



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



DOKTORA TEZİ

**EEG SİNYALLERİNİN GÖRGÜL KİP AYRIŞIM YÖNTEMİ
İLE ANALİZİ**

Ahmet MERT

Biyomedikal Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

Danışman

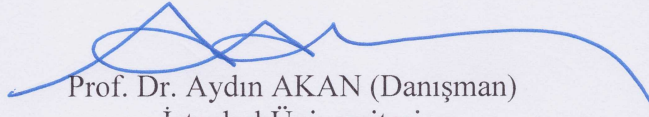
Prof. Dr. Aydın AKAN

Mart, 2015

İSTANBUL

Bu çalışma 12/03/2015 tarihinde aşağıdaki jüri tarafından Biyomedikal Mühendisliği Anabilim Dalı'nda Doktora Tezi olarak kabul edilmiştir.

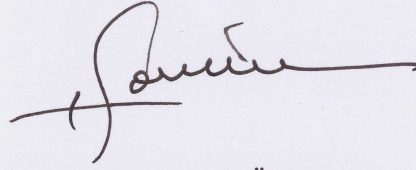
Tez Jürisi:



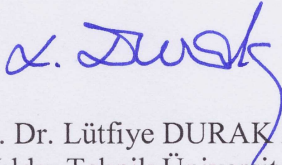
Prof. Dr. Aydın AKAN (Danışman)
İstanbul Üniversitesi
Mühendislik Fakültesi



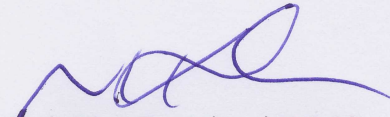
Prof. Dr. Sadık KARA
Fatih Üniversitesi
Mühendislik Fakültesi



Prof. Dr. Gökhan UZGÖREN
Gedik Üniversitesi
Mühendislik Fakültesi



Doç. Dr. Lutfiye DURAK ATA
Yıldız Teknik Üniversitesi
Elektrik-Elektronik Fakültesi



Yrd. Doç. Dr. Niyazi KILIÇ
İstanbul Üniversitesi
Mühendislik Fakültesi

Bu alıřma İstanbul Üniversitesi Bilimsel Arařtırma Projeleri Yürütücü Sekreterliđinin 35830 numaralı projesi ile desteklenmiřtir.

ÖNSÖZ

Tez çalışmalarım boyunca her türlü desteğini esirgemeyen değerli hocam Prof. Dr. Aydın AKAN'a en içten dileklerle teşekkür ederim. Tez izleme komitesinde yer alan ve çalışmada değerli fikirleri ile katkıda bulunan Doç. Dr. Lütfiye DURAK ATA'ya ve Yrd. Doç. Dr. Niyazi KILIÇ'a en içten dileklerle teşekkür ederim.

Doktora eğitimim ve tez çalışmalarım boyunca desteğini esirgemeyen eşim Melek KAYMAZ MERT'e ve tüm eğitim-öğretim hayatım boyunca öğrenmeye teşvik eden merhum babama şükranlarımı sunarım.

Mart, 2015

Ahmet MERT

İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	i
İÇİNDEKİLER	ii
ŞEKİL LİSTESİ.....	iv
TABLO LİSTESİ	viii
SİMGE VE KISALTMA LİSTESİ	ix
ÖZET.....	xii
SUMMARY	xiii
1. GİRİŞ.....	1
1.1. TEZİN KATKILARI	3
2. GENEL KISIMLAR	5
2.1. ELEKTROENSEFALOGRAFİ.....	5
2.2. EPİLEPSİ VE EEG İŞARETLERİ İLE TEŞHİSİ.....	8
2.3. GÜRÜLTÜ TEMİZLEME	14
2.4. DUYGU DURUM VE EEG SİNYALLERİ İLE ANALİZİ.....	15
3. MALZEME VE YÖNTEM	19
3.1. GÖRGÜL KİP AYRIŞIMI	19
3.2. ÇOK DEĞİŞKENLİ GÖRGÜL KİP AYRIŞIMI.....	23
3.3. GÖRGÜL KİP AYRIŞIMI SÜZGEÇ YAPISI ÖZELLİKLERİ.....	25
3.4. HİLBERT-HUANG DÖNÜŞÜMÜ.....	27
3.6. EĞİMDEN ARINDIRILMIŞ DALAGALANMA ANALİZİ.....	30
3.7. ORTAK BİLGİ.....	33
3.8. BAĞIMSIZ BİLEŞEN ANALİZİ	33
3.9. YAPAY ÖĞRENME.....	34
3.9.1. Eğitici-siz Öğrenme	34
3.9.1.1. Hiyerarşik Kümeleme Teknikleri.....	35
3.9.1.2. Uzaklık Ölçüleri	37
3.9.1.3. Hiyerarşik Olmayan Kümeleme Yöntemleri.....	39
3.9.2. Eğitici-li Öğrenme	39
3.9.2.1. Veri Kümesi Bölümleme ve Performans Ölçüm Yöntemleri	41
3.10. EEG VERİ SETLERİ	43
3.10.1. Epileptik Veri Setleri.....	43

3.10.2. EEG Duygu Durum Veri Seti.....	47
4. BULGULAR	52
4.1. GÖRGÜL KİP AYRIŞIMI İLE GÜRÜLTÜ TEMİZLEME.....	52
4.1.1. Görgül Kip Ayrışımı ve Ortak Bilgi Tabanlı Gürültü Temizleme	53
4.1.2. Hilbert-Huang Dönüşümü ve Kümeleme Tabanlı Gürültü Temizleme	59
4.1.3. Eğimden Arındırılmış Dalgalanma Analizi ve Görgül Kip Ayrışımı Tabanlı Gürültü Temizleme	63
4.1.4. Görgül Kip Ayrışımı ve Eğimden Arındırılmış Dalgalanma Analizi İle Elektrokülogram (EOG) Gürültü Temizleme	73
4.2. GÖRGÜL KİP AYRIŞIMI TABANLI EPİLEPTİK EEG ANALİZİ.....	77
4.2.1. Frekans Bölgesi Ölçütü ile Görgül Kip Ayrışımı Tabanlı Epileptik EEG Analizi	78
4.2.2. Zaman Bölgesi Ölçütü ile Görgül Kip Ayrışımı Tabanlı epileptik EEG Analizi	82
4.2.3. Çok Değişkenli Görgül Kip Ayrışımı Tabanlı Epileptik EEG Analizi	85
4.3. EEG SİNYALLERİ İLE DUYGU DURUM ANALİZİ	88
5. TARTIŞMA VE SONUÇ	103
KAYNAKLAR	108
ÖZGEÇMİŞ.....	114

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Uluslararası 10-20 elektrot yerleşimi.	6
Şekil 2.2: Uyku durumuna göre EEG sinyalleri.	8
Şekil 2.3: Sağlıklı EEG ve epileptik EEG dalga şekilleri.	9
Şekil 2.4: 23 kanallı EEG işaretlerinin nöbet halinde değişimi.	9
Şekil 2.5: Örüntü tanıma blok şeması.	10
Şekil 2.6: Sağlıklı ve epileptik EEG güç izgesel yoğunlukları.	12
Şekil 2.7: Tek seviyeli ayırık dalgacık dönüşümü.	13
Şekil 2.8: İki sınıf için iki boyutlu öznelik vektörü.	13
Şekil 2.9: Bilişsel uyarılma/değerlilik duygu durum haritası.	16
Şekil 2.10: EEG ile duygu durum analizi için EEG kanalları.	17
Şekil 2.11: EEG sinyalleri ile duygu durum sınıflandırma.	18
Şekil 3.1: Eleme algoritmasının grafik gösterimi.	20
Şekil 3.2: Enerji çözünürlük seçenekli görgül kip ayrışımı akış şeması.	22
Şekil 3.3: Bir EEG sinyali ve örnek ÖKF'leri.	23
Şekil 3.4: İki değişkenli GKA örneği.	25
Şekil 3.5: GKA'nın sinyal uyarlamalı süzgeç öbeği yapısı örneği.	26
Şekil 3.6: ÇDGKA süzgeç yapısı.	27
Şekil 3.7: EEG sinyalinin Hilbert-Huang İzgesi. (a) Anlık frekans (b) Anlık genlik.	29
Şekil 3.8: Eğimden arındırılmış dalgalanma analizi grafiksel ifadesi.	31
Şekil 3.9: EADA üsteli tespiti için kullanılabilen örnek doğrusal aralıklar.	32
Şekil 3.10: EADA üsteli açılı tespiti için tek doğrusal aralık örneği.	32
Şekil 3.11: Kümeleme yöntemleri çeşitleri.	35
Şekil 3.12: Kümeleme bağlantı teknikleri. (a) tek (b) tam (c) grup bağlantı.	36
Şekil 3.13: Dendogram örneği.	38
Şekil 3.14: $k=5$ için yakın komşu algoritması sonucu.	40

Şekil 3.15: Tek gizli katmanlı YSA mimarisi.	41
Şekil 3.16: 5-kat çapraz doğrulama örnek alt kümeleri.	42
Şekil 3.17: Bonn Üniversitesi EEG kayıt örnekleri.	44
Şekil 3.18: Oslo Üniversitesi EEG kayıt örnekleri.	45
Şekil 3.19: CHB-MIT 23 kanallı EEG örnek kayıtları.	46
Şekil 3.20: DEAP EEG veri seti için video klip seçimi.	47
Şekil 3.21: DEAP veri seti için oluşturulan kayıt ortamı.	48
Şekil 3.22: Öz değerlendirme için kullanılan modeller.	49
Şekil 3.23: Veri seti çalışmasında kullanılan sınıflar.	49
Şekil 4.1: EEG sinyalleri ve ÖKF'leri.	54
Şekil 4.2: Gürültüsüz EEG kayıtlarının OB skorları.	55
Şekil 4.3: 20 dB SNR EEG kayıtları için OB ve eşik değerleri.	55
Şekil 4.4: 20 dB epileptik ve normal EEG ÖKF'leri.	56
Şekil 4.5: 20 dB EEG için gürültü temizleme sonuçları.	57
Şekil 4.6: 0 db EEG kayıtları için OB ve eşik değerleri.	57
Şekil 4.7: 0 dB EEG için gürültü temizleme sonuçları.	58
Şekil 4.8: EEG sinyallerinin Hilbert-Huang Dönüşümü.	60
Şekil 4.9: 20 dB EEG için eşik değerleri (a) normal EEG (b) epileptik EEG.	61
Şekil 4.10: 0 dB EEG sinyalleri için eşik değerleri (a) normal EEG. (b) epileptik EEG.	61
Şekil 4.11: 0 db epileptik EEG sinyalinin ilk dört ÖKF'si.	62
Şekil 4.12: 20 dB EEG sinyalleri için yöntem sonuçları.	62
Şekil 4.13: 0 dB EEG sinyalleri için yöntem sonuçları.	63
Şekil 4.14: 0 dB parçalı fonksiyon ve ÖKF'leri.	65
Şekil 4.15: 0 dB parçalı fonksiyon ÖKF'leri için EADA eğimleri.	65
Şekil 4.16: GKA-EADA tabanlı gürültü temizleme yöntemi karşılaştırma.	66
Şekil 4.17: 20 dB parçalı fonksiyon ve ÖKF'leri.	67
Şekil 4.18: 20 dB parçalı fonksiyon için EADA eğimleri.	68
Şekil 4.19: GKA-EADA gürültü temizleme karşılaştırması.	68

Şekil 4.20: Taban kayması eklenen 0 dB epileptik EEG ve ÖKF'leri.	69
Şekil 4.21: 0 dB epileptik için EADA eğimleri ve eşik aralığı.	70
Şekil 4.22: Epileptik EEG gürültü temizleme sonuçları.....	71
Şekil 4.23: Artığın taban kayması temizleme üzerine etkisi.	71
Şekil 4.24: Kullanılan diğer sentetik sinyaller.....	72
Şekil 4.25: C3 kanal EEG sinyali.	74
Şekil 4.26: v-EOG kanal gürültüsü.....	75
Şekil 4.27: v-EOG gürültüsü içeren C3 kanalının ÖKF'leri.	76
Şekil 4.28: v-EOG içeren C3 kanal ÖKF'leri için EADA eğimleri.	76
Şekil 4.29: C3 EEG kanalından temizlenen v-EOG gürültüsü.....	77
Şekil 4.30: EEG güç izgesel yoğunlukları. (a) epileptik (b) normal.....	79
Şekil 4.31: EEG sinyallerine ait ÖKF güç dağılımları.	80
Şekil 4.32: GKA frekans düzlemi ölçütü ile epileptik EEG analizi.	81
Şekil 4.33: 23 kanallı EEG kayıtları için GKA frekans bölgesi sonuçları.	81
Şekil 4.34: EEG kanallarında epileptik sinyalin baskın olduğu kanallar.	82
Şekil 4.35: EEG sinyalleri için ÖKF'lerin EADA eğimleri.	83
Şekil 4.36: GKA-EADA tabanlı epileptik EEG analiz sonuçları.	84
Şekil 4.37: 23 kanallı EEG için GKA-EADA tabanlı epileptik EEG analizi.	85
Şekil 4.38: Epileptik ÖKF'ler ile güç izgesel yoğunluk benzerliği.....	87
Şekil 4.39: Normal ÖKF'ler ile güç izgesel yoğunluk benzerliği.	87
Şekil 4.40: ÇDGKA ile epileptik ve normal EEG için analiz sonuçları.....	88
Şekil 4.41: Duygu durum EEG kanalları.....	90
Şekil 4.42: Önerilen duygu durum sınıflandırma diyagramı.	92
Şekil 4.43: Özniteliklerin BBA sonunda elde edilen öz değerleri.....	94
Şekil 4.44: Uyarılma/değerlik bilişsel duygu durum haritası.	94
Şekil 4.45: YSA ile yüksek-düşük uyarılma doğruluk sonucu.....	95
Şekil 4.46: YSA ile yüksek-düşük değerlilik doğruluk sonucu.....	96
Şekil 4.47: k-NN kullanılarak yüksek/düşük uyarılma sonuçları.....	97

Şekil 4.48: k-NN kullanılarak yüksek/düşük değerlik sonuçları.....	98
Şekil 4.49: Seçilen dört duygu.....	99
Şekil 4.50: Dört duygu sınıflandırma akış şeması.....	100
Şekil 4.51: Dört duygu sınıflandırma doğruluk oranı.....	101

TABLO LİSTESİ

	Sayfa No
Tablo 2.1: EEG işaretlerinin bant aralıkları.	7
Tablo 3.1: EADA üsteli özel değer aralıkları.....	32
Tablo 3.2: Karışıklık matrisi.	43
Tablo 3.3: DEAP EEG duygu durum veri seti özellikleri.....	50
Tablo 4.1: GKA ve OB Tabanlı Gürültü Temizleme Sonuçları.	58
Tablo 4.2: Gürültü Temizleme Sonuçları.....	63
Tablo 4.3: GKA-EADA gürültü temizleme kıyaslama tablosu.	72
Tablo 4.4: Duygu durum tespiti için elde edilen öznelilikler.....	93
Tablo 4.5: ÇDGKA ve YSA yöntemlerinin kıyaslanması.	96
Tablo 4.6: ÇDGKA ve k-NN yöntemlerinin Kıyaslanması.	98
Tablo 4.7: Duygu durum sınıflandırma karşılaştırması.	102

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
$a(t)$: Özgül kip fonksiyonun anlık genliği
A	: Karıştırma matrisi
A_1	: Birinci seviye dalgacık dönüşümü ayrıştırma katsayıları
α	: Eğimden arındırılmış dalgalanma analizi eğimi
$d(A,B)$: A ve B kümeleri arası uzaklık
D	: Benzerlik matrisi/vektörü
D_1	: Birinci seviye dalgacık dönüşümü detay katsayıları
$D_{KL}(X \ Y)$: Bağlı entropi
$D_{EEG,Ep}$: Analiz edilen EEG ile referans epileptik EEG uzaklığı
$D_{EEG,No}$: Analiz edilen EEG ile referans normal EEG uzaklığı
$f(t)$: Özgül kip fonksiyonu anlık frekansı
$F(n)$: Karekök ortalama dalgalanma
f_s	: Örnekleme frekansı
$h(n)$: Alt ve üst zarf ortlaması
H	: Hurst üsteli
$H(x)$: x rasgele değişkenin entropisi
$H(X Y)$: X ile Y rasgele değişkenleri için koşullu entropi
$I(X;Y)$: X ve Y dağılımları için ortak bilgi
k	: k yakın komşu
L	: Özgül kip fonksiyonu adedi
m_i	: Yerel alt noktalar
$m(n)$: Alt zarf
M	: EEG kanal adedi
M_i	: Yerel üst noktalar
$M(n)$: Üst zarf
N	: Örnek adedi
$P_x(f)$: Güç izgesel yoğunluğu
$\hat{P}_x(f)$: Periodogram
$\hat{P}^{EEG}(f)$: Analiz edilen EEG ÖKF'leri güç izgesel yoğunluğu
$\hat{P}^{No}(f)$: Referans normal EEG ÖKF'leri güç izgesel yoğunluğu
$\hat{P}^{Ep}(f)$: Referans epileptik EEG ÖKF'leri güç izgesel yoğunluğu
$\hat{P}^{EEG}(f)$: Analiz edilen EEG ÖKF'leri güç izgesel yoğunluğu
$\hat{P}^{EEG}(f)$: Analiz edilen EEG ÖKF'leri güç izgesel yoğunluğu
P_i^M	: EEG M . kanal i . ÖKF gücü

P_i / P_M	: ÖKF'nin kanal gücüne oranı
\hat{P}_i^M	: EEG M . kanal i . ÖKF güç izgesel yoğunluğu
$P_{i_{Fark}}^M$: Sağ sol simetrik kanal güç
P_i^M / P_i^{M+8}	: Sağ sol simetrik kanal güç oranı
$qResol$: Özgül kip fonksiyonu ile sinyal enerji oranı
$qResid$: Artık ile sinyal enerji oranı
$r(n)$: Artık
$R_X(\tau)$: Öz ilinti fonksiyonu
S	: Kaynak matrisi
SD	: Standart sapma tabanlı durdurma kriteri
T	: Dalgacık dönüşümü üniversal eşikleme değeri
w	: Yapay sinir ağı ağırlık katsayıları
$\bar{x}(t)$: Gürültüsüz sinyal
$x(t)$: Gürültü içeren / gözlemlenen sinyal
$\tilde{x}(n)$: Gürültüden arındırılmış sinyal
$x_{EEG}(n)$: ÇDGKA ile analiz edilecek EEG sinyali
$x_{No}(n)$: ÇDGKA'ya uygulanan referans normal EEG sinyali
$x_{Ep}(n)$: ÇDGKA'ya uygulanan referans epileptik EEG sinyali
$X(m, w)$: Kısa zamanlı Fourier dönüşümü
$X_w(a, b)$: Sürekli dalgacık dönüşümü
$y(k)$: Entegre edilmiş zaman serisi
$y_n(k)$: Entegre edilmiş zaman serisi eğri uydurma
$\varepsilon(n)$: Elektrookülogram gürültüsü
Σ	: \bar{x} ve \bar{y} vektörü için kovaryans matrisi
μ	: Zaman serisinin ortalaması
σ	: Standart sapma
$\eta(t)$: Gauss gürültüsü
$\rho T(c)$: Sert eşikleme
θ	: Eşik değeri
Δt	: Örnekleme aralığı
$\psi(t)$: Ana dalgacık fonksiyonu
$\varphi(n)$: Özgül kip fonksiyonu
$\varphi_H(t)$: Özgül kip fonksiyonunun Hilbert dönüşümü
$\varphi_A(t)$: Özgül kip fonksiyonunun analitik versiyonu
$\varphi_i^{EEG}(n)$: ÇDGKA ile analiz edilecek EEG sinyali ÖKF'leri
$\varphi^{Ep}(n)$: ÇDGKA ile epileptik EEG özgül kip fonksiyonları
$\varphi^{No}(n)$: ÇDGKA ile normal EEG özgül kip fonksiyonları

$\phi(t)$: Özgül kip fonksiyonu anlık fazı

Kısaltmalar	Açıklama
ADD	: Ayrık dalgacık dönüşümü
AF	: Anlık frekans
AGS	: Alçak geçiren süzgeç
BBA	: Bağımsız bileşen analizi
CHB-MIT	: Çok kanallı EEG veri seti.
ÇDGKA	: Çok değişkenli görgül kip ayrışımı
DD	: Dalgacık dönüşümü
DEAP	: EEG duygu durum veri seti
DFA	: Detrended fluctuation analysis
EADA	: Eğimden arındırılmış dalgalanma analizi
EEG	: Elektroensefalogram
EKG	: Elektrokardiogram
EMD	: Empirical mode decomposition
EMG	: Elektromiyogram
EOG	: Elektrokülogram gürültüsü
FD	: Fourier dönüşümü
fGn	: Kesirli Gauss gürültüsü
FM	: Frekans modülasyonu
GIY	: Güç izgesel yoğunluğu
GKA	: Görgül kip ayrışımı
GM	: Genlik modülasyonu
HD	: Hilbert dönüşümü
h-EOG	: Yatay elektrokülogram gürültüsü
HHD	: Hilbert-Huang dönüşüm
HHI	: Hilbert-Huang izgesi
HHT	: Hilbert-Huang transform
IMF	: Intrinsic mode function
İDGKA	: İki değişkenli görgül kip ayrışımı
KKA	: Kör kaynak ayrışımı
k-NN	: k en yakın komşu
KZFD	: Kısa zamanlı Fourier dönüşümü
MEMD	: Multivariate empirical mode decomposition
MI	: Mutual information
MSE	: Ortalama karesel hata
OB	: Ortak bilgi
ÖKF	: Özgül kip fonksiyonu
SDD	: Sürekli dalgacık dönüşümü
SNR	: Sinyal/gürültü oranı
ÜDGKA	: Üç değişkenli görgül kip ayrışımı
v-EOG	: Dikey elektrokülogram gürültüsü
YGS	: Yüksek geçiren süzgeç
YSA	: Yapay sinir ağı

ÖZET

DOKTORA TEZİ

EEG SİNYALLERİNİN GÖRGÜL KİP AYRIŞIM YÖNTEMİ İLE ANALİZİ

Ahmet MERT

İstanbul Üniversitesi

Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Aydın AKAN

Görgül kip ayrışımı (GKA) doğrusal ve durağan olmayan sinyaller için önerilen yeni bir sinyal işleme yöntemidir. Sinyali kendi içinden elde ettiği özgül kip fonksiyonların (ÖKF) birleşimi olarak temsil eden, algoritma tabanlı ve sinyal uyarlamalı bir yöntemdir. Elde edilen ÖKF'lerin zaman ve frekans bölgesi özellikleri, sinyal hakkında önemli bilgiler vermektedir. Önerilen GKA tabanlı gürültü temizleme yöntemleri ile gürültülü elektroensefalogram (EEG) kayıtlarından ve çeşitli sentetik sinyallerden elde edilen ÖKF'lerin ortak bilgi (OB), Hilbert-Huang dönüşümü (HHD) ile hiyerarşik kümeleme ve eğimden arındırılmış dalgalanma analizi (EADA) ile yoğun olarak gürültü içeren bileşenlerin belirlenmesi hedeflenmiştir. Epileptik ve normal EEG sinyallerinin GKA tabanlı zaman ve frekans bölgesi ölçüleri ile analiz edilerek atakların tespit edilmesi ise GKA'nın diğer sinyal uyarlamalı yapısı neticesinde önerilen yöntemlerdendir. Çok değişkenli görgül kip ayrışımı (ÇDGKA) ile epileptik EEG analizi için geliştirilmiş yeni bir yöntem önerilmiştir. Normal ve epileptik EEG sinyallerinin sınıflandırması karmaşık yapay öğrenme algoritmaları ve çok boyutlu öznitelik vektörleri kullanmadan, önerilen yöntemle elde edilen sayısal parametreler yardımı ile mümkün olmaktadır. EEG sinyallerinden duygu durum tespiti için ÇDGKA yöntemine dayanan bir yaklaşım önerilmiştir. Bu yöntemde çok kanallı EEG sinyallerine ait ÖKF'lere çeşitli sinyal işleme yöntemleri uygulanarak elde edilen öznitelikler ile duygusal durumun belirlenebilmesi amaçlanmıştır. Sonuçlar iki boyutlu bilişsel duygulanım haritası referans alınarak test edilmiştir. Böylece yeni bir sinyal işleme yöntemi olan GKA tabanlı özgün ve yeni yöntemler EEG sinyallerinin analizi için önerilmiştir.

