni parametrelerin sınıflandırma başarısını artırıp artırmayacağı da araştırılabilir. Yeni parametreler seçilirken “İnsan Uyku Evrelerinin Standart Terminolojisi, Teknikler ve Skorlama Sistemleri Elkitabı”nda tanımlanan uyku evrelerini birbirinden ayıran özelliklerin dikkate alınması gereklidir. EEG işaretleri durağan olmayan işaretler olduğundan ayırık dalgacık dönüşümü veya ayırık dalgacık dönüşümü eksikliklerini gideren karmaşık dalgacık dönüşümü yeni parametrelerin hesaplanmasında kullanılabilir uygun dönüşüm uzayları olarak değerlendirilebilir.

EK B. Temel Bileşen Analizi (PCA) Matlab Kodu

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%% TEMEL BİLEŞEN ANALİZİ (PCA)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% ortalama hesaplama (m)
m=mean(hex,2);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% ortalama Covaryans matrisi (C)
CM=zeros(15,15);
for i=1:150
    for j=1:15
        CX(j,i)=hex(j,i);
    end
    CM=CM+(CX(:,i)-m)*(CX(:,i)-m)';
end
CC=(1/150)*CM;

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% Özvektör ve özdeğer hesaplama
[PC,V]=eig(CC);
V=diag(V);
[junk,rind]=sort(-1*V);
V=V(rind);
PC=PC(:,rind);
FF1=PC(:,1:2);

SS1=PC(:,1:5);
SS2=PC(:,1:6);
SS3=PC(:,1:7);
SS4=PC(:,1:8);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% Test veri matrisi hesaplama

VV1=yhtx'*FF1;

tsVV1=(hex'*SS1)';
tsVV2=(hex'*SS2)';
tsVV3=(hex'*SS3)';
tsVV4=(hex'*SS4)';

trVV1=(yhtx'*SS1)';
trVV2=(yhtx'*SS2)';
trVV3=(yhtx'*SS3)';
trVV4=(yhtx'*SS4)';

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% SONUC
h1=VV1(1:50,:);
h2=VV1(51:100,:);

```

```

h3=VV1(101:150,:);
h4=VV1(151:200,:);
h5=VV1(201:250,:);
h6=VV1(251:300,:);

plot(h1(:,1),h1(:,2),'*',h2(:,1),h2(:,2),'o',h5(:,1),h5(:,2),'.');
Title('PCA');
xlabel('1. en büyük temel bileşen (q1)')
ylabel('2. en büyük temel bileşen (q2)')
legend('Evre 1','Evre 2','REM')

figure (2)
plot(h2(:,1),h2(:,2),'o',h5(:,1),h5(:,2),'.',h6(:,1),h6(:,2),'d');
Title('PCA');
xlabel('1. en büyük temel bileşen (q1)')
ylabel('2. en büyük temel bileşen (q2)')
legend('Evre 2','REM','UYANIK')

figure (3)
plot(h3(:,1),h3(:,2),'+',h4(:,1),h4(:,2),'x',h5(:,1),h5(:,2),'.');
Title('PCA');
xlabel('1. en büyük temel bileşen (q1)')
ylabel('2. en büyük temel bileşen (q2)')
legend('Evre 3','Evre 4','REM')