Mart 2015, 113 sayfa.

Anahtar kelimeler: Elektroensefalogram, görgül kip ayrışımı, epilepsi, duygu durum.

SUMMARY

Ph.D THESIS

**ANALYSIS OF EEG SIGNALS USING EMPIRICAL MODE
DECOMPOSITION**

Ahmet MERT

İstanbul University

Institute of Graduate Studies in Science and Engineering

Department of Biomedical Engineering

Supervisor: Prof. Dr. Aydın AKAN

Empirical mode decomposition (EMD) has been recently suggested method to analyze non-linear and non-stationary signals. It is an algorithm based and adaptive decomposition method to represent the signal as the sum of the intrinsic mode functions (IMFs). Thus, time and frequency-domain properties of the extracted IMFs provide important properties about the signal. For EMD based denoising, mutual information (MI), Hilbert-Huang transform (HHT) with hierarchical clustering and detrended fluctuation analysis based metrics are evaluated for noise reduction from electroencephalogram (EEG) and various synthetic signals. Time and frequency domain metrics of the EMD for EEG analysis are the other proposed methods based on the data driven property of the EMD. Multivariate empirical mode decomposition (MEMD) is also suggested as an enhanced method for EEG analysis. The obtained scalar results from the metrics enable to analyze and detect epileptic seizure without using complex machine learning algorithms and feature vectors. For emotion recognition using multi-channel EEG signals, it is proposed that IMFs of the EEG signals decomposed using MEMD are analyzed deploying various signal processing methods. The results are evaluated based on the cognitive emotional state. Therefore, originally proposed EEG analysis methods are suggested using EMD.

March 2015, 113 pages.

Keywords: Electroencephalography, empirical mode decomposition, epilepsy, emotion recognition.

1. GİRİŞ

Beyin sinir hücrelerinin elektrik aktivitesinin elektroensefalografi cihazı yardımıyla elde edilen kayıtlarına elektroensefalogram (EEG) denir. Kafatası üzerindeki saçlı deriye monte edilen tek veya çok kanallı elektrotlar ile kayıtlar elde edilir. Bu sebeple invazif olmayan yöntem olup beyine ait fonksiyonların analizi veya hastalıkların teşhisinde başarıyla kullanılmaktadır [1–3].

Epilepsi, bir grup nöronun anormal aktivitesi sonucunda oluşan bilinç kaybı, dengesiz vücut hareketleri ve kasılmalara neden olan kronik bir rahatsızlıktır. EEG kayıtlarının analizi ile epilepsi tespiti ve tipi hakkında bilgi edinilmektedir. Bu yöntem yapısal, görüntüleme yöntemleriyle (bilgisayarlı tomografi ve manyetik rezonans) kıyaslandığında beyin o anki fonksiyonel durumunu yansıtması sebebiyle güncelliğini ve önemini korumaktadır. Özellikle yapısal inceleme yöntemlerinde tespit edilebilen bir patolojik bulgunun olmadığı hastalarda EEG'nin önemi daha da artmaktadır. Nöbetin oluşma zamanını kestirmek mümkün olmadığı için uzun süreli belki de günlerce kayıt alınması gerekmektedir [4].

EEG kayıtlarının uzun süreli olması analiz sürecinde sinyal işleme ve yapay öğrenme tekniklerinin kullanımını zorunlu kılmaktadır [2]. Her tanılama sisteminin başarısı ayırt edici özneliliğin çıkartılması sürecinde sinyal hakkında yeterli bilgiye ve buna uygun sinyal işleme tekniklerinin kullanımına bağlı olarak değişmektedir. EEG sinyalleri zaman bölgesinde ortalama ve varyans [4] gibi istatistiksel özellikler kullanılarak analiz edilebilirken, Lyapunov üsteli [5], fraktal boyutu [6] ve entropi [7] gibi daha karmaşık sayılabilecek yöntemler yardımıyla başarılı biçimde analiz edilebilmektedir. Bu zaman bölgesi yöntemlerine ek olarak istatistiksel zaman bölgesi metotları arasında sayılan temel bileşen analizi ve bağımsız bileşen analizi gibi teknikler ayırt edici özneliliklerin çıkarılmasında gelişmiş özellikler arasında sayılabilir [2]. Frekans bölgesinde Fourier dönüşümü (FD) tabanlı güç spektral yoğunluğu kestirim metotları [1] zaman bölgesi metotlarına göre daha başarılı ve yaygın yöntemler arasında yer almaktadır. Zaman-frekans bölgesi teknikleri bu her iki yöntemin dezavantajlarını azaltmak için çalışılan

teknikler arasında yer almaktadır. Kısa zamanlı Fourier dönüşümü (KZFD)[8] ve özellikle, Dalgacık Dönüşümü (DD) epileptik işaretlerin tespitinde ayrıcalıklı öneme sahiptir [8, 9].

Epileptik atak gibi hastalıkların yanı sıra beyine ait fonksiyonlar neticesinde oluşan elektriksel sinyalleri de analiz etmek mümkün olmaktadır. Bir durum ve olay esnasında komut verme işlemleri kaydedilen EEG sinyalleri ile bilgisayar insan ara yüzü sistemleri [3] ile yapılabılırken, bir görüntü veya müzik dinlerken duygu durum tespiti ve değişimi EEG sinyallerinin analizi ile mümkün olmaktadır [10–12]. Sosyal bilimciler tarafından da kabul edilen bilişsel (*ing. Cognitive*) duygulanma yaklaşımını temel alan iki boyutlu duygu haritası temel alınarak uyarılma (*ing. Arousal*) ve değerlilik (*ing. Valence*) seviyeleri ile duygu tespit edilmeye çalışılır [11]. Duygu durum tespiti veya sınıflandırma için öznitelik çıkarma işlemleri temel olarak çok kanallı EEG sinyallerinin frekans uzayındaki özellikleri ile elde edilmektedir. Alfa (8-15 Hz) ve Beta (16-31 Hz) bantlarındaki sinyal güç oranları frekans bölgesi için sıklıkla kullanılan yöntemdir [10, 11]. Yüksek dereceli sıfır geçiş sayısı ve dalgacık dönüşümü duygu durum tespiti için önerilen yöntemler arasında gösterilmiştir [12, 13]. Çok kanallı EEG sinyallerine uygulanan birden çok sinyal işleme yöntemi ile yüksek boyutlu (genellikle yüz ve üzeri) öznitelik vektörlerinin yapay sinir ağı (YSA) gibi yapay öğrenme algoritmaları yardımıyla sınıflandırılması neticesinde duygu durum sınıflandırması yapılabilmektedir.

Görgül Kip Ayrışımı (GKA) durağan olmayan sinyallerin analizi için önerilen sinyal uyarlamalı yeni bir yöntemdir [14]. Sinyali kendini oluşturan içsel genlik modüleli (GM) ve frekans modüleli (FM) sıfır ortalamalı öz kip fonksiyonları (ÖKF) şeklinde açarak birden çok bileşen içeren sinyalin gereksinim duyulan bileşenini analiz etme imkânı sağlamaktadır [15]. Bu açıdan, durağan olmayan EEG sinyallerinin analizinde farklı, başarılı ve özgün bir yöntem olarak kullanılması irdelenmiştir. Böylece, epilepsi ve duygu durum tespiti için EEG sinyallerinin GKA tabanlı sinyal işleme ve öznitelik çıkarma bu tezin kapsamında verilmiştir. Klasik sinyal işleme yöntemleri ve diğer analiz yöntemleri ile birlikte kullanılarak GKA'nın EEG analizi üzerindeki başarısı incelenmiştir. Bu amaçla, GKA'nın genel özellikleri önerilen gürültü temizleme metotları ile irdelenecek ve elde edilen ÖKF'lerin özelliklerinden bahsedilecektir. Diğer bölümde ise önerilen GKA tabanlı epileptik EEG analizinin zaman ve frekans uzayında önerilen yöntemlerin

temelleri izah edilip tek kanallı ve çok kanallı EEG veri setleri kullanılarak simülasyonları gerçekleştirilecektir. Duygu durum tespiti için ise GKA ile elde edilen ÖKF'lerin frekans ve zaman bölgesinde öznitelikleri elde edilerek YSA ile sınıflandırılması ele alınacaktır.

1.1. TEZİN KATKILARI

FD veya ADD gibi sinyal işleme yöntemlerinin analitik olması sebebiyle elde edilen katsayıları yorumlamak ve analiz etmek mümkün olmaktadır. Fakat GKA'nın algoritma tabanlı ve sinyal uyarlamalı yöntem olması sebebiyle elde edilen ÖKF'ler için herhangi bir ön bilgiye sahip olunamamaktadır. Bu sebeple, bir sinyalin GKA ile analizi için temel olarak kullanılan yöntem, ayrıştırma sonrası ÖKF'lerin analizi esasına dayanmaktadır.

ÖKF'lerin analiz edildiği en temel sinyal işleme yöntemi olarak GKA tabanlı gürültü temizleme bu tez kapsamında incelenen yöntemlerden biridir. GKA'ya uygulanan sinyallerin ve bu sinyallerin ÖKF'leri ile olan ilişkisi veya benzerliği analiz edilmiştir. Gürültülü sinyalin GKA yardımı ile ÖKF'lerinin elde edilmesi ve bunlar içinde gürültülü ÖKF'lerin tespit edilmesi GKA tabanlı gürültü temizleme yönteminin temelini oluşturmaktadır. Bu amaçla, beyaz gürültü içeren sentetik ve EEG sinyalleri ile EOG gürültüsü içeren EEG sinyallerinden GKA yardımı ile gürültü temizleme çalışılmıştır. Gürültülü sinyallerin GKA sonrasında ÖKF'lerin tespiti için güvenilir analiz yöntemleri neticesinde elde edilen ölçütler yardımı ile eşiklendirme yapılarak gürültünün bileşeni olarak tespit edilen ÖKF'ler yeniden oluşturma işlemine dahil edilmeyerek diğer ÖKF'ler ile gürültüsüz sinyal kestirilmiştir. Sinyal ile ÖKF'leri arasında ortak bilgi (*ing. mutual information*) tabanlı, Hilbert-Huang dönüşümü (*ing. Hilber-Huang Transform*) ve hiyerarşik kümeleme tabanlı, eğimden arındırılmış dalgalanma analizi (*ing. detrended fluctuation analysis*) tabanlı eşik belirleme yöntemleri önerilmiştir ve sonuçları irdelenmiştir. Böylece, ÖKF'lerin elde edilmesi sonrasında analizi gerçekleştirilmiştir.

EEG sinyalleri kullanılarak epileptik atak tespiti için GKA tabanlı yeni bir yöntem bu tez içinde incelenen ikinci konudur. GKA ve çok değişkenli görgül kip ayrışımı (ÇDGKA) ile tek ve çok kanallı EEG sinyalleri için analiz yöntemi önerilmiştir. GKA ve ÇDGKA yöntemlerinin sinyal uyarlamalı yapısı sebebiyle oluşan süzgeç öbeği yapısı EEG sinyallerinin analizi için önerilen yöntemlerin temelini oluşturmaktadır. Normal EEG sinyallerinden atak anındaki EEG sinyallerinin elde edilmesi ile değişen süzgeç öbeği

yapısı neticesinde her iki durumdaki ÖKF'lerin özellikleri farklı kılmaktadır. Bu değişim ÖKF'lerin güç dağılımlarının analizi ile tespit edilebilmektedir. Eğimden arındırılmış dalgalanma analizi yardımı ile ÖKF'lerin özilinti özellikleri (istatistiki özelliklerinin değişimi hızı) derecelendirilerek normal ve epileptik EEG için farklı değerler verdiği gözlemlenmiştir. Böylece, her iki GKA tabanlı yöntem neticesinde elde edilen skalar değer ile normal ve epileptik EEG tespiti yapılabilmektedir. Çok boyutlu öznitelik vektörü ve karmaşık yapay öğrenme algoritmaları kullanmadan tek bir değer yardımı ile bu tespit yapılabilmektedir.

EEG sinyalleri kullanılarak duygu durum tespiti ÇDGKA tabanlı önerilen öznitelik çıkarma yöntemi ile çalışılmıştır. 2-boyutlu bilişsel duygu durum haritası referans alınarak uyarılma ve değerlilik seviyelerini EEG sinyalleri kullanarak bulmak için hazırlanan çok kanallı EEG veri seti bu tez kapsamında önerilen ÇDGKA tabanlı sinyal işleme yönteminin başarısını test etmek ve kıyaslamak için kullanılmıştır. FD ve ADD tabanlı yöntemlerle frekans ve zaman-frekans bölgesinde analizlerin sıklıkla kullanıldığı duygu durum tespiti çalışmalarına alternatif olarak ÇDGKA ile daha yüksek başarı elde edebilmek için yeni öznitelik çıkarma yöntemleri önerilmiştir. EEG sinyallerinin ÇDGKA ile elde edilen ÖKF'leri bant güçleri, bant güç oranları, entropi, Hjorth parametreleri, güç izgesel yoğunlukları ile analiz edilerek uyarılma seviyesinin doğru tespiti için önerilmiştir. Sağ ve sol EEG kanalları arasındaki asimetric ÖKF güç farkları, asimetric güç oranları, bağıl entropi, koherans, ve çapraz ilinti ile değerlilik seviyelerine ait başarı artırmak hedeflenmiştir. Ayrıca, tüm 32 EEG kanalı yerine ön lobda bulunan 18 kanal kullanılarak işlem yükünü azaltarak başarının yükseltilmesi üzerine de yoğunlaşmıştır. Böylece, bu veri setini kullanarak yapılan diğer yüksek/düşük uyarılma ve yüksek/düşük değerlilik seviyeleri tespit çalışmaları ile kıyaslanarak önerilen ÇDGKA tabanlı öznitelik çıkarma yönteminin başarısı gösterilmiştir.

2. GENEL KISIMLAR


2.1. ELEKTROENSEFALOGRAFI

Elektroensefalografi (EEG) beyin aktivitesi neticesinde oluşan elektriksel sinyallerin incelenmesini sağlayan yöntemdir. Elektroensefalogram olarak adlandırılan cihaz yardımı ile genellikle saçlı deriye jel sürülerek bağlanan elektrotlar yardımı ile EEG sinyalleri kaydedilmektedir. Kafatası içerisine yerleştirilen elektrot tipleri ile belirli bölge için detaylı kayıtlar alınmasına olanak sağlayan tipleri olmasına rağmen saçlı deriye uygulanan elektrotlar ile elde edilen EEG kayıtları invazif olmaması sebebiyle tercih edilmektedir. EEG kayıtları, uyku analizi [16], epilepsi [1, 17], anestezi derinliği [18] ve bilgisayar insan ara yüzü sistemleri [3] analizi için kullanılmaktadır.

EEG, milyonlarca sinir hücrelerin aktivitesi sonucu oluşan aksiyon potansiyellerinin beyin zarı üzerinde oluşturduğu elektrik potansiyelini kaydetme esasına dayanmaktadır. Bu potansiyeller saç derisi yüzeyinden veya dahili (*ing. intracranial*) yöntem olarak adlandırılan iki yöntem ile kaydedilmektedir [19]. Dahili kayıtlar cerrahi müdahale gerektiren kafatası altına yerleştirilen elektrotlar ile yapılabilirken, yüzeysel kayıtlar gündelik yaşamı bozmadan mobil cihazlar yardımı ile alınabilmektedir.

Gümüş/gümüş-klorür malzemeden üretilen elektrotlar uluslararası standartlar çerçevesinde belirlenen pozisyonlarda saç derisine iletkenliği artırıcı jel sürülerek monte edilir. Yaygın olarak kabul gören sistem uluslararası 10-20 elektrot pozisyon sistemidir. Bu adın verilmesinin sebebi, göz ile burun birleşim noktası (*ing. nasion*) ve boyun ile kafatası birleşim noktası (*ing. inion*) arasında kalan mesafenin %10'u ve %20'si aralıklarla elektrotların yerleştirilmesidir. Böylece 75 elektrot pozisyonu elde edilebilir fakat sıklıkla 8-32 kanal klinik çalışmalar için yeterli görülmektedir [20]. Bu sistem için elektrot yerleşimi Şekil 2.1 [21]'de gösterilmiştir.

Elektrotlar EEG cihazı için kanal olarak isimlendirilir ve her biri ayrı ayrı kuvvetlendirici girişine uygulanır, gürültüden arındırılır ve kâğıda çizdirilir veya elektronik olarak ileri analiz yöntemlerine uygulanmak üzere saklanır.



Şekil 2.1: Uluslararası 10-20 elektrot yerleşimi.

10-20 sistemine göre elektrot yerleşimi değişmemekle birlikte referans noktası değişiklik gösterebilmektedir. Dört adet referans yöntemi bulunmaktadır;

- Sıralı montaj (*ing. sequential montage*): Her kanal komşu kanal ile farkı alınarak referans belirlenir. Böylece Fp1-F3 kanalı, bu iki kanal arasındaki voltaj farkını ifade eder.
- Referans montaj (*ing. referential montage*): Tüm kanallar için ortak referans noktası belirlenir. Genellikle kulak memesi referans noktası olarak seçilir.
- Ortalama referans montajı (*ing. average reference montage*): Tüm kanalların ortalaması her bir kanalın referansı olarak kullanılır.
- Laplasyan montaj (*ing. Laplacian montage*): Kanalın diğer kanalların ağırlıklı ortalamasına göre referans alınması ile elde edilir.

EEG işaretleri 0,5-40 Hz bandında klinik açıdan anlamlı kabul edilmektedir [22]. Motor beceri veya beyin bilgisayar ara yüzü gibi uygulamalar için bu bant genişletilebilmektedir. 100 μ V'u aşmayan bu sinyallerin hastalık teşhisi gibi klinik incelemeler için uygun hale getirebilmesi için güç hattı girişimi çevresel gürültü ve insan vücudundaki diğer sinirsel aktivite neticesinde oluşan elektriksel sinyallerden temizlenmesi gerekmektedir [23, 24]. 50 Hz ya da 60 Hz şebeke gürültüsü basit çentik (bant söndüren) süzgeç yardımı ile temizlenebilirken, elektromiyogram (EMG), elektrokardiyogram (EKG) ve özellikle elektrotlara yakınlığı sebebiyle baskın olarak EEG sinyallerine karışan elektrookulogram (EOG) sinyallerin temizlenmesi [25] için daha karmaşık yöntemler önerilmektedir. Klinik olarak incelenmesi gereken frekans bantları örtüşmediği zaman frekans seçici süzgeçler verimli bir şekilde kullanılmasına rağmen EKG ve özellikle EOG gürültüsü ile incelenmek istenen EEG bandıyla genellikle örtüşmektedir. Bu sebeple bağımsız bileşen analizi (BBA) gibi kaynak ayrışımı tabanlı yöntemler [26] kullanılmaktadır. EEG bantları Tablo 2.1'de verilmiştir.


Tablo 2.1: EEG işaretlerinin bant aralıkları.

EEG Frekans Bantları	Frekans Aralıkları (Hz)
Delta	0.5 - 4
Teta	4 - 8
Alfa	8 - 13
Beta	13 - 30
Gama	30 <

Bu EEG dalgaları genel olarak aşağıdaki durumlarda izlenirler;

- Delta dalgaları: Sağlıklı bireylerde uyku halindeyken ve bebeklerde görülür. Diğer durumlara ağır beyin hasarına işaret edebilir.
- Teta dalgaları: Genellikle gençlerde ve çocuklarda görülür. Yetişkinler için gerginlik ve depresyon hallerinde görülür.
- Alfa dalgaları: Uyanık ve sakin durumlarda görülen EEG dalgasıdır.
- Beta dalgaları: Gerginlik ve zihinsel aktivitenin arttığı durumlarda görülür.
- Gama dalgaları: Klinik uygulamalarda teşhis amaçlı kullanılmaz.

Örnek olarak aşağıdaki Şekil 2.2 [27]'de EEG işaretleri gösterilmiştir.




Şekil 2.2: Uyku durumuna göre EEG sinyalleri.

2.2. EPİLEPSİ VE EEG İŞARETLERİ İLE TEŞHİSİ


Epilepsi beyinde bulunan bir grup nöronun kontrol dışı elektro-kimyasal boşalmasıdır. Bu sinirsel aktivitenin sonucunda oluşan epileptik nöbet ise kısaca beyne ait fonksiyonların bozukluğu olarak ifade edilmektedir. Halk arasında sara hastalığı olarak bilinen epileptik nöbet tipi olan tonik-klonik nöbet en risklisidir [17].

Nöronların oluşturdukları elektrik aktiviteyi ölçen EEG ile epileptik nöbet ve tipi teşhis edilmektedir. Şekil 2.3 [27]'de farklı bantlarda EEG sinyalleri ile epileptik EEG sinyali görülmektedir.

EEG işaretlerinde gözle bile fark edilen bu şekilsel farklılıklar yardımıyla nöbet, nöbetin tipi, zamanı ve gün boyu süren uzun süreli kayıtlar alınması durumunda nöbet sıklığı incelenebilmektedir. Aşağıdaki şekilde epilepsi teşhisi için oluşturulan 23 kanallı EEG veri setinden (CHB-MIT Scalp EEG Database) [28] alınan nöbet halinde işaretlerin değişimi gösterilmiştir.




Şekil 2.3: Sağlıklı EEG ve epileptik EEG dalga şekilleri.



Şekil 2.4: 23 kanallı EEG işaretlerinin nöbet halinde değişimi.

Epileptik nöbetin gerçekleştiği zamanın bilinmemesi sebebiyle bilgisayar destekli teşhis sistemleri analiz için kullanılmaktadır. Örnek olarak 128Hz örnekleme frekansına sahip 32 kanal EEG işaretlerinin 1 saatlik kayıt edilmesiyle yaklaşık 14.75 milyon örnek elde edilmektedir. Gün boyu süren kayıtların (bu örnekte yaklaşık 354 milyon) saklanabilmesi ve hızlı analiz edilmesi gerekmektedir. Bu analiz için örüntü tanıma metotları [29] kullanılmakta olup en temel haliyle işaret işleme tekniklerinin kullanıldığı Şekil 2.5’de verilen öznelik çıkarma işlemleri ve bu özneliklere göre karar veren yapay öğrenme algoritmalarından oluşmaktadır.



Şekil 2.5: Örüntü tanıma blok şeması.

EEG sinyalleri için öznelik çıkarma işlemleri zaman, frekans ve zaman-frekans bölgesi sinyal işleme teknikleri ile yapılmaktadır. Zaman bölgesi için en basit sayılabilecek yöntem işaretin morfolojik özelliklerinin analizidir. Hjorth parametreleri [30]; aktivite, mobilite ve komplekslik ile zaman bölgesinde EEG analizi yapılmıştır.

$$Aktivite = \frac{1}{N} \sum_{n=0}^{N-1} [x(n) - \bar{x}]^2 \quad (2.1)$$

$$Mobilite = \sqrt{\frac{Aktivite \left(\frac{dx}{dt} \right)}{Aktivite}} \quad (2.2)$$

$$Komplekslik = \sqrt{\frac{Mobilite \left(\frac{dx}{dt} \right)}{Mobilite}} \quad (2.3)$$

Diğer zaman bölgesi yöntemlerinden entropi de EEG için öznelik çıkarma yöntemi olarak kullanılmaktadır [7]. Shannon entropi olarak da bilinen bu ölçüt bu sinyal ile ne kadar bilgi taşınabileceğinin veya diğer bakış açısıyla da sinyalin rastgele olma durumunu

gösteren bir ölçüdür. Ayırık rastgele değişken, $\mathbf{x} = [x(0), x(1), \dots, x(N-1)]$ için entropi $H(x)$ aşağıdaki denklem ile bulunur;

$$H(x) = -\sum_{i=0}^{N-1} p_i(x) \log_b p_i(x) \quad (2.4)$$

burada $p(x)$ olasılık yoğunluk fonksiyonunu ve b logaritmik tabanı ifade eder. Frekans bölgesi özellikleri içerisinde Fourier dönüşümü (FD) ve FD tabanlı yöntemler kullanılmaktadır [1]. Epileptik nöbet halinde EEG işaretlerinin bantlarında ve güçlerinde farklılık olmaktadır. Nöbet halindeki yüksek genlikli düşük frekanslı darbe şeklindeki bileşenlerin baskın olarak görülmesi sebebiyle normal ve epileptik EEG işaretleri için farkı güç izgesel yoğunlukları (GİY) görülmektedir. GİY, $P_x(f)$ işaretin öz ilinti fonksiyonu $R_x(\tau)$ 'in Fourier dönüşümü olarak aşağıdaki denklemde verilmiştir.

$$P_x(f) = \int_{-\infty}^{\infty} R_x(\tau) e^{-j2\pi f\tau} d\tau \quad (2.5)$$

Ayrık işaretler için sayısal olarak GİY kestirimi en periyodogram yöntemi ile yapılabilir. Periodogram,

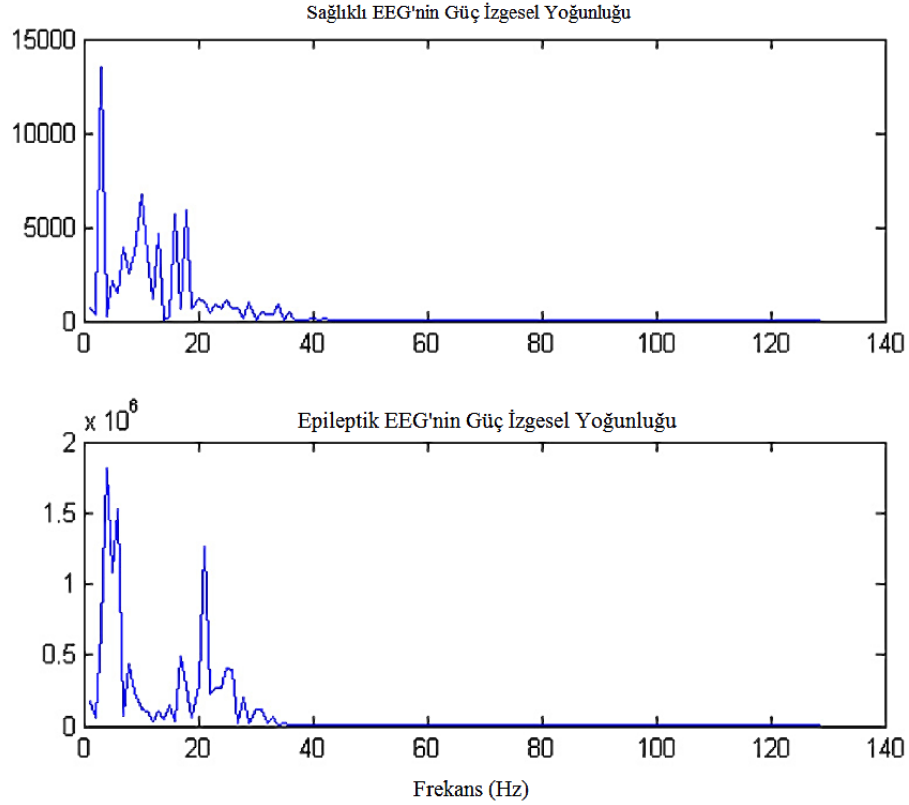
$$\hat{P}_x(f) = \frac{\Delta t}{N} \left| \sum_{n=0}^{N-1} x(n) e^{-j2\pi fn} \right|^2 \quad -1/2\Delta t < f \leq 1/2\Delta t \quad (2.6)$$

ile bulunur. Δt ise ayrık işaretin örnekleme aralığını ifade etmektedir. Böylece frekans bölgesinde elde edilen GİY fonksiyonlarının epileptik ve sağlıklı EEG kayıtları için ayırt edici özellik göstermesi sebebiyle bir sonraki aşamada yapay öğrenme algoritmaları ile bu tespit edilebilmektedir. Sağlıklı ve epileptik nöbet anında kaydedilen EEG sinyalleri [65] için elde edilen GİS'leri Şekil 2.6 [1]'da verilmiştir.

Zaman-frekans analizi olarak kısa zamanlı Fourier dönüşümü (KZFD) [8] ve Dalgacık dönüşümü (DD) epileptik nöbet teşhisi [9, 31] için kullanılmaktadır. Temel olarak KZFD, işaretin tümünün dönüşümünü alarak kaybolan zaman bilgisini yerine koyarak daha detaylı analiz imkanı sağlamaktadır. Diğer deyişle zamanla değişen frekans bilgisini de analiz edebilmektedir. KZFD denklemi aşağıda verilmiştir.

$$X(m, \omega) = \sum_{n=-\infty}^{\infty} x(n)w(n-m)e^{-j\omega n} \quad (2.7)$$

Böylece işaret istenilen genişlikteki pencere ile çarpılarak belirli zaman aralığındaki kısmın FD'si bulunur.




Şekil 2.6: Sağlıklı ve epileptik EEG güç izgesel yoğunlukları.

Uygun pencere genişliğini esnekleştiren DD ile işareti oluşturan yüksek frekanslı ve düşük frekanslı bileşenleri ayrı ayrı analiz etmek mümkün olmaktadır. Alt bant analiz yöntemi olarak da adlandırılan DD ile yüksek frekans bileşenleri için dar, düşük frekanslı bileşenler için geniş taban fonksiyonları kullanılır. En popüler taban fonksiyonları arasında Haar, Morlet ve Daubechies sayılabilir [32]. Bir $x(t)$ işaretinin sürekli dalgacık dönüşümü (SDD) aşağıdaki (2.8) ile ifade edilir.

$$X_w(a, b) = \int_{-\infty}^{\infty} x(t)a^{-1/2}\psi\left(\frac{t-b}{a}\right)dt \quad (2.8)$$


a ve b deęişkenleri taban fonksiyonu $\psi(t)$ 'nin zaman ölçeęini ve $x(t)$ üzerinde öteleme parametrelerini ifade etmektedir. Ayrık zamanlı dalgacık dönüşümü ise Mallat [33] tarafından süzgeç yapıları kullanılarak Şekil 2.7'de gösterildięi gibi önerilmiştir.



Şekil 2.7: Tek seviyeli ayrık dalgacık dönüşümü.

Alçak geçiren (AGS) ve yüksek geçiren süzgeç (YGS) yardımıyla alt bantlara ayrılan sinyallerin taban fonksiyonları cinsinden katsayıları sırası ile yaklaşıklık (A_1) ve detay katsayıları (D_1) olarak adlandırılır.

Sinyal işleme teknikleri ile elde edilen özniteliklerin birbirleriyle örtüşmemesi, analiz edilecek olan işaretler için farklı skalar veya vektörel sonuçlar vermesi beklenir. Böylece bir sonraki aşama olan yapay öğrenme algoritmasıyla ayırt edilebilsin. Örnek olarak elde edilen iki boyutlu öznitelik vektörü $\mathbf{x} = [x_1 \ x_2]^T$ için Şekil 2.8'de verildięi gibi en az oranda örtüşmesi yüksek başarı için gereklidir.



Şekil 2.8: İki sınıf için iki boyutlu öznitelik vektörü.

İdeal olmakla beraber “+” ve “o” sembolleri ile gösterilen bu iki sınıf epileptik ve normal EEG işaretlerinden elde edilen öznitelik olduğunu kabul edersek, bir sonraki aşamada

yapay öğrenme algoritmaları ile %100 doğruluk ile epileptik nöbet tespit edilebilir olacaktır.

2.3. GÜRÜLTÜ TEMİZLEME

Gürültü temizleme performansını etkileyen faktörler arasında eşik değerinin doğru belirlenmesi böylece gürültü veya orijinal sinyal bileşenlerinin hatasız ayrılması yer almaktadır. Bir gürültü temizleme problemi şöyle tarif edilmektedir:

$$x(t) = \bar{x}(t) + \sigma\eta(t) \quad (2.9)$$

burada $\bar{x}(t)$ gürültü içermeyen orijinal sinyali, $\eta(t)$ bilinen veya bilinmeyen varyans, σ 'lı Gauss dağılımına sahip bağımsız değişkeni ifade eder. Gürültüden arındırma işlemlerinde amaç, kestirilen gürültüden arındırılmış $\tilde{x}(t)$ ile $\bar{x}(t)$ arasındaki hatayı en küçük seviyeye indirebilmektir. Hata ölçütü olarak ortalama karesel hata (*MSE*) veya sinyal gürültü oranı (*SNR*) olarak bulunabilir.

$$MSE = \frac{1}{N} \|\tilde{x}(n) - \bar{x}(n)\|_2^2 \quad (2.10)$$

$$SNR = 10 \log \left(\frac{\sigma_{\tilde{x}}^2}{\sigma_{\eta}^2} \right) \quad (2.11)$$

Eşikleme yönteminin başarı ile kullanıldığı dalgacık dönüşümü eşikleme yöntemi ile ortogonal tabanda eşik değerinin üstünde genlik değerine sahip katsayılar kullanılarak ters dalgacık dönüşümü alınır ve $\tilde{x}(n)$ yeniden oluşturulur. Bu işlemdeki ana fikir $\bar{x}(n)$ ile alakalı katsayıların gürültü katsayılarına göre daha büyük genlikli olmasıdır. En basit haliyle sert eşikleme [69]:

$$\rho_T(c) = \begin{cases} c, & |c| > T \\ 0 & |c| \leq T \end{cases} \quad (2.12)$$

burada $\rho T(c)$ eşik uygulanmış ters dalgacık dönüşümünde kullanılarak gürültüsüz $\bar{x}(n)$ ' i elde etmek için kullanılır. Bu çalışmada ve dalgacık dönüşümü tabanlı gürültü temizleme yöntemlerinde eşik, T belirleme en önemli basamağı oluşturmaktadır. Dalgacık dönüşümü için en yaygın yöntem olarak kullanılan eşikleme [70] $T = \hat{\sigma} \sqrt{2 \ln N}$ ve gürültünün standart sapmasını kestirmek için

$$\hat{\sigma} = \frac{\text{medyan}(|c_i| : i = 1, \dots, N)}{0.6745} \quad (2.13)$$

kullanılmaktadır. Bahsi geçen kestirimlerin hepsi sinyal bileşenlerine ve katsayılarının tümüne bağlıdır. Eşik belirlenirken orijinal sinyal ve gürültü katsayılarına bağlı olarak tespit yapılmakta fakat herhangi bir bileşen veya katsayı kendi içinde bağımsız değerlendirilmemektedir.


2.4. DUYGU DURUM VE EEG SİNYALLERİ İLE ANALİZİ

Duygu ve duygulanma göreceli olması sebebiyle çeşitli görüşler ortaya atılmıştır. Bunların içerisinde Darwin ve bilişsel görüş öne çıkmaktadır;

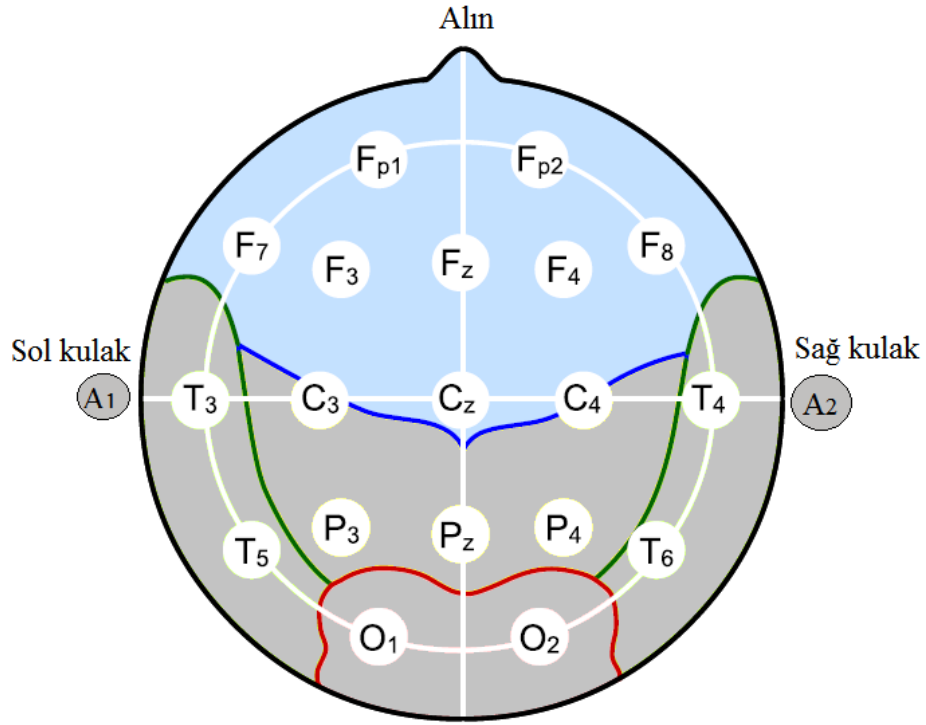
- Darwin'e göre duygular da evrimin bir parçasıdır. Ekman [34], bu görüşün savunurlarından biri olup 15 adet duygu olduğunu öne sürmüştür. Sekiz adet temel duygu olduğu ve bunların kızgınlık, korku, üzüntü, tiksinti, merak, kabullenmişlik ve neşeden oluştuğunu belirtmektedir.
- Bilişsel (*ing. cognitive*) yaklaşım ise günümüzde psikologlar tarafından yaygın olarak kabul edilmektedir ve EEG ile duygu durumu tespiti çalışmalarında sıklıkla kabul görmektedir [11–13]. Duygulanım ise iki boyutlu uyarılma ve değer (*ing. arousal-valance*) haritası ile belirlenir. Bu eksenlerden uyarılma, sakinlik ve aktiflik belirteci olarak kullanılırken, değerlik ise pozitif ve negatif olarak duyguları tanımlar [35]. Uyarılma/değerlilik bilişsel duygu harita örneği Şekil 2.9'da gösterilmiştir.

Bu grafiđi esas alınarak birçok duygunun nasıl oluştuđu, nasıl değeriendirileceđi ve aralarındaki iliřki açıklanır. Uygun haritalama ile aralıkların belirlenmesi ile duyguların sınıflandırması yine bu duygu durum haritası temel alınarak yapılmaktadır.

EEG sinyalleri analiz edilerek kiřiye ait duygu durumu tespit edilebilmektedir. Beyin ön lob (ing. *frontal lob*)ve özellikle alın bölgesinin hemen arka kısmı (ing. *prefrontal lob*) biliřsel duygusal ve motivasyondan sorumlu kısım olması sebebiyle bu bölgeden kaydedilen EEG sinyalleri ile duydu durum sınıflandırma yapılabilmektedir. 10-20 EEG elektrot yerleřim düzenine göre ön lob üzerinde bulunan elektrotlar ve pozisyonları Őekil 2.10 [36]'da verilmiřtir.



Őekil 2.9: Biliřsel uyarılma/deđerlilik duygu durum haritası.



Şekil 2.10: EEG ile duygu durum analizi için EEG kanalları.

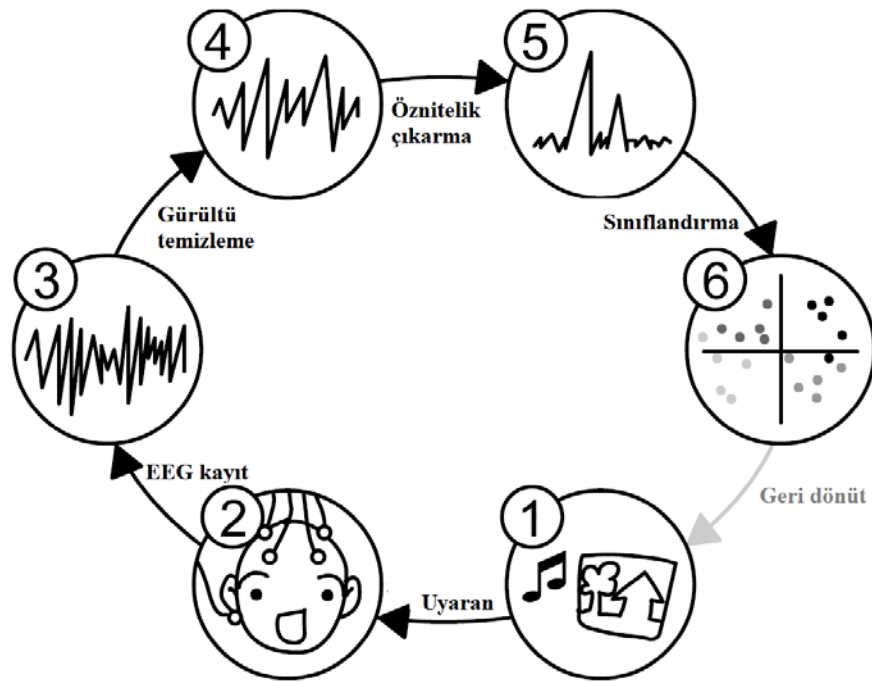
Genellikle sol-sağ kulak hattı ile alın bölgesi arasında kalan bölgedeki elektrotlardan kaydedilen sinyaller genellikle kullanılmakla birlikte hesaplama hızı gibi ölçütlerin önemli olduğu durumlarda F3, F4 ve Fz kullanılmaktadır. Diğer bir ifadeyle, bu elektrotlar EEG sinyalleri ile duygu durum tespiti için kullanılacak temel kanallardır [10, 36].