figure (4)
plot(h2(:,1),h2(:,2),'o',h4(:,1),h4(:,2),'x',h6(:,1),h6(:,2),'d');
Title('PCA');
xlabel('1. en büyük temel bileşen (q1)')
ylabel('2. en büyük temel bileşen (q2)')
legend('Evre 2','Evre 4','UYANIK')

```

EK C. Polinomik Kernel PCA Matlab Kodu

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%% POLİNOMİK KERNEL TEMEL BİLEŞEN ANALİZİ
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% K matrisi oluşturma
d=0.4;
for i=1:150
    for j=1:150
        K(i,j)=(hex(:,i)'*hex(:,j)+1)^d;
    end
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% ORTALANMIŞ VERİLER KT HESABI
LM=(1/150)*ones(150,150);
KT=K-LM*K-K*LM+LM*K*LM;

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% Özvektör ve özdeğer hesaplama
[PC,V]=eig(KT);
V=diag(V);
[junk,rind]=sort(-1*V);
V=V(rind);
PC=PC(:,rind);
FF1=PC(:,1:2);

SS1=PC(:,1:5);
SS2=PC(:,1:6);
SS3=PC(:,1:7);
SS4=PC(:,1:8);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% bilinmeyen verildiğinde izdusum hesaplama
for m=1:300
    for n=1:150
        KK(m,n)=(yhtx(:,m)'*hex(:,n)+1)^d;
    end
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% ORTALANMIŞ VERİLER KT HESABI
LM1=(1/150)*ones(300,150);
KX=KK-LM1*K-KK*LM1+LM1*K*LM1;
KS=KX';

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

VV1=KS'*FF1;

tsVV1=(KT'*SS1)';
tsVV2=(KT'*SS2)';
tsVV3=(KT'*SS3)';

```

```

tsVV4=(KT'*SS4)';

trVV1=(KS'*SS1)';
trVV2=(KS'*SS2)';
trVV3=(KS'*SS3)';
trVV4=(KS'*SS4)';

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

% SONUC
h1=VV1(1:50,:);
h2=VV1(51:100,:);
h3=VV1(101:150,:);
h4=VV1(151:200,:);
h5=VV1(201:250,:);
h6=VV1(251:300,:);

plot(h1(:,1),h1(:,2),'*',h2(:,1),h2(:,2),'o',h5(:,1),h5(:,2),'.');
Title('POLİNOMİK KERNEL PCA');
xlabel('1. en büyük temel bileşen (q1)')
ylabel('2. en büyük temel bileşen (q2)')
legend('Evre 1','Evre 2','REM')

figure (2)
plot(h2(:,1),h2(:,2),'o',h5(:,1),h5(:,2),'.',h6(:,1),h6(:,2),'d');
Title('POLİNOMİK KERNEL PCA');
xlabel('1. en büyük temel bileşen (q1)')
ylabel('2. en büyük temel bileşen (q2)')
legend('Evre 2','REM','UYANIK')

figure (3)
plot(h3(:,1),h3(:,2),'+',h4(:,1),h4(:,2),'x',h5(:,1),h5(:,2),'.');
Title('POLİNOMİK KERNEL PCA');
xlabel('1. en büyük temel bileşen (q1)')
ylabel('2. en büyük temel bileşen (q2)')
legend('Evre 3','Evre 4','REM')

figure (4)
plot(h2(:,1),h2(:,2),'o',h4(:,1),h4(:,2),'x',h6(:,1),h6(:,2),'d');
Title('POLİNOMİK KERNEL PCA');
xlabel('1. en büyük temel bileşen (q1)')
ylabel('2. en büyük temel bileşen (q2)')
legend('Evre 2','Evre 4','UYANIK')

```

EK D. Radyal Kernel PCA Matlab Kodu

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%% RADYAL KERNEL TEMEL BİLEŞEN ANALİZİ
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% K matrisi oluşturma
d=1000;
for i=1:150
    for j=1:150
        K(i,j)=exp(((hex(:,i)-hex(:,j))'*(hex(:,i)-
hex(:,j)))/(2*d));
    end
end
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% ORTALANMIŞ VERİLER KT HESABI
LM=(1/150)*ones(150,150);
KT=K-LM*K-K*LM+LM*K*LM;

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Özvektör ve özdeğer hesaplama
[PC,V]=eig(KT);
V1=diag(V);
[junk,rind]=sort(-1*V1);
V2=V1(rind);
PC=PC(:,rind);
FF1=PC(:,1:2);

SS1=PC(:,1:5);
SS2=PC(:,1:6);
SS3=PC(:,1:7);
SS4=PC(:,1:8);
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% bilinmeyen verildiğinde izdusum hesaplama
for m=1:300
    for n=1:150
        KK(m,n)=exp(((yhtx(:,m)-hex(:,n))'*(yhtx(:,m)-
hex(:,n)))/(2*d));
    end
end
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% ORTALANMIŞ VERİLER KT HESABI
LM1=(1/150)*ones(300,150);
KX=KK-LM1*K-KK*LM1+LM1*K*LM1;
KS=KX';
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
VV1=KS'*FF1;

tsVV1=(KT'*SS1)';
tsVV2=(KT'*SS2)';
tsVV3=(KT'*SS3)';
tsVV4=(KT'*SS4)';

trVV1=(KS'*SS1)';
trVV2=(KS'*SS2)';

```

```

trVV3=(KS'*SS3)';
trVV4=(KS'*SS4)';