EEG sinyalleri ile duygu durum analizi için frekans bölgesi işaret işleme yöntemleri önerilmektedir. Kayıtlar alfa (8-13Hz) ve beta (13-30Hz) bantlarına ayrılarak analiz edilmesi temel yöntemlerdendir [10]. Bilişsel duygulanım haritası referans alınarak duygu tahmini için gerekli olan uyarılma ve değerlilik seviyelerinin elde edilebilmesi için alfa ve beta bantlarının güç dağılımları incelenmektedir.

Uyarılma Değeri: Bu değer sakinliğin ölçütüdür. EEG sinyallerinde beta ve alfa bantlarının oranı ile belirlenebilmektedir. Beta dalgaları (13-30 Hz) zihinsel aktivite durumlarında görülürken alfa dalgaları (8-13 Hz) sakinken görülmektedir. Bu sebeple uyarılma değeri EEG sinyallerinin frekans uzayında analizi ile bu iki bantta spektral gücün oranı ile tanımlanmaktadır [10, 11, 36].

Değerlilik Değeri: Duyguların negatif veya pozitif olmasını belirleyen bu değer beyin yarım kürelerinin aktivasyonu ile ilgilidir. Beyin sol lob inaktivasyonu negatif duyguya işaret etmektedir. Düşük güçlü alfa bant EEG sinyali düşük aktiviteyi gösterdiği için sol ve sağ küredeki alfa bantı oranı değerlendirilerek oranını belirlemekte kullanılmaktadır [10, 11, 36].

EEG sinyalleri ile duygu durum sınıflandırma bahsi geçen frekans bölgesi yöntemleri kullanılarak Şekil 2.11 [36]'da gösterilen süreçler uygulanarak yapılmaktadır.



Şekil 2.11: EEG sinyalleri ile duygu durum sınıflandırma.

Sesli veya görüntülü kayıtların genellikle uyarı olarak kullanılması neticesinde deneklerde duygu durumunun değişmesi ve bu esnada EEG sinyallerinin kayıt edilmesi ile belirli duygu için farklı deneklerden sinyaller veri tabanı oluşturulur. Gürültüden arındırılan sinyaller işaret işleme yöntemleri ile öznitelikleri elde edilerek sınıflandırıcı ile 2 boyutlu bilişsel duyulanma haritasına göre duygu belirlenir.

3. MALZEME VE YÖNTEM

Bu bölümde tez kapsamında EEG sinyallerinin analizinde kullanılan yöntemler ve bu yöntemlerin uygulandığı veri setleri hakkında bilgi verilecektir.

3.1. GÖRGÜL KİP AYRIŞIMI

Görgül kip ayrışımı (*ing. empirical mode decomposition, EMD*) (GKA) Huang ve arkadaşları [14] tarafından önerilen doğrusal ve durağan olmayan sinyaller için geliştirilmiş sinyal işleme yöntemidir. Temel olarak kübik spline interpolasyon yardımıyla üst ve alt zarfların bulunarak bunların ortalaması esasını bulma esasına dayanır. Böylece işaret kendini oluşturan yarı ortogonal özgül kip fonksiyonları (*ing. intrinsic mode function*), (ÖKF) diye adlandırılan salınımlar cinsinden ifade etmeye dayanmaktadır. Bu yöntemde elde edilen her salınının ÖKF olabilmesi için iki koşul gerekmektedir:

- uç nokta sayısının sıfır geçiş sayısına eşit veya farkın bir olmalı.
- üst ile alt zarfın ortalamasının sıfır olması gerekmektedir.

FT ve DD ile kıyaslandığında taban fonksiyonu seçimi gerektirmemesi, sinyal uyarlamalı ve durağan olmayan sinyaller için geliştirilmiş olması sebebiyle işaret işleme uygulamaları için alternatif yöntem olarak başarıyla kullanılmaktadır.

GKA algoritmasının en önemli kısmı eleme (*ing. sifting*) algoritmasıdır. ÖKF'leri belirtilen iki özelliği sağlayana kadar sinyalin içinden elde etmeye dayanır. GKA algoritmasının eleme bölümü şu adımlardan oluşmaktadır [37]:

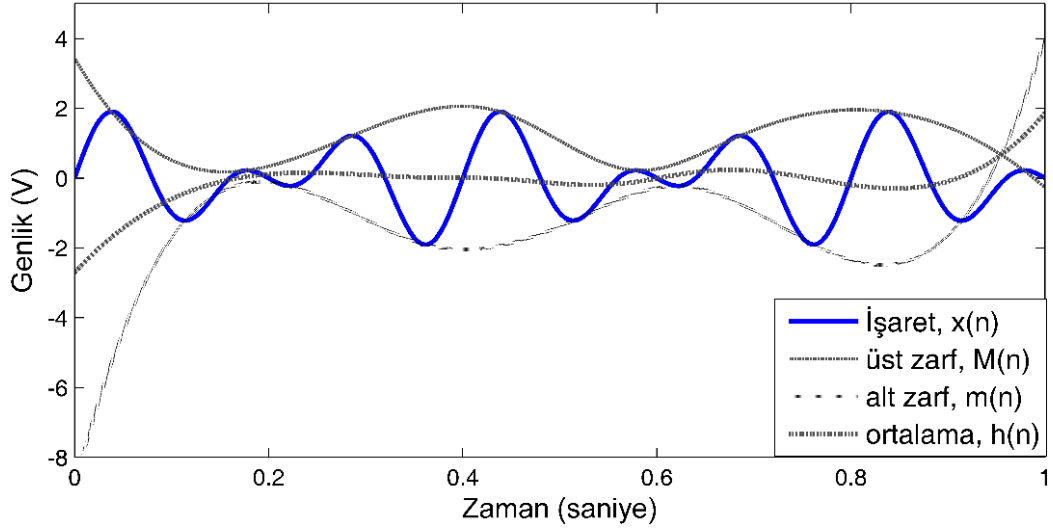
- i. Ayrık sinyal $x(n)$ içinde yerel üst ve alt maksimum/minimum noktaları $M_i, i=1,2,\dots$ ve $m_k, k=1,2,\dots$ bulunur.
- ii. Kübik interpolasyon ile bulunan üst ve alt ekstremum noktaları birleştirilerek üst zarf $M(n) = f_M(M_i, n)$ ve alt zarf $m(n) = f_m(m_i, n)$ elde edilir.
- iii. Alt ve üst zarfların ortalaması bulunur, $h(n) = (M(n) + m(n)) / 2$.

- iv. Eğer $h(n)$ ÖKF koşullarını sağlıyorsa; ÖKF, $\varphi(n) = h(n)$ olarak sakla. Değilse, $h(n)$ sinyalden çıkarılır, $x(n) = x(n) - h(n)$.
- v. Eğer $x(n)$ durdurma kriterlerini sağlıyorsa durdurulur ve $r(n) = h(n)$ olarak kaydedilir.

ÖKF'ler sabit veya trend şeklinde artık $r(n)$ elde edilinceye kadar eleme algoritması ile elde edilir. Böylece GKA algoritması ile herhangi bir kabul ve seçim yapılmadan ÖKF'ler elde edilir.

$$x(n) = \sum_{i=1}^L \varphi_i(n) + r(n) \quad (3.1)$$

burada, L toplam ÖKF sayısıdır. Bu ÖKF'ler ve artık toplandığında orijinal sinyali oluşturur. GKA algoritmasının eleme kısmı görsel olarak aşağıda verilen Şekil 3.1'de özetlenmiştir.



Şekil 3.1: Eleme algoritmasının grafik gösterimi.

GKA algoritmasının eleme kısmı için çeşitli iyileştirmeler yapılmaya çalışılmaktadır. Eleme algoritmasının grafik gösteriminde de açık olarak görülebildiği üzere enterpolasyon kaynaklı alt ve üst zarfı çıkarma ile ilgili hatalardan dolayı bitiş etkisi (*ing. end effect*) ve ortak mod-karıştırma etkisi (*ing. mode-mixing effect*) olarak adlandırılan

problemlere sahiptir [38–40]. Farklı enterpolasyon yöntemleri üzerine çalışmalar yoğunlaşmaktadır. En temel haliyle elde edilen zarfın ilk ve son örneklerinin sinyalin gerçek üst ve alt noktaları ile kıyaslandığında hatanın büyük olması bitiş etkisi problemini oluşturur. Ortak mod hatası ise genel olarak çok bileşenli bir $x(n)$ serisinin kendini oluşturan orijinal mono bileşenlerinin elde edilememesidir. Diğer bir deyişle, elde edilen ÖKF, $\varphi(n)$ 'nin tek bileşene tekabül etmemesidir. Bu karışım frekans ve genlik özellikleri birbirine yakın salınımların bir arada olduğu ÖKF olarak elde edilir.

GKA yönteminin durma kriterleri (*ing. stopping criteria*) ve buna bağlı iyileştirmeler de yapılmaktadır. Böylece sınırlı olsa bile kullanıcıya ÖKF'lerin adedi ve iterasyon adedi gibi şartlar getirilebilmektedir. Önerilen orijinal haliyle standart sapma tabanlı durma kriterinde [14, 41, 42] sıralı iki iterasyon arası değişim irdelenmiştir;

$$SD = \sum_{t=0}^T \left[\frac{|h_{(k-1)}(t) - h_{(k)}(t)|^2}{h_{(k-1)}^2(t)} \right] \quad (3.2)$$


Bir önceki iterasyonda bulunan alt ve üst zarfın ortalaması $h_{(k-1)}(t)$ ile o anki $h_{(k)}(t)$ genliklerinin farkı alınarak bulunur ve genellikle 0.2-0.3 olarak kullanılmasının elde edilecek ÖKF'lerin sinyal işleme açısından anlamlı genlik ve frekans bilgisine sahip olacağı belirtilmiştir. Bu tez çalışmasında kullanılan, enerji tabanlı çözünürlük seçeneği sunan GKA algoritmasında [37] ise durma kriterleri olarak kullanıcıya standart ÖKF koşullarına ilave olarak ÖKF ve artık olarak saklanabilmesi ve bu koşulları sağlamıyorsa durması için aşağıdaki (3.2) ve (3.3) eklenmiştir.

$$qResol = 10 \log \left(\frac{\sigma_{x(t)}^2}{\sigma_{h(t)}^2} \right) \quad (3.3)$$

$$qResid = 10 \log \left(\frac{\sigma_{x(t)}^2}{\sigma_{r(t)}^2} \right) \quad (3.4)$$

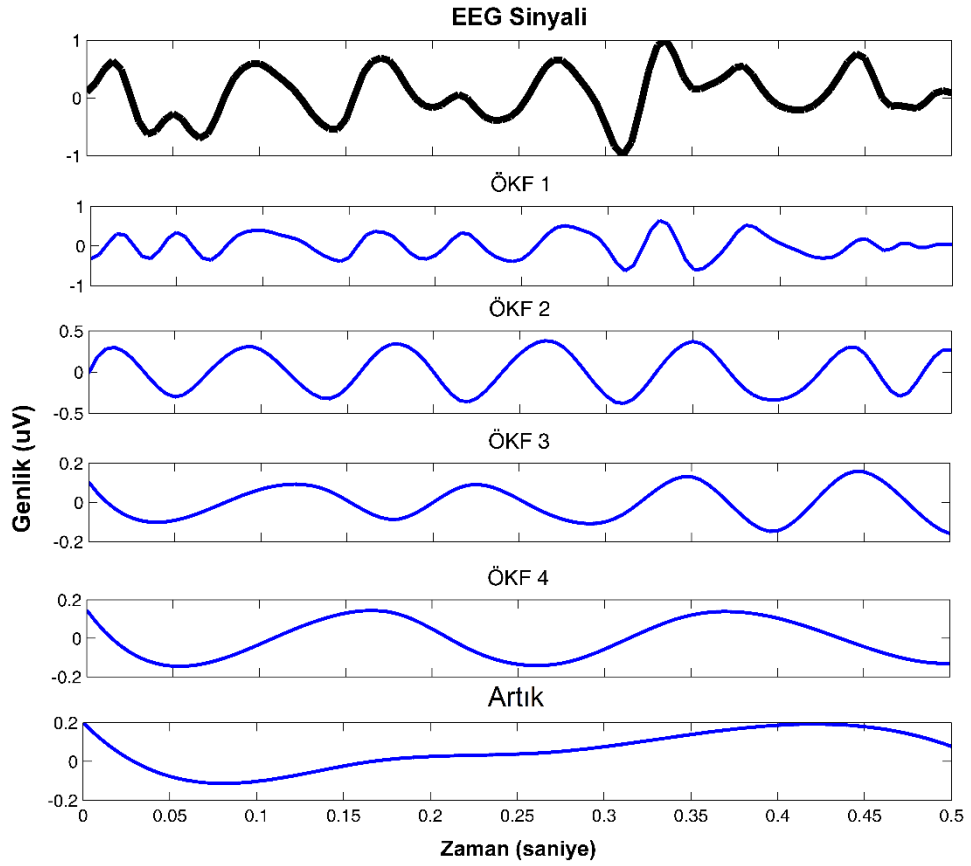
Böylece elde edilen her $h(t)$ 'nin $\varphi(t)$ olarak saklanması için sinyal, $x(t)$ 'e oranla belirli bir enerjiye $qResol$ 'a sahip olması gerekir. Benzer şekilde algoritmanın durması içinse

$r(t)$ 'nin enerji oranı q_{Resid} 'in kullanıcı tarafından belirlenen değerin altına düşmesi gerekir. Enerji çözünürlük seçenekli GKA [37] algoritması Şekil 3.2'de verilmiştir.



Şekil 3.2: Enerji çözünürlük seçenekli görgül kip ayrışımı akış şeması.

Örnek olarak tek kanal EEG sinyali ve GKA algoritması ile elde edilen ÖKF'leri Şekil 3.3'de verilmiştir.



Şekil 3.3: Bir EEG sinyali ve örnek ÖKF'leri.

Böylece 0.5 saniyelik EEG sinyali GKA algoritması ile 4 adet ÖKF ve artıktan oluşan salınım olarak ayrıştırılmıştır. İlk ÖKF yüksek frekanslı bileşenleri içerirken, ÖKF numarası büyüdükçe içerdiği bileşenlerin frekansları düşmektedir.

3.2. ÇOK DEĞİŞKENLİ GÖRGÜL KİP AYRIŞIMI

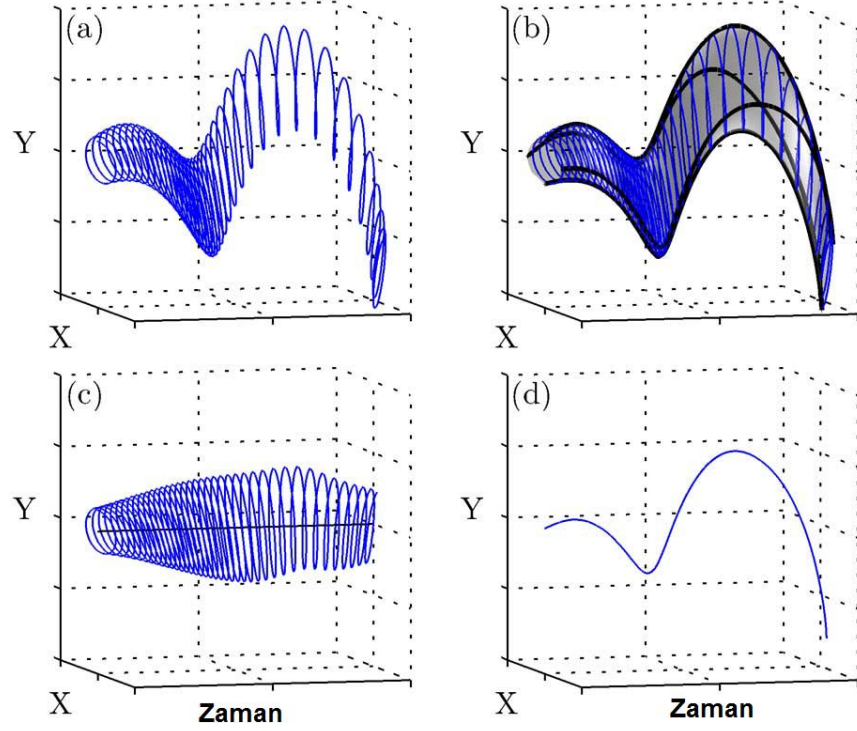
Çok kanallı EEG sinyalini bir arada GKA ile analiz etmek için çok değişkenli görgül kip ayrışımı kullanılmıştır. Bu çalışmalar ilk olarak iki değişkenli veya karmaşık değişkenli sinyaller için iki değişkenli görgül kip ayrışımı (İDGKA) (*ing. bivariate empirical mode decomposition*) [43], sonra ise üç değişkenli GKA (ÜDGKA) (*ing. trivariate EMD*) [44] çalışmaları yapılmıştır. Tüm bu çalışmaların neticesinde bunları kapsayacak çok değişkenli GKA (ÇDGKA) (*ing. multivariate empirical mode decomposition*) [45] geliştirilmiştir, 32 kanala kadar denenmiş ve başarısı gösterilmiştir.

Temel olarak tek deęişkenli GKA'dan farkları, çok boyutlu düzleme örneklerin yansımından enterpolasyon ile alt ve üst zarfların elde edilmesinden ibarettir. Çok deęişkenli GKA algoritması [45];

- i) l deęişkenli sinyaller için $(l-1)$ boyutlu küresel koordinatlara örnekleme yapılır.
- ii) Giriş sinyalleri $\{\mathbf{v}(t)\}_{t=1}^T$ için projeksiyonları $p^{\theta_k}(t)_{t=1}^T$ yön vektörleri \mathbf{x}^{θ_k} boyunca hesaplanır.
- iii) $p^{\theta_k}(t)_{k=1}^K$ Projeksiyonu elde edilmiş sinyal seti üzerinde anlık maksimum noktalar $\{t_i^{\theta_k}\}$ bulunur.
- iv) $[t_i^{\theta_k}, \mathbf{v}(t_i^{\theta_k})]$ interpolasyon edilerek çok deęişkenli zarf eğrisi $\mathbf{e}^{\theta_k}(t)_{k=1}^K$ elde edilir.
- v) K adet yön vektörü için, zarfın ortalaması $\mathbf{m}(t) = \frac{1}{K} \sum_{k=1}^K \mathbf{e}^{\theta_k}(t)$ ile bulunur.
- vi) Ayrıntı $d(t) = x(t) - m(t)$ formülü ile bulunur. Eğer $d(t)$ durma kriterini sağlıyorsa ÖKF olarak saklanır ya da ilk adıma geri dönülür.

ÇDGKA algoritmasını grafik olarak özetlemek için İDGKA algoritmasının çalışması ile iki deęişkenli sinyal için zarf elde edilmesi Şekil 3.4 [43]'de verilmiştir.

Tek deęişkenli GKA ile kıyaslandığında, çok kanallı sinyali birer birer GKA algoritmasına uygulayıp ÖKF'lerini elde edince her kanal için ÖKF adedi farklı olabilmektedir. Bu farklılığın yanı sıra eşleşen ÖKF'lerin istatistiksel ve frekans bölgesi özellikleri birbirinden çok farklı olabilmektedir.




Şekil 3.4: İki değişkenli GKA örneği.

Birden çok sinyal için çok değişkenli GKA ile elde edilen ortak zarf ve ortalama ile her kanal için aynı adette GKA elde edilir ve bunların özellikleri birbiriyle benzer olması sebebiyle olası çalışmalar için kıyaslamaya imkân sağlamaktadır.

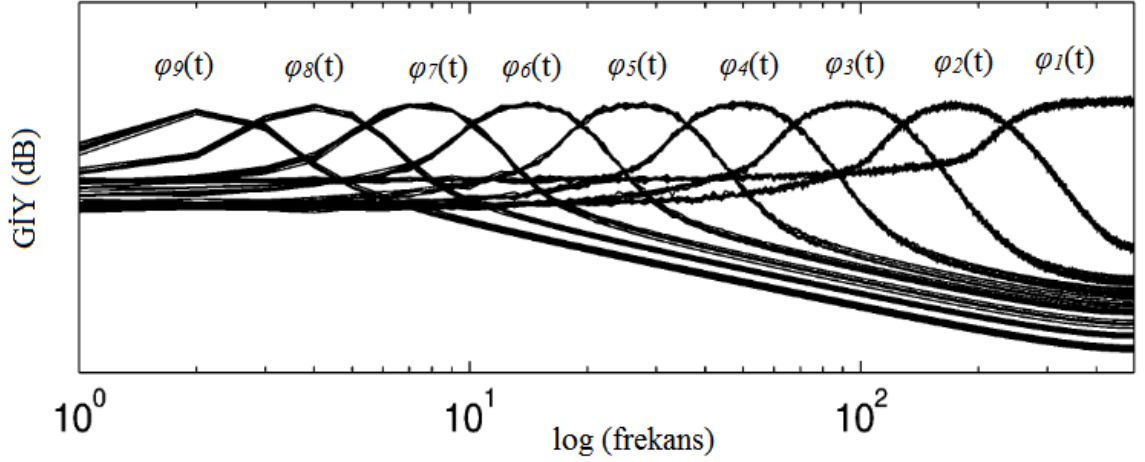
3.3. GÖRGÜL KİP AYRIŞIMI SÜZGEÇ YAPISI ÖZELLİKLERİ

Flandrin ve diğerleri ile yapılan çalışmada [46] GKA metodunun süzgeç öbeği yapıları incelenmiştir. Kesirli Gauss gürültüsü (fGn) kullanılarak gerçekleştirilen çalışmada ÖKF'lere tekabül eden süzgeç öbeği yapılarının sinyal uyarlamalı yapıya sahip olduğu ve bu uyarlamalı yapının sinyalin Hurst üsteline göre değiştiği gösterilmiştir. Şekil 3.5 [46, 47]'de bu çalışmada verilen Hurst üsteline bağımlı GKA süzgeç öbeği yapısı verilmiştir.