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% SONUC
h1=VV1(1:50,:);
h2=VV1(51:100,:);
h3=VV1(101:150,:);
h4=VV1(151:200,:);
h5=VV1(201:250,:);
h6=VV1(251:300,:);

plot(h1(:,1),h1(:,2),'*',h2(:,1),h2(:,2),'o',h5(:,1),h5(:,2),'.');
Title('RADYAL KERNEL PCA');
xlabel('1. en büyük temel bileşen (q1)')
ylabel('2. en büyük temel bileşen (q2)')
legend('Evre 1','Evre 2','REM')

figure (2)
plot(h2(:,1),h2(:,2),'o',h5(:,1),h5(:,2),'.',h6(:,1),h6(:,2),'d');
Title('RADYAL KERNEL PCA');
xlabel('1. en büyük temel bileşen (q1)')
ylabel('2. en büyük temel bileşen (q2)')
legend('Evre 2','REM','UYANIK')

figure (3)
plot(h3(:,1),h3(:,2),'+',h4(:,1),h4(:,2),'x',h5(:,1),h5(:,2),'.');
Title('RADYAL KERNEL PCA');
xlabel('1. en büyük temel bileşen (q1)')
ylabel('2. en büyük temel bileşen (q2)')
legend('Evre 3','Evre 4','REM')

figure (4)
plot(h2(:,1),h2(:,2),'o',h4(:,1),h4(:,2),'x',h6(:,1),h6(:,2),'d');
Title('RADYAL KERNEL PCA');
xlabel('1. en büyük temel bileşen (q1)')
ylabel('2. en büyük temel bileşen (q2)')
legend('Evre 2','Evre 4','UYANIK')

```


EK E. Olasılıksal Sinir Ağı Matlab Kodu

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%% OLASILIKSAL SİNİR AĞLARI
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

P=hex;
Tc=ce;

T = ind2vec(Tc);
net = newpnn(P,T,1.93);
Y = sim(net,P);
Yc = vec2ind(Y);

t=0;
for i=1:150
    if Yc(i)==ce(i)
        t=t+1;
        tt=(t/150)*100;
    end
end

P1=htx;

Yt = sim(net,P1);
Yct = vec2ind(Yt);

t1=0;
for i=1:300
    if Yct(i)==ct(i)
        t1=t1+1;
        ts=(t1/300)*100;
    end
end
```

KAYNAKLAR

- [1] PRINZ, P.N., LARSEN, L.H., MOE, K.E., and VITIELLO, M.V., “EEG markers of early Alzheimer’s disease in computer selected tonic REM sleep”, *Electroencephalogr. Clin. Neurophysiol.*, 1992, 83:36–43.
- [2] SINHA, R.K., Artificial Neural Network and Wavelet Based Automated Detection of Sleep Spindles, REM Sleep and Wake States, *Journal of Medical Systems*, vol. 32, 2008, pp. 291–299.
- [3] KOCYIGIT, Y., ALKAN, A., EROL, H., “Classification of EEG Recordings by Using Fast Independent Component Analysis and Artificial Neural Network”, *Journal of Medical System*, Feb. 2008, 32 (1):17–20.
- [4] KIM, M.S., CHO, Y.C., BERDAKH, A., SEO, H.D., Analysis of Brain Function and Classification of Sleep Stage EEG using Daubechies Wavelet, *Sensors and Materials*, Vol. 20, No. 1, 2008, pp. 001–014.
- [5] VIRKKALA, J., HASAN, J., VÄRRI, A., HIMANEN, S.L., MÜLLER, K., Automatic sleep stage classification using two-channel electro-oculography, *Journal of Neuroscience Methods*, vol. 166, 2007, pp. 109–115.
- [6] DOROSHENKOV, L., KONYSHEV, V., SELISHCHEV, S., “Classification of human sleep stages based on EEG processing using hidden Markov models”, *Biomedical Engineering*, January 2007, 41 (1): 25-28.
- [7] MAEDA, M., TAKAJYO, A., INOUE, K., KUMAMARUL, K., MATSUOKA, S., “Time-Frequency Analysis of Human Sleep EEG and Its Application to Feature Extraction about Biological Rhythm”, *SICE Annual Conference 2007*, Kagawa University, Japan, September 17-20, 2007.
- [8] HELD, C.M., HEISS, J.E., ESTEVEZ, P.A., PEREZ, C.A., GARRIDO, M., ALGARIN, C., PEIRANO, P., “Extracting Rules From Polysomnographic Recordings for Infant Sleep Stage Classification”, *IEEE Transactions on Biomedical Engineering*, October 2006, 53 (10): 1954-1962.

- [9] CAFFAREL, J., GIBSON, G.J., HARRISON, J.P., GRIFFITHS, C.J., DRINNAN, M.J., “Comparison of Manual Sleep Staging with Automated Neural Network-Based Analysis in Clinical Practice”, *Medical & Biological Engineering & Computing*, 2006, 44: 105-110.
- [10] TIAN, J.Y., LIU, J.Q., “Automated Sleep Staging by a Hybrid System Comprising Neural Network and Fuzzy Rule-based Reasoning”, *Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*, Shanghai, China, September 1-4, 2005.
- [11] HANAOKA, M., KOBAYASHI, M., YAMAZAKI, H., “Automatic Sleep Stage Scoring Based on Waveform Recognition Method and Decision-Tree Learning”, *Systems and Computers in Japan*, 2002, 33 (11):1-13.
- [12] SHIMADA, T., SHIINA, T., SAITO, Y., “Detection of Characteristic Waves of Sleep EEG by Neural Network Analysis”, *IEEE Transactions on Biomedical Engineering*, March 2000, 47(3):369-379.
- [13] CHILDERS, C.K., *Evoked Responses: Electrogenesis Models, Methodology and Tracking Analysis*, *Proceedings of IEEE, USA*, 1997, 5:612-626.
- [14] LESSER, R.P., “Design Principles for Computerized EEG Monitoring”, *Electroencephalography and Clinical Neurophysiology*, 1992, 83:24-35.
- [15] LOOMIS, A.L., HARVEY, E.N., HOBART, G.A., “Cerebral States During Sleep, as Studied by Human Brain Potentials” *J. Exp. Psychol.*, 1937, 21: 127–144.
- [16] YAZGAN, E., KORÜREK, M., *Tıp Elektroniği, İTÜ Elektrik - Elektronik Fakültesi Ofset Baskı Atölyesi*, İstanbul, 1996.
- [17] TERZANO, M., MANCIA, D., SALATI, M., COSTANI, G., DECEMBRINO, A., PARRINO, L., “The Cycle Alternating Pattern as A Physiological Component of Normal NREM Sleep”, *Sleep*, 1985, 8:137-145.
- [18] AKIN, M., *Uyarılmış Beyin Potansiyellerin Spektral Analiz Yöntemlerle İncelenmesi. Doktora Tezi*, E.Ü., Kayseri, 1995.
- [19] HU, J., KNAPP, B., “Electroencephalogram Pattern Recognition Using Fuzzy Logic”, 4-6 Nov 1991, 2: 805-807.
- [20] HAZARIKA, N.J., CHEN, Z., TSOI, A.C., SERGEYEW, A., “Classification of EEG signals by Using The Wavelet Transform”, *Elsevier, Signal Processing*, 1997, 59: 61-72.