Şekil 3.5: GKA'nın sinyal uyarlamalı süzgeç öbeği yapısı örneği.

Hurst üsteli 0-1 arasında değişmektedir. Yüksek Hurst değeri yavaş değişen istatistik özellikleri daha kalıcı ve sabit olan zaman serisini ifade etmektedir. Sinyal uyarlamalı GKA süzgeç öbeği yapısı ile beraber yorumlandığında; $H=0.1$ iken istatistik özellikleri hızlı değişen sinyal GKA'ya uygulandığında ilk ÖKF'ler daha geniş bantta salınımlar içermektedir ve böylece daha yüksek güçlü GİS'lere sahiptir. Eğer sinyalin Hurst üsteli yüksek ise, örnek olarak $H=0.9$ ise, son ÖKF'ler daha geniş banttaki salınımları içermektedir ve yüksek GİY seviyelerine sahip olmaktadır. $H=0.5$, beyaz gürültü uygulanması durumunda ise tüm ÖKF'lerin güç izgesel yoğunlukları eşittir. Benzer şekilde ÇDGKA süzgeç öbeği yapısı 500 örnekli ($N=500$) beyaz gürültü için elde edilerek Şekil 3.6 [48]'da gösterilmiştir.



Şekil 3.6: ÇDGKA süzgeç yapısı.

Toplam 8 kanal beyaz gürültü ÇDGKA algoritmasına uygulanmış ve her biri için 9 adet ÖKF elde edilmiştir. Bunların GİY ortalamaları alınarak ÇDGKA süzgeç öbeği yapısı çıkarılmıştır.

3.4. HİLBERT-HUANG DÖNÜŞÜMÜ

Hilbert-Huang dönüşümü (HHD) [14], en basit ifadeyle bir sinyalin görgül kip ayrışımı ile elde edilen özgül kip fonksiyonlarına Hilbert dönüşümünün (HD) uygulanmasıdır. Sinyal $x(t)$ 'nin HD ile anlık genlik ve frekans bilgisinin bulunmasından farklı olarak, bu sinyalin bileşenlerini zaman-frekans bölgesinde analiz etmek için önerilmiştir. Her ÖKF HD ile analitik formları bulunur;

$$\varphi_{A_i}(t) = \varphi_i(t) + j\varphi_{H_i}(t), i = 1, 2, \dots, L. \quad (3.5)$$

burada $\varphi_{A_i}(t)$, ÖKF'lerin analitik versiyonları ve $\varphi_{H_i}(t)$ ise aşağıda verilen Cauchy integrali ile bulunan HD dönüşümleridir.

$$\varphi_{H_i}(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{\varphi_i(\tau)}{t - \tau} d\tau \quad (3.6)$$

Böylece eşitlik (3.4)'de verilen analitik form kutupsal formda,

$$\varphi_{A_i}(t) = a_i(t) e^{j\phi_i(t)} \quad (3.7)$$

anlık genlik $a_i(t)$ ve anlık faz $\phi_i(t)$ şeklinde yazılır. Anlık genlik ve faz ise;

$$a_i(t) = \sqrt{\varphi_i^2(t) + \varphi_{H_i}^2(t)} \quad (3.8)$$


$$\phi_i(t) = \arctan\left(\frac{\varphi_{H_i}^2(t)}{\varphi_i^2(t)}\right) \quad (3.9)$$

eşitlikleri kullanılarak bulunur. Anlık frekans $f_i(t)$ bilgisi anlık faz $\phi_i(t)$ 'in türevi alınarak bulunur.

$$f_i(t) = \frac{1}{2\pi} \frac{d\phi_i(t)}{dt} \quad (3.10)$$

Böylece bir sinyali oluşturan bileşenlerin zaman-frekans bölgesi analizi gerçekleştirilir. Diğer bir ifadeyle $f_i(t)$ ve $a_i(t)$ izgeleri, Hilbert-Huang İzgesi (HHİ) olarak adlandırılır. EEG sinyali için elde edilen örnek HHİ Şekil 3.7 'de verilmiştir

İlk ÖKF'lerin anlık frekansı HHİ analizi neticesinde daha büyük bir aralıkta değişim göstermekteyken, yüksek numaralı ÖKF'ler ve artık da ise bu değişim çok azdır. Bu benzer durum anlık genlik için de geçerlidir.



Şekil 3.7: EEG sinyalinin Hilbert-Huang İzgesi. (a) Anlık frekans (b) Anlık genlik.

3.6. EĞİMDEN ARINDIRILMIŞ DALAGALANMA ANALİZİ


Eğimden arındırılmış dalgalanma analizi (*ing. detrended fluctuation analysis*) (EADA), durağan olmayan zaman serilerinde ilinti ve benzerliği analiz etmek için 1994 yılında Peng ve diğerleri tarafından önerilen bir yöntemdir [49]. Hurst üsteline [50] benzer kullanıma sahip olmakla beraber, durağan olmayan bir teknik olması sebebiyle tercih edilmektedir [51–53]. Bir zaman serisinin eğilimden arındırılmış karekök dalgalanmasının segment/kutu genişliği veya örnek adedi cinsinden fonksiyonu olarak yazma prensibine dayanmaktadır. Bu amaçla bir zaman serisi $x(n)$ öncelikle ortalaması çıkarılarak aşağıdaki gibi entegre edilir:

$$y(k) = \sum_{i=1}^k [x(i) - \bar{x}], \quad 1 \leq k \leq N \quad (3.11)$$

burada \bar{x} zaman serisinin $[1, N]$ aralığında ortalaması, ve $y(k)$ ise entegre edilmiş zaman serisini belirtmektedir. Bu işlemin sonrasında, $y(k)$ n örnek adedi genişliğinde kutulara /segmentlere bölünür. Her kutu içerisinde en küçük kareler yöntemi ile doğru uydurulur, $y_n(k)$. Entegre edilmiş zaman serisi $y(k)$, yerel eğimden $y_n(k)$ çıkarılarak karekök ortalama dalgalanma, $F(n)$ şöyle bulunur:

$$F(n) = \sqrt{\frac{1}{N} \sum_{k=1}^N [y(k) - y_n(k)]} \quad (3.12)$$


burada $F(n)$ tüm n değerleri için hesaplanarak, Hurst üsteli gibi log-log skalada, $\log(F(n))$, $\log(n)$ çizilmesi ile EADA üsteli, α bulunur. EADA algoritmasındaki adımları görsel olarak ifade etmek için çalışmada verilen grafik [51] revize edilerek Şekil 3.8'de gösterilmiştir. Kutu genişliği, n arttıkça yerel eğim $y_n(k)$ 'den sapma artmaktadır. Böylece skaladan bağımsız α değeri elde edilmiş olur




Şekil 3.8: Eğimden arındırılmış dalgalanma analizi grafiksel ifadesi.

EADA analizi yapılırken kutu genişliğine bağlı olarak üstel değer açısı α değerinde zaman analizinin özelliğine ve örnek adedine göre değişim göstermektedir. Şekil 3.9’de Jospin ve arkadaşları tarafından [51] EEG çalışmalarında kullanılabilir olası EADA üsteli için örnek açı tespit aralıkları verilmiştir.

Aralıklar veriye bağımlı olmakla birlikte bazen tek bir açı değeri bile gerekli doğrusal özelliği göstermekte ve sadece bir bölgeden üstel değeri hesaplamak yeterli olmaktadır. Lee ve arkadaşlarının çalışmasından [52] elde edilen grafik Şekil 3.10’da buna örnek olarak verilmiştir. Zaman serisinin özelliklerine göre değişen doğrusal aralıklar olmasına rağmen, kabul gören sıklıkla kullanılan kutu genişliği, $4 \leq n \leq 16$ olarak kullanılmaktadır, diğer tercih olarak ise $16 \leq n \leq 200$ kullanılmaktadır. Diğer üstellere göre, EADA üstelinin sinyali daha iyi karakterize ettiği, elde edilen üstel değerinin daha belirleyici olduğu bilinmektedir. EADA üstelinin sahip olduğu özel değerler Tablo 3.10’da verilmiştir.



Şekil 3.9: EADA üsteli tespiti için kullanılabilen örnek doğrusal aralıklar.



Şekil 3.10: EADA üsteli açısı tespiti için tek doğrusal aralık örneği.

Tablo 3.1: EADA üsteli özel değer aralıkları.

Sinyal çeşidi	EADA üsteli
Beyaz gürültü	0.5
Pembe gürültü	1.0
Brownian gürültü	1.5
Anti-ilintili sinyal	$0 < \alpha < 0.5$
Geçici veya zamanla değişen ilintili sinyal	$0.5 < \alpha < 1$
Durağan olmayan sinyal	$\alpha > 1$

EADA üsteli sinyal işleme perspektifinden ele alındığında; büyük α üsteli daha az dalgalanmalı yumuşak sinyal anlamına gelmektedir [53].

3.7. ORTAK BİLGİ

Ortak bilgi (OB), rastgele değişkenlerin olasılıksal bağımlılık için kuramsal bilgi ölçümünde kullanılmaktadır [54]. OB, rastgele değişken, Y 'nin rastgele değişken X içindeki gerçekleşme oranını belirtir ve $I(X;Y)$ olarak gösterilir. Entropi, $H(X)$ ve koşullu entropi, $H(X|Y)$ bulunarak hesaplanabilir. Ayrık rastgele değişkenler, X ve Y arasında OB:

$$H(X) = -\sum_x P(x) \log P(x) \quad (3.13)$$

$$H(X|Y) = -\sum_y P(y) \sum_x P(x|y) \log P(x|y) \quad (3.14)$$

$$I(X;Y) = H(X) - H(X|Y) = \sum_x P(x) \sum_y P(x|y) \log \frac{P(x|y)}{P(x)} \quad (3.15)$$

olarak tanımlanır. Böylece iki değişken arasındaki OB, diğer bir bakış açısıyla ne kadar benzerlik gösterdiklerinin ölçütü olarak kullanılabilir.

3.8. BAĞIMSIZ BİLEŞEN ANALİZİ

Bağımsız bileşen analizi (BBA), çok değişkenli veri içerisinde saklı olan yapıları belirleyip analiz etmek için kullanılan istatistiksel yöntemdir [55]. Örnek olarak n adet bağımsız kaynağın (s) karışmasıyla oluşan m adet ölçüm noktasından alınan sinyaller aşağıdaki denklemlerle ifade edilirse,

$$\begin{aligned} x_1(t) &= A_{11}s_1(t) + A_{12}s_2(t) + A_{13}s_3(t) + \dots + A_{1n}s_n(t) \\ x_2(t) &= A_{21}s_1(t) + A_{22}s_2(t) + A_{23}s_3(t) + \dots + A_{2n}s_n(t) \\ x_3(t) &= A_{31}s_1(t) + A_{32}s_2(t) + A_{33}s_3(t) + \dots + A_{3n}s_n(t) \\ &\vdots \\ x_m(t) &= A_{m1}s_1(t) + A_{m2}s_2(t) + A_{m3}s_3(t) + \dots + A_{mn}s_n(t) \end{aligned} \quad (3.16)$$

Bu denklem sisteminde $x_1(t), x_2(t), x_3(t), \dots, x_m(t)$ gözlem veya ölçüm sinyallerini ifade eder. $s_1(t), s_2(t), s_3(t), \dots, s_n(t)$ ise bağımsız kaynakları gösterir ve bu sistemde

$A_{11}, A_{12}, \dots, A_{1n}$ karıştırma katsayıları oranında bu bağımsız kaynaklar ölçüm sinyallerini oluşturur. Böylece bu denklem sistemi matris formunda aşağıdaki denklem (3.16)'da ki gibi yazılabilir.

$$\mathbf{x} = \mathbf{A}\mathbf{s} \quad (3.17)$$

BBA ise gözlem/ ölçüm sinyalleri \mathbf{x} 'i elde edilen sistemler için bu karışım matrisi \mathbf{A} 'yı kestirmeyi ve aşağıdaki eşitlik ile bağımsız kaynakları \mathbf{S} 'i bulmayı amaçlar.

$$\mathbf{s} = \mathbf{A}^{-1}\mathbf{x} \quad (3.18)$$

BBA'nın ilk aşaması gözlem verilerinin beyazlaştırılmasıdır. Bu aşamada ölçüm sinyalleri arasındaki ilintiler temizlenir.

BBA öznitelik vektörünü oluşturan bağımsız bileşenlerin tespiti gibi boyut indirgeme amaçlı çalışmalarda [56, 57] sıklıkla ve başarıyla kullanılmakla birlikte, diğer yaygın kullanım alanı kör kaynak ayrıştırmasıdır [58, 59].

3.9. YAPAY ÖĞRENME

Yapay öğrenme algoritmaları öğrenme işlevleri açısından üç temel gruba ayrılmaktadır. Bunlar [60] ;


- Eğitici-siz öğrenme
- Eğitici-li öğrenme
- Pekiştirmeli öğrenme

Olarak üç alanda sınıflandırılır.

3.9.1. Eğitici-siz Öğrenme

Eğitici-siz öğrenme algoritmaları etiketlenmemiş eğitim verileri kullanılarak yapılan öğrenme tipidir. Veriler arası benzer özelliklerin analizi gerçekleştirilmesi neticesinde aralarında yakın ilişki bulunan örneklerin bir guruba dahil edilmesidir. Daha çok kümeleme (*ing. clustering*) olarak bilinen bu yöntem ile verileri etiketli bir eğitim kümesine gerek kalmadan veriler kümelere bölünebilmektedir.

Kümeleme için birçok yöntem öne sürülmekle beraber, iki başlık altında toplanabilir. Hiyerarşik ve hiyerarşik olmayan kümeleme yöntemleri olarak ayrılan kümeleme yöntemlerinden, temel olarak hiyerarşik yöntem dendogram oluşturulan yöntem olarak da bilinmektedir. Kümeleme yöntemleri çeşitleri Şekil 3.11’de gösterilmiştir [61].



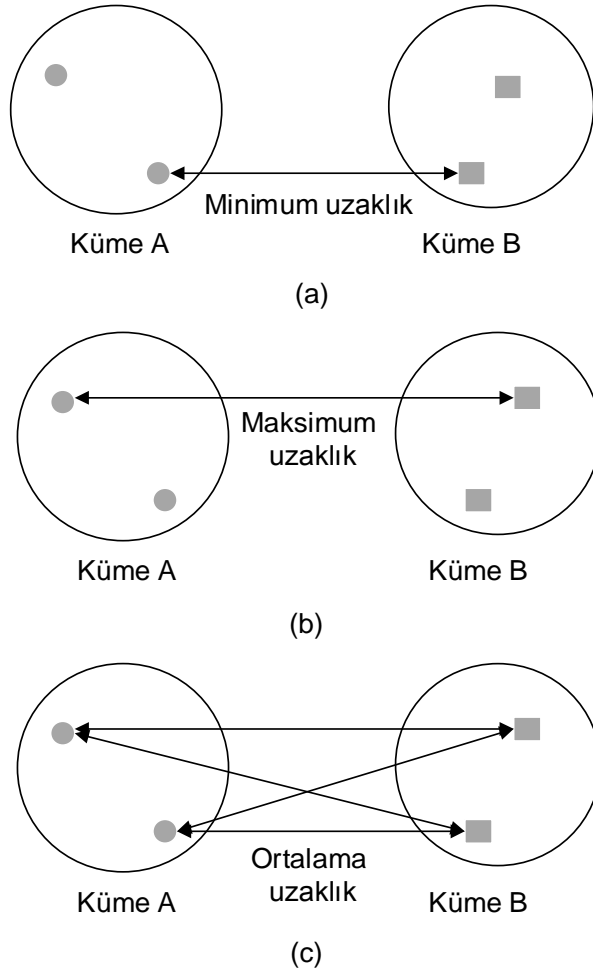
Şekil 3.11: Kümeleme yöntemleri çeşitleri.

3.9.1.1. Hiyerarşik Kümeleme Teknikleri

Her veri noktası başlangıçta bir küme olarak kabul edilir ve diğerleri ile uzaklıklarına göre grup oluşturarak kümeleme yapılan yöntemdir. Birbirine yakın veriler gruplar halinde birleştirilir ve iteratif olarak devam ederek sürdürülür. Böylece yakın özellikli

verilerin bir arada bulunduğu gruplar oluşturulur. Hiyerarşik kümeleme için tek bağlantı (*ing. single-linkage*), tam bağlantı (*ing. complete-linkage*) ve ortalama bağlantı (*ing. average-linkage*) sıklıkla kullanılan kümeler arası bağlantı tekniğidir.

Tek bağlantı tekniği için iki küme arasındaki uzaklık, kümeleri oluşturan üyeler arasındaki minimum uzaklık ile belirlenir. Tam bağlantı tekniğinde ise iki küme içerisindeki en uzak veri mesafesinin kullanılıyor olması tek bağlantı tekniği ile farkı oluşturmaktadır. Ortalama grup bağlantı tekniğinde kümeler içindeki tüm veriler arası uzaklığın ortalamasını alınır. Şekil 3.12 bağlantı tekniklerini görsel olarak özetlemek için verilmiştir.



Şekil 3.12: Kümeleme bağlantı teknikleri. (a) tek (b) tam (c) grup bağlantı.

Hiyerarşik kümeleme için bağlantı tekniklerine uygun olarak iki küme A ve B arasındaki uzaklık $D(A, B)$, tek, tam ve ortalama grup bağlantı için;

$$d(A, B) = \min [d(x_i, x_j) : x_i \in A, x_j \in B] \quad (3.19)$$

$$d(A, B) = \max [d(x_i, x_j) : x_i \in A, x_j \in B] \quad (3.20)$$

$$d(A, B) = \frac{1}{|A||B|} \sum_i \sum_j d(x_i, x_j) \quad (3.21)$$

olarak bulunur. Tüm uzaklıklar hesaplanarak kümeler arası benzerlik matrisi \mathbf{D} elde edilir.

$$\mathbf{D} = \begin{bmatrix} 0 & d_{12} & d_{13} & \cdot & \cdot & \cdot & d_{1m} \\ & 0 & d_{23} & \cdot & \cdot & \cdot & d_{2m} \\ & & 0 & \cdot & \cdot & \cdot & d_{3m} \\ & & & & & & \cdot \\ & & & & & & \cdot \\ & & & & 0 & \cdot & d_{(m-1)m} \\ & & & & & & 0 \end{bmatrix} \quad (3.22)$$

3.9.1.2. Uzaklık Ölçüleri

Kümeleme yöntemleri içerisinde performansı belirleyen etkenlerin başında yer alan veri noktaları arasındaki uzaklık ölçüsüdür. Öklit uzaklığı, yaygın olarak kullanılan ölçüdür. Öklid uzayında veri noktaları arasında uzaklığın karekökü olarak eşitlik (3.22) ile yazılır.

$$d(\vec{x} - \vec{y}) = \|\vec{x} - \vec{y}\| \quad (3.23)$$

n boyutlu vektörler $\mathbf{x} = [x_1, x_2, x_3, \dots, x_n]^T$ ve $\mathbf{y} = [y_1, y_2, y_3, \dots, y_n]^T$ için eşitlik (3.22)

$$d(\vec{x} - \vec{y}) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + (x_3 - y_3)^2 + \dots + (x_n - y_n)^2} \quad (3.24)$$

olarak ifade edilir. Öklit uzaklığı değişkenlerin bağımsız olduğu ve aynı aralıkta ölçeklendiği durumlarda başarılı sonuçlar vermektedir. Öklit uzaklığının farklı ρ değerleri için genelleştirilmiş haline Minkowski uzaklığı adı verilmektedir. Genel olarak formülü:


$$d(\bar{x} - \bar{y}) = \left(\sum_{i=1}^n |x_i - y_i|^\rho \right)^{1/\rho} \quad (3.25)$$

Mahalanobis uzaklığı veriler arası varyans ve kovaryans özelliklerini de dahil ederek korelasyon tabanlı ölçüt kullanır [62]. Bu uzaklık,

$$d(\bar{x} - \bar{y}) = \sqrt{(\bar{x} - \bar{y})^T \Sigma^{-1} (\bar{x} - \bar{y})} \quad (3.26)$$

Burada Σ kovaryans matrisidir. Kovaryans matrisinin birim matris olması durumunda $\Sigma = I$, Mahalanobis uzaklığı Öklit uzaklığı ile aynıdır. Eğer kovaryans matrisinin diyagonal olması durumunda bu uzaklığa normalize Öklid uzaklığı adı verilir.

Öklid uzaklığı kullanılarak Hiyerarşik kümeleme örneği Şekil 3.13'de verilmiştir.



Şekil 3.13: Dendrogram örneği.

Yedi adet veri için Öklit uzaklığı kullanılarak yapılan hiyerarşik kümeleme neticesinde 6. ve 7. Veriler birbiriyle çok benzer özellikler göstermekteyken 3., 4. ve 5. Veriler ise kendi içinde çok benzer ve diğer gruplardan en yakın olarak 6. ve 7.veriler ile benzerdir. Bu benzerlik Öklit uzaklığı kullanılarak tespit edilmiştir.