- [21] JAMES, C.J., “Multireference Adaptive Noise Cancelling Applied to The EEG”, *IEEE Transactions On Biomedical Engineering*, August, 1997, 44 (8): 775-779.
- [22] MERICA, H., BLOIS, R., “Relationship between the time courses of power in the frequency bands of human sleep EEG”, *Neurophysiol Clin*, 1997, 27:116–128.
- [23] PEREDA, E., RIAL, R., GAMUNDI A., GONZALES, J., “Assessment of changing interdependencies between human electroencephalograms using nonlinear methods”, *Physica D*, 2001, 148: 147–158.
- [24] SHIMADA, T., SHIINA, T., and SAITO, Y., “Sleep Stage Diagnosis System with Neural Network Analysis”, *Proceeding of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, vol. 20, no. 4, pp. 2074-2077, 1998.
- [25] PACHECO, O.R., and VAZ, F., “Integrated System for Analysis and Automatic Classification of Sleep EEG”, *Proceeding of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, vol. 20, no. 4, pp. 2062-2065, 1998.
- [26] OROPESA, E., CYCON, H.L., JOBERT, M., “Sleep Stage Classification Using Wavelet Transform and Neural Network”, TR-99-0038, Marc 30, 1999.
- [27] FLEXER, A., SYKACEK, P., et al., “Using Hidden Markov Models to build an automatic, continuous and probabilistic sleep stager”, *IEEE*, 2000, pp. 627-631.
- [28] FLEXER, A., GRUBER, G., and DORFFNER, G., “Improvements on Continuous Unsupervised Sleep Staging”, *Proceedings of the 2002 12th IEEE Workshop on Neural Networks for Signal Processing*, New York, ABD, 4-6 September 2002, 687-695.
- [29] VAN HESE, P., PHILIPS, W., De KONINCK, J., VAN de WALLE, R., LEMAHIEU, I., “Automatic Detection of Sleep Stages Using the EEG”, 2001 *Proceeding of the 23rd Annual EMBS International Conference*, İstanbul, Turkey, October 25-28, 2001.
- [30] HERRMANN, C.S. , T. ARNOLD, A. VISBECK, H. P. HUNDEMER, HOPF, H.C., “Adaptive Frequency Decomposition Of EEG With Subsequent Expert System Analysis”, *Computers in Biology and Medicine*, 2001, 31: 407–427.
- [31] KIYMIK, M.K., AKIN, M., SUBAŞI, A., “Automatic Recognition of Alertness Level by Using Wavelet transform and Artificial Neural Network”, *Journal of Neuroscience Methods*, 2004, 139: 231-240.

- [32] MADAN, T., AGARWAL, R., SWAMY, M.N.S., “Compression of Long-term EEG Using Power Spectral Density”, Proceedings of the 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBS), San Francisco, CA, USA, September 1-5, 2004.
- [33] PINERO, P., GARCIA, P., ARCO, L., ALVAREZ, A., GARCIA, M.M., BONAL, R., “Sleep Stage Classification Using Fuzzy Sets and Machine Learning Techniques”, Neurocomputing, 2004, 58–60 : 1137 – 1143.
- [34] SUBAŞI, A., “Automatic Recognition Of Alertness Level From EEG By Using Neural Network And Wavelet Coefficients”, Expert Systems with Applications, 2005, 28: 701–711.
- [35] HE, W.X., YAN, X.G., CHEN, X.P., and LIU, H., “Nonlinear Feature Extraction of Sleeping EEG Signals”, Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference, Shanghai, China, September 1-4, 2005.
- [36] BRONZINO, J.D., Biomedical Signals: Origin and Dynamic Characteristics; Frequency-Domain Analysis, The Biomedical Engineering Handbook, IEEE Press, 2000.
- [37] ALKAN, A., “EEG İşaretlerinin Klasik ve Modern Yöntemlerle Önışlenmesi ve Sınıflandırılması”, Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Eylül, 2005.
- [38] BRONZINO J.D., Medical Devices and Systems (The Biomedical Engineering Handbook), CRC, April 19, 2006.
- [39] TATUM, W.O., Handbook of EEG Interpretation, Demos Medical Publishing, 1 edition, New York, July 1, 2007.
- [40] SANEI, S., CHAMBERS, J., EEG Signal Processing, John Wiley & Sons, Ltd, 2007.
- [41] STERMAN, M. B., MACDONALD, L. R., and STONE, R. K., “Biofeedback training of sensorimotor EEG in man and its effect on epilepsy”, Epilepsia, 15, 1974, 395–416.
- [42] WEBSTER, J.G., Encyclopedia of Medical Devices and Instrumentation, John Wiley & Sons Inc., 2nd Ed. Vol.3, 2006.
- [43] MALMIVUO, J., PLONSEY, R., Bioelectromagnetism, Principles and Applications of Bioelectric and Biomagnetic Fields, New York, Oxford University Press, 1995.
- [44] De GENNARO, L., FERRARA, M., and BERTINI, M., “Topographical distribution of spindles: Variations between and within NREM sleep cycles”, Sleep Res. Online 3, 2000, 155-160.

- [45] TANK, J, DIEDRICH, A., HALE, N., NIAZ, F.E., FURLAN, R., ROBERTSON, R.M., MOSQUEDA-GARCIA, R., “Relationship between blood pressure, sleep K-complexes, and muscle sympathetic nerve activity in humans,” *American journal of physiology. Regulatory, integrative and comparative physiology*, , 285 (1), July 2003, 208-214.
- [46] MACCALLUM, M., and ALMAINI, A.E.A., “The Application of the Wavelet Transform to Polysomnographic Signals”, *International Journal of Wavelets, Multiresolution and Information Processing*, Vol. 1, No. 3, 2003, 263-274.
- [47] SILBERT, P.L., RADHAKRISHNAN, K., JOHNSON, J., and CIASS, D.W., ‘The significance of the phi rhythm’, *Electroencephalogr. Clin. Neurophysiol.*, 95, 1995, 71–76.
- [48] SHARBROUGH, F., CHATRIAN, G.E., LESSER, R.P., LÜDERS, H., NUWER, M., PICTON, T.W., *American Electroencephalographic Society Guidelines for Standard Electrode Position Nomenclature. Journal of Clinical Neurophysiology*, 1991, 8: 200-202.
- [49] BLUMHARDT L.D., BARRETT G., HALLIDAY A.M., KRISS A., “The asymmetrical visual evoked potential to pattern reversal in one half field and its significance for the analysis of visual field effects” *Br. J. Ophthalmol.* , 1977, 61: 454-61.
- [50] AKIN, M., KIYMIK, M.K., “Application of Periodogram and AR Spectral Analysis to EEG Signals”, *Journal of Medical Systems*, 2000, 24 (4): 247-256.
- [51] ŠUŠMAKOVA, K., “Human Sleep and Sleep EEG”, *Measurement Science Review*, 4 (2), 2004,59-74.
- [52] HORNE, J., *The Phenomena of Human Sleep*, Karger Gazette, 1997.
- [53] STICKGOLD, R., JAMES, L.T., and HOBSON, J.A., “Visual discrimination learning requires sleep after training”, *Nature Neurosci.*, 3, 2000,1237–1238.
- [54] HUBER, R., GHILARDI, M.F., MASSIMINI, M., and TONONI, G., “Local sleep and learning”, *Nature*, 430 (6995), 2004, 78–81.
- [55] RECHTSCHAFFEN, A., and KALES, A., eds., “A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects”, NIH Publication No. 204, US Government Printing Office, Washington, DC., 1968.
- [56] GELİR, E., ARDIÇ, S., “İnsan uyku Evrelerinin Standart Terminolojisi, Yöntem ve Skorlama Elkitabı”, Ankara, 2000.