3.9.1.3. Hiyerarşik Olmayan Kümeleme Yöntemleri

Ayrılmak istenen kümeler hakkında ön bilgi sahibi olması durumunda ve keyfi veya mecburi küme sayısına karar verilmiş ise hiyerarşik olmayan kümeleme yöntemleri kullanılabilir. k -ortalama tekniği en temel hiyerarşik olmayan kümeleme tekniğidir [63]. Bir veri önceden belirlenen k adedinde kümeden birine ait olabilmektedir. Böylece, keskin bir kümeleme algoritmasıdır. Her küme merkez noktasiyla temsil edilir ve her veri bu kümelerden en yakın uzaklıkta olana dahil edilir. En yaygın olarak karesel hata ölçütü kullanılarak bu atama işlemi yapılmaktadır.


$$\underset{C}{\operatorname{argmin}} = \sum_{i=1}^k \sum_{\mathbf{x} \in C_i} \|\mathbf{x} - \mu_i\|^2 \quad (3.27)$$

Burada $C = \{C_1, C_2, C_3, \dots, C_k\}$ k adet kümeye μ_i ise kümelerin ortalamasına tekabül eder.

3.9.2. Eğitici Öğrenme

Eğitici öğrenmede etiket değerleri belirli olan veriler yardımıyla eğitilen yapay öğrenme algoritmasının yeni ve bilinmeyen verilerin etiketlerini tahmin etmesi amaçlanmaktadır. Sınıflandırıcılar en tipik eğitici öğrenme teknikleridir. Bu amaçla, veriler eğitim ve test verisi olarak sınıflandırıcıya uygulanır.

En basit ve doğrusal olmayan sınıflandırıcı olarak bilinen k -en yakın komşu (k -NN) (*ing. k-nearest neighbor*) algoritmasında test edilmek istenen veriler, etiketi bilinen eğitim verisi ile uzaklıkları hesaplanarak, en yakın verinin sınıfına atanır. Bu işleme en yakın komşu algoritması adı verilirken, k adedi kadar yakındaki veriler içinde en fazla bulunan etikete atama yapan yapay öğrenme algoritması ise k -NN olarak adlandırılır. Bu özel durum $k=1$ olması durumunda her iki yöntem de aynı olmaktadır. Şekil 3.14'de $k=5$ için sınıflandırma sonucu verilmiştir.



Şekil 3.14: $k=5$ için yakın komşu algoritması sonucu.

Bu örnekte sınıfı bilinmeyen x vektörü kare ve daire olarak simgelenen iki sınıflı eğitim verileri arasında uzaklıkları ölçülerek, en yakın 5 komşu içerisinde en fazla bulunan kare etiketi sınıfına atanarak sınıflandırma tamamlanmıştır. Uzaklık ölçütü olarak önceden bahsedilen Öklit, Miknkowski ve Mahalonobis ölçüleri kullanılabilir.

Yapay sinir ağları (YSA), kontrol, sinyal işleme ve örüntü tanıma gibi uygulamalarda sıklıkla ve başarıyla uygulanan yöntemlerden biridir. Giriş katmanı, en az bir adet gizli katman ve çıkış katmanından oluşmaktadır.

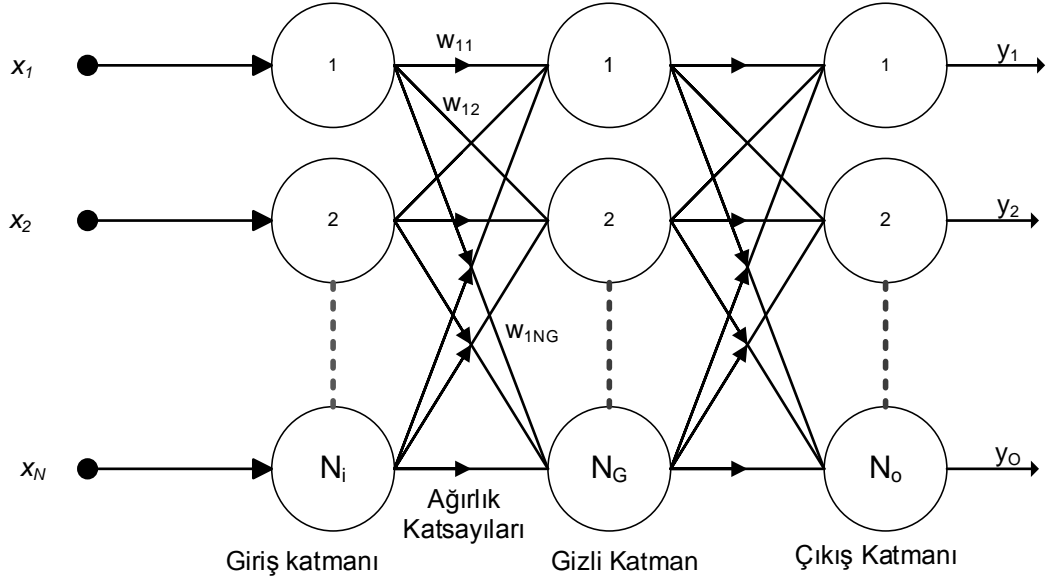
N_i , N_G ve N_O sırası ile giriş, gizli ve çıkış katman nöron sayısını belirtmektedir. Gizli katmandaki nöronlar ağırlıklı ($w_{11}, w_{12}, w_{13}, \dots, w_{1N_G}, w_{2N_G}, \dots, w_{N_i N_G}$) giriş değerlerini çıkış katna transfer eder. Böylece,

$$y_{net} = \sum_{i=1}^N x_i w_i + w_0 \quad (3.28)$$

$$y_{out} = f(y_{net}) = \frac{1}{1 + e^{-y_{net}}} \quad (3.29)$$

$$E = \frac{1}{2} \sum_{i=1}^k (y_{obs} - y_{out})^2 \quad (3.30)$$

Olarak tek gizli katmanlı YSA ağı mimarisi Şekil 3.15’de verilmiştir.

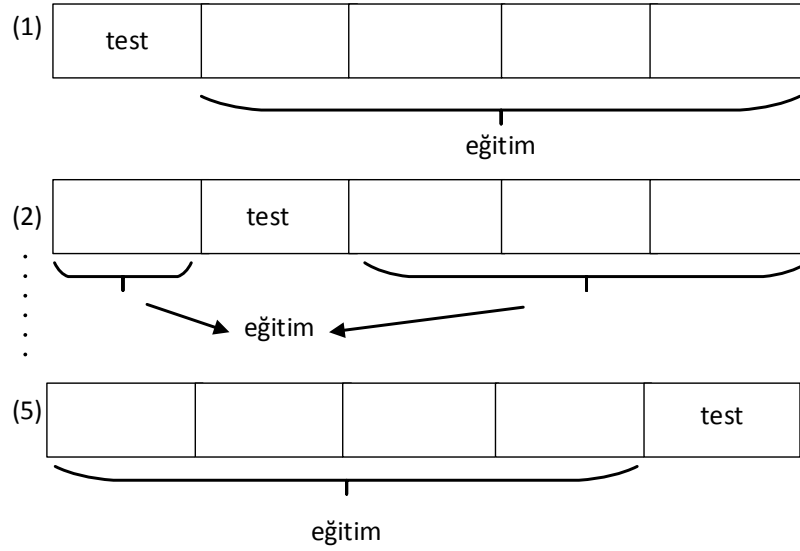


Şekil 3.15: Tek gizli katmanlı YSA mimarisi.

olarak yazılır. w_0 biyas, y_{net} ağırlıklı girişlerin toplamı ve y_{out} ise çıktıdır. E ise ağ çıkışı ile gerçek değerler arası hatadır [64].

3.9.2.1. Veri Kümesi Bölümleme ve Performans Ölçüm Yöntemleri

Çeşitli sinyal işleme yöntemleri ile elde edilen gözlemlerin veya örneklerin bir kısmının eğitim seti, diğerlerinin ise test verisi olarak kullanılarak önerilen örüntü tanılamının başarısının ölçülmesi gerekmektedir. Bu sebeple en temel veri kümesi bölümleme yöntemi olarak rassal bölümleme kullanılmaktadır. Veriler içinden rasgele seçilen örneklerle eğitim ve test kümesi oluşturulmaktadır. Uygulamalarda genellikle %50-%25 arası değişen oranlarda test verisi kullanılmaktadır. Rassal bölümlemenin dezavantajını ortadan kaldırmak amacıyla k -kat çapraz geçirme (ing. *k-fold cross-validation*) başarıyla kullanılan yöntemler arasındadır [56]. Rasgele seçilen örnekler yerine, tüm örnekler arasında oluşturulan alt kümelerin sırası ile test ve diğerlerinin eğitim verisi olarak kullanılması neticesinde tüm veri setinin başarısını ölçmeyi hedefleyen daha kararlı bir bölümleme oluşturulmaktadır. 5-kat çapraz geçirme için örnek Şekil 3.16’da gösterilmiştir.



Şekil 3.16: 5-kat çapraz doğrulama örnek alt kümeleri.

Veri setinin 5 eşit alt kümelere ayrılması neticesinde her iterasyonda bir alt küme test verileri olarak saklanırken, diğer dört alt kümedeki verilerin kullanılarak eğitilen sınıflandırıcıya uygulanır. Beş iterasyon sonucunda performans değerlerinin ortalaması bulunarak bu model için başarı değeri hesaplanır.

Birini dışarıda bırakma (*ing. leave one-out*) ise k-kat çapraz geçişlemenin özel bir tipidir. Veri seti k-adet alt kümeyle bölmek yerine, her bir örnek test verisi olarak kullanılırken diğerleri eğitim kümesini oluşturur. Bu yöntemde tek bir örneğin sınıflandırılmasının incelenmesi amaçlanmaktadır. Birini dışarıda bırakma yöntemini esas alarak bir katılımcıyı dışarıda bırak çapraz geçişlemesi (*ing. leave-one-participant-out*) de çeşitli uygulamalarda kullanılmaktadır.

Bir kişi veya katılımcıya ait birden fazla verilerin test verisi olarak, diğer kişi ve katılımcıların verileri ile eğitilmiş sınıflandırıcıya uygulandığı çapraz geçişleme tekniğidir [11]. Bu iterasyon her katılımcı için tekrarlanır ve katılımcı sayısında ortalaması alınarak önerilen sınıflandırıcı modelinin başarısı tespit edilir.

Her sınıflandırma için Tablo Tablo 3’de karışıklık matrisi elde edilir. Verilen bu değerler sırası ile gerçek pozitif (TP), yanlış negatif (FN), yanlış pozitif (FP) ve gerçek negatif (TN)’dir.

Tablo 3.2: Karışıklık matrisi.

Gerçek Değer	Sınıflandırılan Değer	
	Pozitif	Negatif
Pozitif	TP	FN
Negatif	FP	TN

Bu sayım değerleri ile doğruluk değeri aşağıdaki eşitlik (3.30) ile bulunur.

$$Doğruluk = \frac{TP + TN}{TP + FP + FN + TN} \quad (3.31)$$

Böylece bir sınıflandırmanın başarısı doğru tespit edilen örneklerin toplam örneklere oranı olarak hesaplanır.

3.10. EEG VERİ SETLERİ

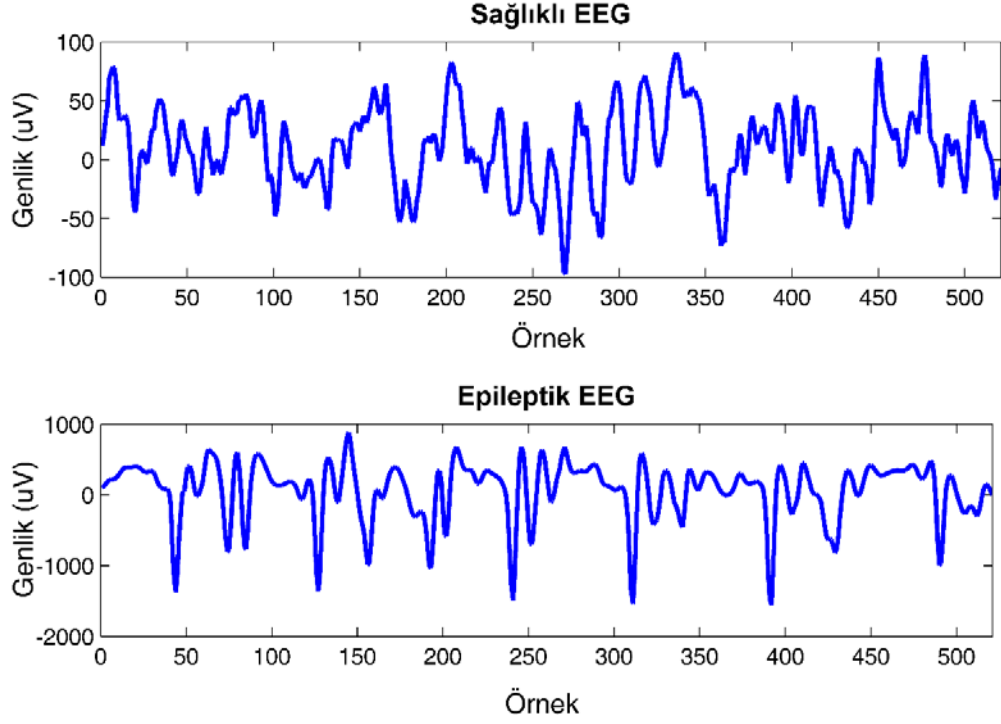
3.10.1. Epileptik Veri Setleri

Epileptik EEG kayıtlarını analiz etmek amaçlı Bonn Üniversitesinde oluşturulan tek kanallı beş veri setinden oluşmaktadır [65]. A, B, C, D ve E olarak isimlendirilen veri setleri, her biri 23.6 saniyelik 100 segmentli sinyalleri içermektedir. Örnekleme frekansı, $f_s = 173.60$ Hz olan bu kayıtlardan, kas ve göz kırpması gibi gürültülerin varlığında ilgili kısımlar atılarak oluşturulmuştur. A ve B veri setleri saçlı deri yüzeyinden, C, D ve E setleri ise dahili olarak kaydedilmiştir.

A ve B kümelerindeki sinyaller gözler açık ve kapalıyken beş sağlıklı bireyin EEG kayıtlarından oluşmaktadır. C ve D verileri ise beş epilepsi hastasının atak geçirmediği zamanlardaki kayıtlarından oluşturulmuştur. E veri seti atak anında beş epilepsi hastasının kayıtlarıdır.


Bu veri setleri kabul görmüş ve birçok çalışmada kullanılarak, EEG sinyalleri için çeşitli zaman ve frekans bölgesi sinyal işleme yöntemleri kullanılarak öznelik çıkarma ve farklı yapay öğrenme algoritmalarına uygulanmıştır [1, 66]. Temel olarak A veya B veri setleri

sağlıklı EEG, E veri setleri ise epileptik EEG olarak çalışmalarda kullanılmıştır. Bu veri setinden sağlıklı ve epileptik EEG sinyal örnekleri Şekil 3.17’de verilmiştir.




Şekil 3.17: Bonn Üniversitesi EEG kayıt örnekleri.

Diğer EEG veri seti Oslo Üniversitesi Hastanesinde oluşturulan tek kanallı sağlıklı ve epileptik kayıtlarıdır [67]. Örnekleme frekansı $f_s = 200$ Hz olan bu kayıtlar yaklaşık 20 saniyeliktir. Örnek olarak sağlıklı ve epileptik EEG kayıtları Şekil 3.18’de verilmiştir.



Şekil 3.18: Oslo Üniversitesi EEG kayıt örnekleri.

Çok kanallı EEG kayıtları için CHB-MIT [28] olarak isimlendirilen veri seti kullanılmıştır (Children's Hospital Boston (CHB) ve Massachusetts Institute of Technology (MIT) tarafından oluşturulmuştur). 24 katılımcı için günler boyu süren 23 kanallı veri setinden oluşmaktadır. 16-bit çözünürlüğe sahip kayıt cihazı ile $f_s = 256$ Hz örnekleme frekansında kaydedilmiştir. CHB-MIT veri setine ait 23 kanallı EEG sinyalleri Şekil 3.19'da verilmiştir.




Şekil 3.19: CHB-MIT 23 kanallı EEG örnek kayıtları.

CHB-MIT çok kanallı EEG kayıtları bahsedilen tek kanallı EEG veri setleri gibi epileptik atak ve normal zamanlardaki kayıtlardan kesilerek oluşturulmadığı için belirli zaman aralıklarında yapılan analizleri veya yapılan analizler için gecikme ve anlık epileptik atak tespiti gibi çalışmalara olanak sağlamaktadır [68].

3.10.2. EEG Duygu Durum Veri Seti

Orijinal adıyla ‘‘DEAP’’ veri tabanı akademik arařtırmalar için izin alınarak kullanılabilen bir veri set kümesidir [11]. Duygu durumunu tespit etmek amaçlı 32 kanal EEG sinyallerini, yüz videolarını, katılımcı listesini, dinletilen video-müzik listesini ve fiziksel sinyallerini (soluma hızı, kan basıncı, sıcaklık) içermektedir.

Bu veri setinde öncelikle 120 adet video izletilmiş bilişsel duygulanma haritası referans alınarak en tutarlı duygu uyandıran ilk 40 video seçilerek deney setinin güvenilirliği artırılmıştır. Bu amaçla her bir video için verilen değerlerin ortalamasının standart sapmaya oranı kullanılmıştır (μ_x / σ_x). Bu durumun izah için veri setinin orijinal çalışmasında verilen grafik [11] Şekil 3. 20.’de gösterilmiştir.



Şekil 3.20: DEAP EEG veri seti için video klip seçimi.


Seçilen 40 video, bu kayıtların izletilip EEG sinyallerinin alınması için tasarlanan odada 32 katılımcı için 32 kanallı EEG ile yapılmıştır. Kayıt ortamı Şekil 3.21’de verilmiştir.




Şekil 3.21: DEAP veri seti için oluşturulan kayıt ortamı.

EEG kayıtlarına başlamadan önce katılımcı Şekil 3.21’de gösterildiği gibi on saniye dinlenmesi sağlanmıştır ve sonrasında monitör ekranındaki video izletilerek Şekil 3.22.’de verilen öz değerlendirme modeli (*ing. self-assessment manikin*) yardımıyla katılımcıların uyarılma/değerlilik değerlerini girmesi istenir. Şekil 3.22’de verilen öz değerlendirme modeli yardımı ile katılımcıların bilişsel duygu haritası çıkarılır.

Bu modelin kullanılmasının en önemli sebebi katılımcının video izlerken dikkatini dağıtmadan, değerlendirme formunu görsel olarak kolay anlayıp rahat doldurabilmesidir. Sonuç olarak her katılımcı için 40 video ve 40 video esnasında kaydedilen 32 kanal EEG sinyallerinden oluşan bir EEG kayıtları ve bunlara tekabül eden Şekil 3.23’de bir örneği verilen değerlendirme ile uyarılma etiketlerinden oluşmaktadır.



Şekil 3.22: Öz değerlendirme için kullanılan modeller.



Şekil 3.23: Veri seti çalışmasında kullanılan sınıflar.

Orijinal EEG kayıtları 512 Hz örnekleme frekansı ile örneklenmiş olup, elektrookulogram (EOG) ve şebeke gürültüleri temizlenip 128 Hz aşağı örnekleme ile yeniden oluşturulmuştur. Bu işlenmiş verilerin en önemli özelliği ise; katılımcıların durgun durumdaki (video başlamadan önce) kayıtları, video esnasındaki kayıtlardan çıkarılarak, duygulanım esnasındaki EEG sinyalleri değişimi bu veri setinde hazır olarak sunulmaktadır. Uluslararası 10/20 elektrot pozisyonuna göre kaydedilip oluşturan DEAP EEG veri setine ait özet bilgiler Tablo 3.3’de verilmiştir.

Tablo 3.3: DEAP EEG duygu durum veri seti özellikleri.

Kanal no.	Kanal adı	Açıklama
1	Fp1	i. Veriler 128 Hz örnekleme frekansı ile aşağı örneklenmiştir. ii. EOG gürültüsü temizlenmiştir. iii. 4-45 Hz bant geçiren filtre uygulanmıştır. iv. Kanallar ortak referansa göre ortalaması alınmıştır. v. 3sn video öncesi kayıtlar kaldırılarak 60sn’lik bölümlere ayrılmıştır. vi. Video sırası katılımcılar için aynı sıraya getirilmiştir. vii. Veri seti; $40 \times 32 \times 8064$ (<i>video</i> \times <i>kanal</i> \times <i>örnek</i>) örnekten oluşmaktadır. viii. Etiket olarak, 40×4 (değerlilik, uyarılma, baskınlık ve beğenme) değerleri.
2	AF3	
3	F3	
4	F7	
5	FC5	
6	FC1	
7	C3	
8	T7	
9	CP5	
10	CP1	
11	P3	
12	P7	
13	PO3	
14	O1	
15	Oz	
16	Pz	
17	Fp2	
18	AF4	
19	Fz	
20	F4	
21	F8	
22	FC6	
23	FC2	
24	Cz	
25	C4	
26	T8	
27	CP6	
28	CP2	
29	P4	
30	P8	
31	PO4	
32	O2	

Bu DEAP EEG duygu durum veri seti alıřmalarımızda kullanılmıřtır. Bu veri setinin sahiplerinin yayınlamıř oldukları alıřma sonuları [11] kıyaslama amalı kullanılmıřtır.

4. BULGULAR

Bu tez çalışmasında, doğrusal olmayan ve durağan olmayan sinyaller için önerilen yeni bir sinyal işleme yöntemi olan görgül kip ayrışımı (GKA) kullanılarak EEG kayıtlarının analizi için özgün ve yeni yöntemler önerilmektedir.