- [57] KÖKTÜRK, O., “Polisomnografide EEG, EOG ve EMG Kayıdı: Temel Bilgiler”, Türk Toraks Derneği Okulu, 1999, 61-68.
- [58] Japon Uyku Araştırmaları Topluluğu Uyku Hesaplama Komitesi, “Proposed Supplements and Amendments to ‘A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects’, the Rechtschaffen & Kales (1968) standard”, *Psychiatry and Clinical Neurosciences*, 55, 2001,305-310.
- [59] <http://www.dreamviews.com/sleepstages.php>, Temmuz 2008
- [60] PARMEGGIANI, P.L., and VELLUTI, R.A., *The Physiologic Nature of Sleep*, Imperial College Press, Singapore, 2005.
- [61] LEE-CHIONG, T., *Sleep: A Comprehensive Handbook*, John Wiley & Sons, Inc., New Jersey, 2006.
- [62] SHEN, J.Y., “Sleep Staging Study Through Spectrogram and Scalogram”, Course Project, Dec. 15, 2003.
- [63] HIMANEN, S.L., “A New Visual Adaptive Scoring System for Sleep Recordings”, Electronic dissertation, *Acta Electronica Universitatis Tamperensis*, 61, 2000.
- [64] ŠUŠMAKOVA, K., “Nonlinear Prediction of Sleep Electroencephalogram”, Dissertation proposal, Institute of Measurement Science, Slovak Academy of Sciences, 2005.
- [65] NORMAN, R., PAL, I., et al., “Interobserver Agreement among Sleep Scorers From Different Centers in A large Dataset”, *Sleep*, 23 (7), 2000, 901-908.
- [66] SUN, M., RYAN, N.D., DAHL, R.E., HSIN, H.C., IYENGAR, S., SCLABASSI, R.J., “A neural network system for automatic classification of sleep stages”, *Proceedings of the 12th Southern Biomedical Engineering Conference*, New Orleans, Louisiana, April 2-4, 1993, pp. 137-139.
- [67] ESTRADA, E., NAZERAN, H., NAVA, P., BEHBEHANI, K., BURK, J.R., LUCAS, E., “EEG feature extraction for classification of sleep stages”, *Proceedings of the 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBS)*, San Francisco, CA, USA, September 1-5, 2004.
- [68] KERKENI, N., ALEXANDRE, F., BEDOUI, M., BOUGRAIN, L., DOGUI, M., “Automatic classification of Sleep Stages on a EEG signal by Artificial Neural Networks”, *5th WSEAS International Conference on SIGNAL, SPEECH and IMAGE PROCESSING - WSEAS SSIP'05*, Corfu Island, Greece, August 2005.

- [69] ESTRADA, E., NAZERAN, H., BARRAGAN, J., BURK, J.R., LUCAS, E., and BEHBEHANI, K., "EOG and EMG: Two Important Switches in Automatic Sleep Stage Classification", Proceedings of the 28th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBS), New York City, USA, August 30-September 3, 2006.
- [70] GONZALES, R.C., WOODS, R.E., Digital Image Processing, Pearson Prentice Hall, Inc., 3rd Edition, New Jersey, USA, 2008.
- [71] SZETO, H.H., "Spectral Edge Frequency as a Simple Quantitative Measure of the Maturation of Electro cortical Activity", Pediatric Research, vol. 27, No.3, 1990, pp. 289-292.
- [72] KAY, S.M., Modern Spectral Estimation: Theory and Application, Prentice Hall, New Jersey, January 1988.
- [73] ALTINTAŞ, A., Matlab ve Genel Uygulamaları, Değişim Yayınları, İstanbul, 2006.
- [74] LYNN, A.P., FUERST, W., Introductory Digital Signal Processing with Computer Applications, Second Ed., John Wiley and Sons, England, pp.479 , 2004.
- [75] PROAKIS, J.G., MANOLAKIS, D.G., Digital Signal Processing Principles, Algorithms, and Applications, Prentice-Hall, Englewood Cliffs, NJ, 1996.
- [76] ALKAN, A., KIYMIK, M.K., ve ÖZÇALIK, H., "EEG İşaretlerinin AR İzgel Çözümlemesinde En Yüksek Olabilirlik Kestiriminin (MLE) Kullanılması", Biyomedikal Mühendisliği Ulusal Toplantısı, Kayseri, 1999.
- [77] BROERSEN, P.M.T., Automatic Autocorrelation an Spectral Analysis, Springer-Verlag, New York, June 2006.
- [78] MITRA, S., Digital Signal Processing, A Computer-Based Approach, Second Ed., McGraw Hill Company, New York, 2001.
- [79] CUFFIN, B.N. and COHEN, D., "Comparison of the magneto-encephalogram and Electroencephalogram", Electroencephalography and Clinical Neurophysiology, 1979, 47 (2): 132-146.
- [80] SHLENS, J., A Tutorial on Principal Component Analysis, Dec. 10, 2005. www.sn1.salk.edu/~shlens/pub/notes/pca.pdf
- [81] SMITH, L.I., A tutorial on Principal Analysis, 2002. http://csnet.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf

- [82] PICARD, R.W., KABIR, T., "Finding Similar Patterns in Large Image Databases", IEEE ICASSP, Minneapolis, MN, April 1993, V: 161-164.
- [83] VURAL, C., YILDIZ, M., "Determination of Sleep Stage Separation Ability of Features Extracted from EEG Signals Using Principle Component Analysis", Journal of Medical Systems, DOI 10.1007/s10916-008-9218-9, October 11, 2008.
- [84] SCHÖLKOPF, B., SMOLA, A.J., and MÜLLER, K.R., "Nonlinear component analysis as a kernel eigenvalue problem", Neural Computation, 1998, 10 (5) : 1299-1319.
- [85] HERBRICH, R., Learning Kernel Classifiers: Theory and Algorithms, The Massachusetts Institute of Technology Press, London, 2002.
- [86] BOSER, B.E., GUYON, I.M., and VAPNIK, V., "A training algorithm for optimal margin classifiers", In Fifth Annual Workshop on Computational Learning Theory, ACM, Pittsburgh, 1992.
- [87] SCHÖLKOPF, B., BURGESS, C., and VAPNIK, V., "Extracting support data for a given task", In FAYYAD, U.M., and UTHURUSAMY, R., editors Proceedings First International Conference on Knowledge Discovery, Data Mining, AAAI Press, Menlo Park, CA, 1995.
- [88] CHERKASSKY, V., FRIEDMAN, J.H., WECHSLER, H., "From Statistics to Neural Networks", Theory and Pattern Recognition Applications, NATO ASI Series F, Vol. 136, 1993.
- [89] BAUER, M., General Regression Neural Network for Technical Use, Master Thesis, University of Wisconsin-Madison, 1995.
- [90] SPECHT, D.F., Probabilistic Neural Net, Neural Networks, Vol 3 pp. 109-118, 1990.
- [91] TÜRKOĞLU, İ., Örüntü Tanıma Sistemleri (Ders Notları), Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, 2003.
- [92] SPECHT, D.F., "A General Regression Neural Network", IEEE Transactions on Neural Networks, Vol. 2 pp. 568-576, 1991.
- [93] ZAKNICH, A., "A Vector Quantisation Reduction Method for the Probabilistic Neural Network", IEEE International Conference on Neural Networks, Vol. 2, pp.1117-1120, 1997.
- [94] PARZEN, E., "On estimation of a probability density function and mode", The Annals of Mathematical Statistics, vol. 33, pp. 1065-1076, 1962.

- [95] AGARWAL, R., GOTMAN, J., “Computer-Assisted Sleep Staging”, IEEE Transactions on Biomedical Engineering, December 2001, 48 (12): 1412-1423.

ÖZGEÇMİŞ

Murat Yıldız, 10.04.1977 de Siirt'te doğdu. İlk ve orta eğitimini Siirt'te, lise eğitimini Van'da tamamladı. 1994 yılında Van Özel Serhat Fen Lisesi'nden mezun oldu. Aynı yıl Sakarya Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Bölümüne girdi ve 1999 yılında mezun oldu. 2000 yılı Temmuz ayında aynı bölümde araştırma görevlisi olarak çalışmaya başladı. 1999-2002 yılları arasında Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Müh. Anabilim dalı Elektronik bilim dalında "Fotovoltaik Pil ve Modüllerin PSPICE ile Benzetimi" üzerine Yüksek Lisans yaptı. Güneş enerjisi, hidrojen enerjisi, mühendislik eğitimi, mühendislik etiği, temel elektronik elemanların pspice ile modellenmesi konularında çalışmalarda bulundu. 2003 yılında doktora eğitimine başladı. Doktora çalışmasında elektroensefalogram üzerinde çalıştı. Tıp elektroniği ve Biyomedikal işaretlerin işlenmesi ve sınıflandırılması konularında çalışmaları devam etmektedir. Evli ve bir çocuk babasıdır.