GKA algoritması için iyileştirilmiş özellikleri sebebiyle Rato ve arkadaşlarının [37] MATLAB ortamı için geliştirdiği algoritma kullanılmıştır. Çok değişkenli görgül kip ayrışımı (ÇDGKA) için Rehman ve Mandic tarafından [45] geliştirilen kodlar kullanılmıştır.

Oslo ve Bonn Üniversitelerinin tek kanal epileptik ve sağlıklı EEG kayıtları [65, 67] ile CHB-MIT çok kanallı EEG verileri [28] önerilen GKA tabanlı sinyal işleme yöntemleri ile epileptik EEG analizi için kullanılmıştır. DEAP duygu durum EEG veri seti [11] ise EEG sinyalleri kullanılarak duygu durum sınıflandırma yöntemlerini değerlendirmek için uygulanmıştır. Bunlarla birlikte önerilen gürültü temizleme yöntemleri için elektrookulogram (EOG) sinyalleri [28] ile vuru, Doppler, blok ve parçalı fonksiyon gibi sentetik sinyaller tez kapsamında kullanılmıştır.

GKA yardımı ile elde edilen özgül kip fonksiyonları (ÖKF)'nin analiz edilmesi temelli yöntemler bu tez kapsamını oluşturmaktadır. GKA'nın algoritma tabanlı ve sinyal uyarlamalı yapısı sebebiyle ÖKF'lerin zaman ve frekans bölgesindeki özellikleri ayrıştırma öncesinde bilinmemektedir. Bir sinyal için elde edilen ÖKF'ler ve adedi ile diğer bir sinyal için elde edilen ÖKF'lerin ve adetlerinin sayısı ve özellikleri farklı olmaktadır. Bu sebeple, sinyalin GKA algoritması ile ayrıştırılması neticesinde elde edilen ÖKF'lerin bir ölçüt veya metotla analiz edilmesi GKA tabanlı yöntemlerin temelini oluşturmaktadır.

4.1. GÖRGÜL KIP AYRIŞIMI İLE GÜRÜLTÜ TEMİZLEME

GKA ile gürültülü sinyalin ÖKF'leri elde edilince, bu ÖKF'lerin bir veya birden fazlası gürültüye ait olmaktadır. Gürültüye ait ÖKF'lerin tespiti için güvenilir bir metrik yardımı ile eşik değerinin bulunması ve eşiğin üstü veya altında kalanların gürültünün bileşenleri olarak kabul edilip yeniden oluşturma sürecine dahil edilmemesi gerekmektedir.

GKA tabanlı gürültü temizleme yöntemleri için gürültülü salınımları içeren ÖKF'lerin bulunması ile yeniden oluşturma sürecinde bunların göz önünde bulundurulması gerekmektedir. Bir ölçüt yardımıyla belirlenen bir eşik, θ yardımıyla, bu eşğin altında veya üstünde değer alan ÖKF'ler gürültüsüz $\bar{x}(t)$ 'yi oluşturmak için kullanılır. Bu tez kapsamında ortak bilgi (OB), Hilbert-Huang Dönüşümü (HHD) tabanlı hiyerarşik kümeleme ve eğimden arındırılmış dalgalanma analizi (EADA) gibi ölçütler kullanılarak gürültülü ÖKF'ler için eşik belirlenmiştir.


4.1.1. Görgül Kip Ayrışımı ve Ortak Bilgi Tabanlı Gürültü Temizleme

Gürültülü sinyal $x(n)$ ile ÖKF'leri $\varphi_i(n)$, $i=1,2,\dots,L$ arasında bulunan OB'nin ÖKF'lerin içerdiği salınımların ne kadar bilgi içerdiği konusunda bir ölçü olması sebebiyle bu yöntem önerilmiştir. Gürültülü sinyal ve ÖKF'lerin ortak bilgi değeri neti

- i. $x(n) = \bar{x}(n) + \sigma\eta(n)$ elde edilen gürültülü sinyaldir. $\bar{x}(n)$ orijinal gürültüsüz sinyal ve $\eta(n)$ ise beyaz gürültüyü temsil etmektedir.
- ii. Gürültülü sinyal $x(n)$ 'nin GKA ile ÖKF $\varphi_i(n)$ 'leri elde edilir. Burada, $i=1,2,\dots,L$ toplam ÖKF adedidir.
- iii. ÖKF'lerin ve gürültülü sinyalin öz-ilinti fonksiyonları $R_i(k)$ ve $R_x(k)$ bulunur.
- iv. $R_i(k)$ ve $R_x(k)$ arasında ortak bilgi, $I_i = OB(R_i(k); R_x(k))$ olarak hesaplanır.
- v. OB dizisi maksimum değerine bölünerek normalize edilir, $\mathbf{I} = \mathbf{I} / \text{maksimum}(\mathbf{I})$.
- vi. Eğer sinyal beyaz gürültü içeriyorsa $I_{\max} - I_{\min} < 0.8$ olması beklenir.
- vii. Eşik değeri, $\theta = 0.5(I_3 - I_1) + I_1$ olarak belirlenir.
- viii. Gürültüsü temizlenen sinyal $\tilde{x}(n) = \sum_j \varphi_j(n)$, $j = \{i \mid I_i > \theta\}$ olarak kestirilir.


İşlem basamağı (vi) gürültü temizleme metodu için gerekli bir adım olmayıp sadece kontrol ve test amaçlı eklenmiştir. Durağan ve durağan olmayan sinyaller ile yapılan denemelerde, gürültüsüz olma durumunda OB değerinin 0.8 olduğu tespit edilmiştir. Böylece eşik $\theta = 0.8$ olarak belirlenmiş olup, bu değer üstünde OB değerine sahip

ÖKF'ler orijinal gürültüsüz sinyal $\bar{x}(n)$ 'in bileşeni olarak kabul edilip gürültüden arındırılmış $\tilde{x}(n)$ 'nin kestirilmesinde kullanılmıştır. Önerilen GKA ve OB tabanlı gürültü temizleme tek kanal normal ve epileptik EEG kayıtları [67] üzerinde denenmiştir ve Şekil 4.1'de verilmiştir.




Şekil 4.1: EEG sinyalleri ve ÖKF'leri.

Bu gürültüsüz sinyallerin toplam 4'er adet ÖKF ve birer adet artıkları elde edilmiştir. Bunların önerilen yöntemin bir parçası olan OB skorları ise Şekil 4.2'de gösterilmiştir.




Şekil 4.2: Gürültüsüz EEG kayıtlarının OB skorları.

Verilen örneklerdeki EEG kayıtlarına 20 dB ve 0 dB beyaz gürültü eklenerek önerilen yöntem test edilmiştir. 20 dB SNR oranına sahip normal ve epileptik EEG sinyallerinin önerilen yöntem sonucunda elde edilen OB değerleri Şekil 4.3’de verilmiştir.




Şekil 4.3: 20 dB SNR EEG kayıtları için OB ve eşik değerleri.

Şekil 4.3’deki OB değerleri ve eşik değerleri dikkate alınarak Şekil 4.4’de verilen 20 dB SNR’lık kayıtların ÖKF’leri içinden eşik değerinden yüksek değerli ortak bilgiye sahip olan seçilmektedir.




Şekil 4.4: 20 dB epileptik ve normal EEG ÖKF'leri.

Her iki EEG kayıtları için ÖKF 1'ler belirlenen eşik altında kalmaktadır. Epileptik ve normal EEG sinyalleri için eşikler $\theta = 0.82$ ve $\theta = 0.88$ olarak hesaplanmış ve ÖKF 1'ler beyaz gürültü bileşeni olarak tespit edilmiştir. Böylece diğer ÖKF'ler $\tilde{x}(n)$ 'i kestirmek için kullanılır. Epileptik ve normal EEG'ler için gürültüden temizlenmiş versiyonları Şekil 4.5'de gösterilmiştir.




Şekil 4.5: 20 dB EEG için gürültü temizleme sonuçları.

Önerilen yöntem 0 dB EEG sinyalleri için de uygulanarak, gürültü temizleme performansı irdelenmiştir. 0 dB için OB değerleri Şekil 4.6'da gösterilmiştir.



Şekil 4.6: 0 db EEG kayıtları için OB ve eşik değerleri.

0 dB sinyaller için ÖKF 1 ve ÖKF 2 beyaz gürültü salınımı olarak tespit edilmiştir. Bu ÖKF'ler hariç tutularak elde edilen gürültüsüz sinyaller Şekil 4.7'de verilmiştir.



Şekil 4.7: 0 dB EEG için gürültü temizleme sonuçları.

Önerilen GKA ve OB tabanlı EEG gürültü temizleme yöntemlerinin performansını değerlendirmek için orijinal gürültüsüz epileptik ve normal EEG ile gürültüden arındırılmış versiyonları arasında ortalama karesel hata (MSE) hesaplanarak Tablo 4.1’de verilmiştir.

Tablo 4.1: GKA ve OB Tabanlı Gürültü Temizleme Sonuçları.

SNR	EEG Kayıtları Gürültü Temizleme MSE Değerleri	
	Normal	Epileptik
20 dB	0.0104	0.0069
10 dB	0.0127	0.0565
0 dB	0.0531	0.1195
-10 dB	0.1819	0.2344


Böylece GKA ve OB tabanlı gürültü temizleme yöntemi ile elde edilen ÖKF’lerin hangisinin gürültüye hangisinin orijinal sinyale ait olduğu tespit edilebilmekte ve gürültüden arındırılmış versiyonunun kestirilmesi için kullanılabilir. Bu bölüme önerilen GKA ve OB tabanlı gürültü temizleme yöntemiyle elde edilen sonular bir konferans bildirisinde [24] de bahsedilmiştir.

4.1.2. Hilbert-Huang Dönüşümü ve Kümeleme Tabanlı Gürültü Temizleme

Gürültülü sinyalin GKA algoritması neticesinde elde edilen ÖKF'ler için eşik belirlenmesi HHD tabanlı hiyerarşik kümeleme ile önerilmiştir. HHD dönüşümü ile anlık frekans (AF) izgesi kümelenen ÖKF'lerin gürültünün yada gürültüden arındırılmak istenen sinyalin bileşeni olduğu tespit edilir. Önerilen HHD ve hiyerarşik kümeleme tabanlı gürültü arındırma yöntemi işlem basamakları;

- i. $x(n) = \bar{x}(n) + \sigma\eta(n)$ elde edilen gürültülü sinyaldir. $\bar{x}(n)$ orijinal gürültüsüz sinyal ve $\eta(n)$ ise beyaz gürültüyü temsil etmektedir.
- ii. Gürültülü sinyal $x(n)$ 'nin GKA ile ÖKF $\varphi_i(n)$ 'leri elde edilir. Burada $i = 1, 2, \dots, L$ ve L toplam ÖKF adedidir.
- iii. Her $\varphi_i(n)$ için HHD uygulanarak $AF_i(n)$ izgeleri elde edilir.
- iv. $AF_i(n)$ izgeleri arasında Öklit uzaklığı $d_{ij}(AF_i, AF_j) = \|AF_i(n) - AF_j(n)\|$ olarak hesaplanır, burada $i = 1, 2, \dots, L-1$ ve $j = 1, 2, \dots, L$.
- v. Benzerlik vektörü \mathbf{D} elde edilir.
- vi. \mathbf{D} vektörü $[0.1, 1]$ aralığında normalize edilir.
- vii. \mathbf{D} benzerlik vektörünün ortalaması eşik olarak kullanılır. $\theta = \frac{1}{M} \sum_{i=1}^M D_i$ ve $M = L(L-1) / 2$.
- viii. Tek bağlama yöntemi ile dendrogram elde edilir.
- ix. Gürültüden arındırılmış sinyal $\tilde{x}(n) = \sum_j \varphi_j(n)$, $j = \{i \mid D_i < \theta\}$ olarak kestirilir.


Bu işlem basamaklarında $\|\cdot\|$ Öklid normunu ve $\mathbf{D} = [d_{12}, d_{13}, \dots, d_{1M}, d_{23}, d_{24}, \dots, d_{2M}, \dots, d_{M-1M}]$ formunda benzerlik vektörünü ifade eder. Bir önceki bölüm Şekil 4.1'de verilen epileptik ve normal EEG kayıtları bu yöntemin gürültü temizleme performansını test etmek için de kullanılmıştır. Bu EEG kayıtlarının HHD sonucunda elde edilen AF izgeleri Şekil 4.8'de gösterilmiştir.




Şekil 4.8: EEG sinyallerinin Hilbert-Huang Dönüşümü.

Epileptik ve normal EEG sinyallerinin AF izgeleri incelendiğinde dalgalanmalar ve değişimlerin sinyale göre değiştiği görülmektedir. Bu durumu esas alan HHD tabanlı gürültü temizleme yönteminde gürültülü ÖKF'lerin izgelerinin diğer ÖKF'lerin izgelerinden farklı olacağı sebebiyle önerilmiştir. 20 dB SNR değerinde beyaz gürültü eklenmiş normal ve epileptik EEG işaretlerinde denenmiştir. Önerilen yöntem neticesinde Öklit uzaklığı kullanılarak elde edilen dendogram ve belirlenen eşik seviyeleri Şekil 4.9'da verilmiştir.

20 dB sinyaller için dendogramda görülen Öklid uzaklığı ile elde edilen **D** benzerlik vektörünün ortalaması alınarak elde edilen sinyal uyarlamalı eşik değeri θ ile ÖKF 1'ler beyaz gürültü salınımı olarak kabul edilmiştir. Benzer şekilde önerilen yöntem 0 dB EEG sinyalleri üzerinde test edilmiştir ve Şekil 4.10'da gösterilmiştir.




Şekil 4.9: 20 dB EEG için eşik değerleri (a) normal EEG (b) epileptik EEG.




Şekil 4.10: 0 dB EEG sinyalleri için eşik değerleri (a) normal EEG. (b) epileptik EEG.

0 dB için elde edilen sonuçlarda elde edilen eşik değerleri gereğince ÖKF 1 ve ÖKF 2 beyaz gürültü bileşeni içerdiği tespit edilmiştir ve gürültüden arındırılmış sinyallerin kestirimi için kullanılmamıştır. Bu örnek 0 dB epileptik EEG sinyalinin Şekil 4.11'de verilen ÖKF'leri ile izah edilmeye çalışılmıştır. ÖKF 1 ve ÖKF 2 beyaz gürültü bileşeni olarak kabul edilmiştir.


Önerilen yöntem kullanılarak elde edilen gürültüden arındırılmış EEG sinyalleri orijinaleri de verilerek Şekil 4.12 ve Şekil 4.13'de gösterilmiştir.



Şekil 4.11: 0 db epileptik EEG sinyalinin ilk dört ÖKF'si.



Şekil 4.12: 20 dB EEG sinyalleri için yöntem sonuçları.



Şekil 4.13: 0 dB EEG sinyalleri için yöntem sonuçları.

20 dB ve 0 dB epileptik ve normal EEG sinyalleri üzerinde test edilen HHD ve hiyerarşik kümeleme tabanlı gürültü temizleme yönteminin performansını değerlendirmek için gürültüden arındırılmış sinyaller ile orijinaler kıyaslanarak Tablo 4.2’de verilmiştir.

Tablo 4.2: Gürültü Temizleme Sonuçları.

SNR	EEG Kayıtları Gürültü Temizleme Performansı (dB)	
	Normal	Epileptik
20 dB	12.05	7.58
0 dB	27.34	20.08

Böylece, önerilen HHD ve hiyerarşik kümeleme neticesinde gürültüden arındırma işlemi başarılı olabilmektedir. Bu başarı normal EEG sinyalleri için epileptiğe oranla daha yüksektir. Bu yonteme ait sonuçları konferansta [23] ve kitap bölümünde [71] sunulmuştur.

4.1.3. Eğimden Arındırılmış Dalgalanma Analizi ve Görgül Kip Ayrışımı Tabanlı Gürültü Temizleme

Önerilen EADA ve GKA tabanlı gürültü temizleme yöntemi sinyalin ÖKF’leri arasında gürültülü olanların EADA kullanılarak tespit edilmesi esasına dayanır. EADA üstelinin belirli istatistiksel özellikteki sinyaller için statik değer vermesi sebebiyle bu çalışma için


önerilmiştir. EADA üsteli, beyaz gürültü, pembe gürültü ve Brownian gürültüsü için $\alpha = 0.5$, $\alpha = 1.0$ ve $\alpha = 1.5$ değerlerini vermektedir. Ara değerler olarak, anti-ilintili sinyaller için $\alpha < 0.5$ ve herhangi bir durağan olmayan sinyal için $\alpha > 1.0$ olmaktadır.

Beyaz gürültülü ÖKF'lerin tespiti için diğer yöntemlerde önerilenlerin tersine bu yöntemde, her ÖKF için statik bir aralık belirlenir. Diğer bir ifade ile ön tanımlı beyaz gürültü tespit aralığı ile ÖKF'ler sınanır. Bu seviye diğerlerindeki gibi sinyal uyarlamalı veya SNR gibi parametrelere bağlı olarak değişmez. Önerilen EADA ve GKA tabanlı gürültü temizleme algoritması;


- i. $x(n) = \bar{x}(n) + \sigma\eta(n)$ elde edilen gürültülü sinyaldir. $\bar{x}(n)$ orijinal gürültüsüz sinyal ve $\eta(n)$ ise beyaz gürültüyü temsil etmektedir.
- ii. Gürültülü sinyal $x(n)$ 'nin GKA ile ÖKF $\varphi_i(n)$ 'leri elde edilir. Burada $i = 1, 2, \dots, L$ ve L toplam ÖKF adedidir.
- iii. Her $\varphi_i(n)$ için EADA üsteli, α_i bulunur.
- iv. Eşik değeri, $\theta = \alpha \pm 0.25$ olarak, $\alpha = 0.5$ beyaz gürültü değeri ve ± 0.25 emniyet aralığı eklenerek belirlenir.
- v. Gürültüden arındırılmış sinyal; $\tilde{x}(n) = \sum_j \varphi_j(n)$, $j \neq \{i | \theta_{\min} < \alpha_i < \theta_{\max}\}$ olarak, EADA eğimi bu aralıkta olmayan ÖKF'ler kullanılarak oluşturulur.

Bu yöntem sentetik sinyal olan parçalı fonksiyon üzerinde ve diğer sentetik sinyaller üzerinde denenmiştir. 0 dB parçalı fonksiyon ve ÖKF'leri Şekil 4.14'de gösterilmiştir. 0 dB parçalı fonksiyon için elde edilen 11 adet ÖKF ve bir artık için EADA kullanılarak elde edilen eğim, α değerleri ile ÖKF'lerin beyaz gürültü içerenleri belirlenecektir.

Şekil 4.15'de 0 dB parçalı fonksiyon ÖKF'lerinin EADA eğimleri verilmiştir.



Şekil 4.14: 0 dB parçalı fonksiyon ve ÖKF'leri.




Şekil 4.15: 0 dB parçalı fonksiyon ÖKF'leri için EADA eğimleri.

Şekil 4.15 referans alınarak, önerilen GKA-EADA tabanlı gürültü arındırma yönteminde ÖKF 1 ve ÖKF 2 beyaz gürültünün bileşenleri olarak tespit edilmiştir. Böylece


gürültüden arındırılmış sinyal $\tilde{x}(n) = \sum_{j=3}^{11} \varphi_j(n) + r(n)$ olarak kestirilir.

Bu yöntem ayrık dalgacık dönüşümü (ADD) tabanlı yumuşak ve sert eşikleme ile kıyaslanarak Şekil 4.16’da gösterilmiştir.



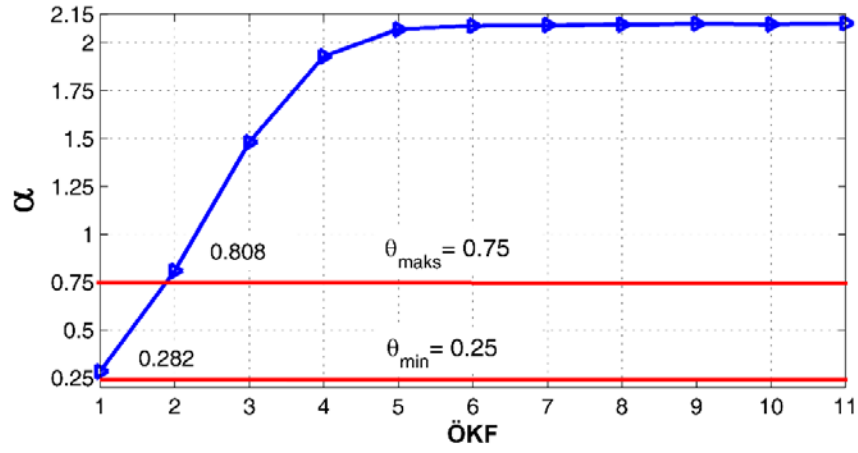
Şekil 4.16: GKA-EADA tabanlı gürültü temizleme yöntemi karşılaştırma.

Önerilen yöntem için 6.066 dB SNR elde edilirken, ADD yumuşak ve sert eşikleme için bu değerler 1.277 dB ve -0.05 dB olmaktadır. Bu örnekte görüldüğü gibi yüksek oranda gürültü karışan sinyaller için önerilen GKA-EADA tabanlı yöntem daha başarılıdır. Benzer işlem basamakları aşağıda Şekil 4.17’de gösterilen 20 dB parçalı fonksiyon ve ÖKF’lerine uygulanmıştır.



Şekil 4.17: 20 dB parçalı fonksiyon ve ÖKF’leri.

ÖKF’ler için uygulanan EADA neticesinde elde edilen eğimleri Şekil 4.18’de verilmiştir.




Şekil 4.18: 20 dB parçalı fonksiyon için EADA eğimleri.

Böylece eşik aralığında kalan ilk ÖKF yeniden oluşturma işlemine dahil edilmeyerek

$\tilde{x}(n) = \sum_{j=2}^{12} \varphi_j(n) + r(n)$ olarak gürültüden arındırılmış sinyal elde edilir. Elde edilen


gürültü temizleme sonuçları ADD ile kıyaslanarak Şekil 4.19'da gösterilmiştir.



Şekil 4.19: GKA-EADA gürültü temizleme karşılaştırması.


Sonuçlar incelendiğinde ADD tabanlı yumuşak ve sert eşikleme yüksek SNR değerlerinde daha başarılı sonuç vermektedir. ADD yumuşak ve sert eşikleme 26.508 dB ve 24.901 dB SNR değerlerine sahipken önerilen GKA-EADA tabanlı yöntem 22.373 dB SNR değerine ulaşabilmektedir. Bunun sebebi GKA algoritmasının ortak mod karıştırma problemi Bu dezavantaj önceden de belirtildiği üzere birden fazla bileşenin tek ÖKF içerisinde yer almasıdır. Bu yüzden bu örnekte atılan ÖKF 1 hem beyaz gürültü hem de orijinal sinyalin bileşenlerini içerdiği için biraz daha düşük SNR değerlerine sahip olmaktadır. Fakat 2.373 dB iyileştirme yapabilmektedir.

Önerilen yöntem EEG sinyali üzerinde de denenmiştir. Şekil 4.20’de gösterilen epileptik EEG ile denenmiştir. GKA ile gürültü temizleme yönteminin diğer avantajı olan taban kayması temizleme özelliğini göstermek için bu EEG sinyaline doğrusal artan taban kayması eklenmiştir. Böylece $x(n) = \bar{x}(n) + \sigma\eta(n) + v(n)$ olarak beyaz gürültü ve taban kayması $v(n) = n$ eklenmiştir.



Şekil 4.20: Taban kayması eklenen 0 dB epileptik EEG ve ÖKF’leri.


Taban kayması eklenen 0 dB epileptik EEG sinyali için elde edilen ve Şekil 4.21’de verilen EADA eğimleri neticesinde eşiklendirme uygulanarak gürültüden arındırma işlemi tamamlanmıştır.




Şekil 4.21: 0 dB epileptik için EADA eğimleri ve eşik aralığı.

ADD tabanlı yumuşak ve set eşikleme ile kıyasladığımızda ise önerilen GKA-EADA tabanlı gürültü temizleme daha başarılı olarak gürültüyü bastırmaktadır. Şekil 4.22’de bu karşılaştırma sonuçları verilmiştir.

Şekil 4.22’de verilen gürültüsü temizlenmiş epileptik EEG sinyalleri incelendiğinde, önerilen GKA-EADA ve ADD tabanlı yöntemlerde de taban kayması mevcuttur. GKA algoritmasının diğer avantajı olan taban kayması temizleme özelliği ise önerilen bu yöntemin bir avantajı olarak sunulabilir. Eşik veya herhangi bir ölçüt gerektirmeden son ÖKF olan artık, $r(n)$ yeniden oluşturma sürecine katılmazsa taban kayması olan sinyaller için hem gürültü hem de taban kayması temizleme işlemi yapılabilir. Bu durumun izahı için Şekil 4.23’de atığın dahil edilerek ve dahil edilmeyerek yapılan gürültü temizleme gösterilmiştir.




Şekil 4.22: Epileptik EEG gürültü temizleme sonuçları.



Şekil 4.23: Artığın taban kayması temizleme üzerine etkisi.

artık gürültüsüz sinyalin oluşturulma işlemine dahil edilmediğinde başarılı biçimde taban kaymasında ortadan kaldırarak gürültü temizleme yapabilmektedir. Şekil 4.24’de gösterilen sentetik sinyaller üzerinde de denemeler yapılarak GKA-EADA yönteminin performansı test edilmiştir ve tüm sonuçlar Tablo 4.3’de verilmiştir.



Şekil 4.24: Kullanılan diğer sentetik sinyaller.

Tablo 4.3: GKA-EADA gürültü temizleme kıyaslama tablosu.

Sinyal	SNR (dB)	EADA-GKA (dB)	ADD-Yumuşak (dB)	ADD-Sert (dB)
Parçalı Fonksiyon	0	6.066	1.277	-0.050
	10	15.586	14.120	10.215
	20	22.373	26.508	24.901
Epileptik EEG	0	5.873	-0.040	-0.060
	10	14.706	9.991	9.938
	20	22.259	20.083	19.939
Normal EEG	0	5.940	0.111	-0.060
	10	15.484	10.354	9.938
	20	22.710	21.231	19.955
Vuru	0	5.900	7.522	7.521
	10	12.941	11.825	11.825
	20	19.412	12.631	12.631
Blok	0	6.012	7.942	2.643
	10	15.363	16.614	16.614
	20	21.287	19.714	19.714
Doppler	0	6.131	8.893	8.893
	10	15.746	17.501	17.501
	20	23.259	21.768	21.768

Tablo 4.3’de elde edilen sonuçlar neticesinde önerilen GKA-EADA tabanlı gürültü temizleme yöntemi özellikle 0 dB gibi yüksek gürültülü sinyallerde daha başarılı sonuçlar vermektedir. Sinyal tipine göre yorumlandığında ise parçalı fonksiyon gibi sentetik sinyal ve epileptik ile normal EEG sinyallerinde dalgacık dönüşümü tabanlı yöntemlere göre daha başarılı olmaktadır. Kısaca dalgacık dönüşümü tabanlı metotların başarı sağlayamadığı sinyallerde 5-6 dB daha başarılı fakat dalgacık dönüşümünün başarı sağladığı yerlerde 0-1 dB daha az başarılı veya çok yakın sonuçlar vermektedir. Bu çalışma sonuçları bildiri [72] ve makalede [73] verilmiştir.

4.1.4. Görgül Kip Ayrışımı ve Eğimden Arındırılmış Dalgalanma Analizi İle Elektrokülogram (EOG) Gürültü Temizleme

Elektrokardiogram (EKG), elektromiyogram (EMG) ve elektrokülogram (EOG) gibi vücudun diğer sinirsel faaliyetlerinin neticesinde ortaya çıkan biyolojik sinyaller ile beyin sinir hücrelerin ürettiği sinyaller karışmaktadır. Böylece, ön işlem olarak EEG sinyallerine gürültü temizleme yöntemlerini uygulamak gerekmektedir.

EOG gürültü temizleme ise gözün EEG elektrotlarına yakın olmasından dolayı yüksek genlikli, keskin ve baskın bir gürültüdür ve temizlenmesi önem arz eden öncelikli bir gereksinimdir. Özellikle, göz kırpması gözün dikey ve yatay hareketine göre daha şiddetli bir gürültü kaynağı oluşturmaktadır.

EOG gürültü temizleme, görgül kip ayrışımı ile elde edilen ÖKF'lerin istatistiksel özelliklerinin eğimden arındırılmış dalgalanma analizi ile incelenmesi esasına dayanmaktadır. EOG gürültülü EEG sinyali GKA algoritmasına uygulanır ve EADA eğimine göre ÖKF'lerin yeniden oluşturma işlemine dahil edilerek gürültüden arındırılmış sinyal elde edilir.


Gürültülü EEG sinyali $x(n) = \bar{x}(n) + \varepsilon(n)$ olarak orijinal EEG sinyali $\bar{x}(n)$ ile EOG gürültüsü $\varepsilon(n)$ 'nin karışımı şeklinde ifade edilirse, önerilen yöntem için işlem basamakları:

- i. $x(n)$ GKA algoritması ile ÖKF'leri $\varphi_i(n)$, $i = 1, 2, \dots, L$ elde edilir. L ise toplam ÖKF adedini temsil eder.


- ii. Her $\varphi_i(n)$ EADA'ye uygulanarak eğimleri α_i elde edilir.
- iii. Eşik değeri $\theta = 0.4$ olarak belirlenir. Bu eşik değeri 0.1 koruma aralığı gözetilerek $\theta < 0.4$ 'den küçük EADA eğimine sahip ÖKF'lerin tespiti için kullanılır.
- iv. Gürültüden arındırılmış EEG sinyali $\tilde{x}(n)$, $\theta = 0.4$ 'den büyük EADA eğim α 'li ÖKF'lerin toplamı olarak elde edilir: $\tilde{x}(n) = \sum_j \varphi_j(n)$, $j = \{i \mid \alpha_i > \theta\}$.

olarak yazılabilir. Bu yöntemde EADA eğimi, $\theta < 0.5$ için anti-ilintili zaman serisi tanımlayıcısı referans alınarak eşik değeri belirlenmiştir. EOG gürültüsünde göz kırpmasının seyrek ve yüksek genlikli özelliğinin anti-ilintili sinyal özelliği göstermesinden kaynaklanmaktadır.

EADA ile önerilen eşik belirleme yöntemi esaslı GKA ile gürültü temizleme metodu için örnekleme frekansı 256 Hz ($f_s = 256$ Hz) olan dikey ve yatay EOG (vEOG, hEOG) gürültüsü ile 10-20 kanal standardına uyumlu 6 kanal (Fp1, Fp2, C3, C4, O1, O2) EEG sinyalini içeren veri seti kullanılmıştır [45]. Bu kanallar içerisinde Şekil 4.25 ve Şekil 4.26'de gösterilen C3 ve vEOG gürültülü sinyal önerilen yöntem ile denenmiştir.



Şekil 4.25: C3 kanal EEG sinyali.




Şekil 4.26: v-EOG kanal gürültüsü.

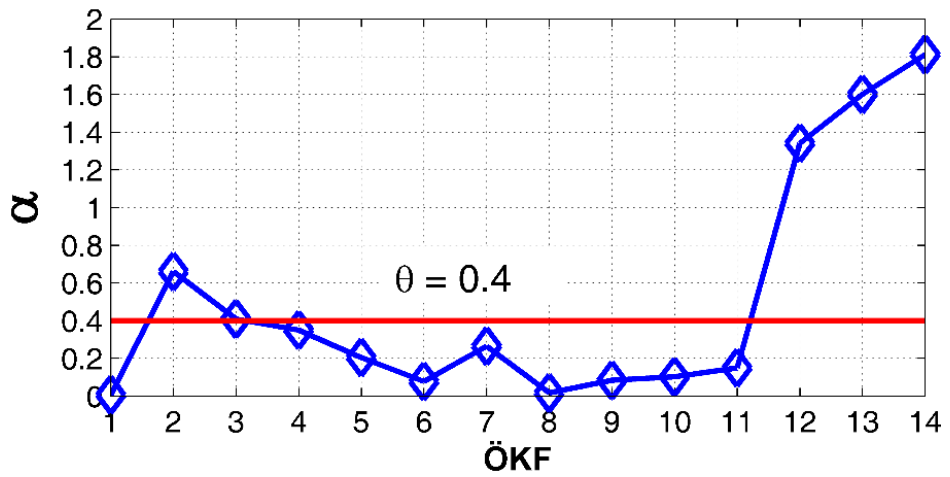
Her iki şekil incelendiğinde EEG kanalında görülen yüksek genlikli ve düşük frekanslı bileşenlerin v-EOG kaynaklı olduğu anlaşılmaktadır. Önceden de belirtildiği gibi, her sinyal karışım oranı bilinmemekle birlikte her iki sinyali de içermektedir. Diğer ifadeyle, EEG sinyali nöron aktivitesi sonucu oluşan elektriksel sinyal ile birlikte daha az oranda EOG gürültüsü içerir. Bu oran elektrotların kaynaklara olan uzaklığına bağlı olarak değişmektedir.

Şekil 4.25’de verilen C3 kanalı EEG sinyali gürültüden arındırılmak istenen sinyal olması sebebiyle GKA algoritmasına uygulanmıştır ve Şekil 4.27’de gösterilen ÖKF’lere EADA uygulanarak üstel eğimleri hesaplanmıştır.

Gösterilen salınımlar içerisinde özellikle ÖKF4-ÖKF8 yüksek genlikli düşük frekanslı darbe benzeri bileşen içermektedir. Gözle fark edilebilen bu özelliği EADA ile eşiklendirmek bu çalışmanın temelini oluşturmaktadır. Bu sebeple her ÖKF EADA’ye uygulanır ve belirlenen eşik değeri ile birlikte Şekil 4.28’de verilmiştir.




Şekil 4.27: v-EOG gürültüsü içeren C3 kanalının ÖKF'leri.



Şekil 4.28: v-EOG içeren C3 kanal ÖKF'leri için EADA eğimleri.

Eşik değeri $\theta = 0.4$ için $\varphi\{2,3,12,13,14\} > \theta$ 'dir. Böylece bu ÖKF'ler kullanılarak yapılan yeniden oluşturma neticesinde EEG $\tilde{x}(n)$ sinyali elde edilir. Görsel olarak daha net görülebilmesi sebebiyle temizlenen EOG gürültüsü orijinal gürültülü EEG'den gürültüden arındırılmış versiyonu çıkarılarak bulunur $\varepsilon(n) = x(n) - \tilde{x}(n)$ ve Şekil 4.29'da gösterilmiştir.



Şekil 4.29: C3 EEG kanalından temizlenen v-EOG gürültüsü.

Vücuttaki biyolojik kaynaklı sinyallerin birbiri ile karışması sebebiyle v-EOG kanalından saf EOG gürültüsü elde edilemediği gibi, EEG kanal kayıtları da sadece beyin nöron aktivitesini içermemektedir. Hem v-EOG hem de EEG kanalları bir birinden belirli bir karışım oranında içermektedir. Bu sebeple diğer kör kaynak ayrışımı (KKA) yöntemlerinde de olduğu gibi başarının ölçüsü gözleme dayanmaktadır. Fakat GKA-EADA tabanlı yöntemde sadece EEG kanalları kullanılarak bu ayrıştırma yapılabilmektedir [25, 71].

4.2. GÖRGÜL KİP AYRIŞIMI TABANLI EPİLEPTİK EEG ANALİZİ

GKA'nın algoritma ve sinyal uyarlamalı olması sebebiyle elde edilen ÖKF'lerin özellikleri de sinyal uyarlamalı ve sinyale göre değişmektedir. Farklı sinyaller için elde

edilen ÖKF'lerin frekans ve zaman bölgesinde özellikleri analiz edilerek uygulanan sinyal için çeşitli analiz yöntemleri geliştirilebilir.

Bu tez çalışması kapsamında epileptik atakların EEG sinyalleri kullanılarak tanınması ve tespit edilmesi konusu incelendiği için normal EEG ve epileptik EEG sinyalleri uygulanan GKA algoritmasının ayırttığı ÖKF'lerin analizi için frekans bölgesi ve zaman bölgesinde çeşitli ölçütler ile öznelikleri çıkarılacaktır. Bölüm 3.'de verilen GKA özellikleri bu analizin temelini oluşturacaktır.

Frekans bölgesi öznelik çıkarma olarak, GKA süzgeç öbeği yapısı neticesinde ÖKF'lerin enerji dağılımları ölçüt olarak alınmıştır. Zaman bölgesinde ise ÖKF'lerin öz-ilişim özelliklerini kapsayacak EADA üsteli ölçüt olarak kullanılmıştır. Son olarak ÇDGKA ile normal ve epileptik EEG özellikleri kıyaslanarak referans tabanlı yöntem önerilmiştir. GKA tabanlı epileptik EEG analiz yöntemleri konferans bildirisi [74], kitap bölümü [71] olarak sunulmuştur.

4.2.1. Frekans Bölgesi Ölçütü ile Görgül Kip Ayırımı Tabanlı Epileptik EEG Analizi

GKA'nın Bölüm 3.3'de ve Şekil 3.6'da verilen süzgeç öbeği yapısı frekans bölgesi epileptik EEG analizi için temel özelliği oluşturmaktadır. Sinyal uyarlamalı olan süzgeç yapıları sebebiyle uygulanan sinyale göre her ÖKF'nin bant genişliği değişmektedir. Bu yüzden ÖKF'lerin toplam enerji dağılımları sinyale göre değişmektedir. Bu enerji değerleri ise önerilen GKA ile frekans bölgesi yönteminin temelini oluşturmaktadır. Yapılan orijinal çalışmada [47] ve Bölüm 3.3'de izah edildiği gibi sinyalin Hurst üsteli ile karakterize edilen süzgeç öbeği yapısı referans olarak alındığında epileptik ve normal EEG için $H = 0.66$ ve $H = 0.90$ çıkmaktadır. Böylece, düşük Hurst üsteline sahip epileptik EEG için oluşan GKA süzgeç öbeği yapısı neticesinde ÖKF'lerin enerji dağılımlarının farklı olması gerekmektedir. İşlem basamakları;

- i. $x(n)$ tipi bilinmeyen epileptik veya normal EEG sinyalidir.
- ii. EEG sinyali $x(n)$ 'nin GKA ile ÖKF'leri $\varphi_i(n)$, $i = 1, 2, \dots, L$, elde edilir. L elde edilen toplam ÖKF adedidir.

iii. Her ÖKF'nin enerji seviyesi $S_i(f) = \sum_{n=0}^{N-1} \left[\left| \sum_{n=0}^{N-1} \varphi_i(n) e^{-j(2\pi f/F_s)n} \right|^2 \right]$ olarak ayrık

Fourier dönüşümü ile bulunur.


iv. Enerji dağılımı S 'i karakteri etmek için varyansı $\sigma^2 = \frac{1}{L} \sum_{i=1}^L [S_i - \bar{S}]^2$ hesaplanır.

v. M adet EEG kanallı uygulamalar için her kanal için elde edilen σ^2 için ortalaması

$$\bar{\sigma}^2 = \frac{1}{M} \sum_{i=1}^M \sigma_i^2 \text{ bulunur.}$$


vi. Yukarıdaki işlem basamakları bir sonraki epok için tekrarlanır.

Süzgeç öbeği yapısı neticesinde elde edilen ÖKF'lerin GIY'ları Şekil 4.30'da gösterilmiştir.



Şekil 4.30: EEG güç izgesel yoğunlukları. (a) epileptik (b) normal.


ÖKF'lerin GİY'leri incelendiğinde ÖKF1 yaklaşık olarak 0-0.42 normalize frekans (f_n) (0-73Hz) arası salınım içerirken, ÖKF 2 ise 0-0.38 Fn (0-65Hz) arasındadır. Genel olarak ÖKF'lerin yüksek frekansı birinciden sonuncuya doğru azalmaktayken, her ÖKF'ler düşük frekansları ortak olarak kapsamaktadır. Bu özellik sonucunda her ÖKF'lerin enerji dağılımlarının normal ve epileptik EEG'ye göre değişmesi beklenmektedir. ÖKF'lerin enerji dağılımları Şekil 4.31'de verilmiştir.



Şekil 4.31: EEG sinyallerine ait ÖKF güç dağılımları.


Şekil 4.31'de görülen ÖKF enerji dağılım düzenleri epileptik ve normal EEG için farklıdır. Epileptik EEG için ÖKF 1 en yüksek enerji seviyesine sahipken ve ÖKF numarası büyüdükçe kısmen azalma eğimi gösterirken, normal EEG için son ÖKF'ler daha yüksek enerji seviyelerine sahip olmaktadır. Bu dağılımı karakterize edebilen varyans değerleri toplam 58 adet iki saniyelik EEG epokları üzerinde denenmiştir ve Şekil 4.32'de önerilen GKA ve frekans bölgesi özellikli epileptik EEG analizinin başarısı gösterilmiştir.

İlk 29 epok epileptik için ÖKF enerji dağılımlarının varyansı normal EEG'ye çok yüksek çıkmıştır. Böylece ÖKF'lerin enerji dağılımları epileptik ve normal EEG için başarılı bir analiz olarak kullanılabilir.




Şekil 4.32: GKA frekans bölgesi ölçütü ile epileptik EEG analizi.

Çok kanallı EEG için kanal adedince ortalaması alınan varyans değeriyle elde edilen sonuçlar Şekil 4.33'de gösterilmiştir.



Şekil 4.33: 23 kanallı EEG kayıtları için GKA frekans bölgesi sonuçları.

23 kanallı EEG kayıtlarında önerilen GKA frekans bölgesi tekniği ile sekiz adet epileptik epok içerisinde iki tanesi normal epok ile örtüşen değer almaktadır. Tek kanal sonuçlarında %100 doğruluk ile tespit edilebilirken, bu başarımın çok kanallı kayıtlarda azalmasının sebebi Şekil 4.34'de izah edilmeye çalışılmıştır.



Örnek

Şekil 4.34: EEG kanallarında epileptik sinyalin baskın olduğu kanallar.


Şekil 4.34 incelendiğinde epileptik sinyalin baskın olduğu kanal adedi kadar EEG sinyalinin olmadığı kanal sayısının bulunmasıdır. Diğer bir deyişle, 23 kanalın ÖKF'lerinin ayrı ayrı enerji dağılımlarının varyansının ortalamasına epileptik sinyalin var olmadığı diğer kanallarında dahil edilmesidir. Bu sebeple normal ve epileptik sinyal için tek kanala göre daha yakın değerler elde edilebilmektedir.

4.2.2. Zaman Bölgesi Ölçütü ile Görgül Kip Ayrışımı Tabanlı epileptik EEG Analizi

Zaman bölgesi ölçütü olarak diğer çalışmalarımızda da kullanılan EADA seçilmiştir. Bir zaman serisinin öz-iliinti özelliklerini ölçmeye yarayan bu analiz ile epileptik ve normal EEG ÖKF'leri incelenmiştir. Önceki bölümde Hurst üsteliyle de izah edilen epileptik sinyallerin normal EEG sinyallerine kıyasla zaman içerisinde dalgalanmalar göstermekte ve istatistiki özellikleri hızla değişmektedir. Bu durumun fizyolojik sebebi olarak ise kontrol dışı ve aniden boşalan sinir hücrelerinin elektriksel aktivitesidir. Bu istatistiki özelliği EADA kullanarak ölçen epileptik EEG analiz yöntemi işlem basamakları;

- i. EEG sinyali, $x(n)$ GKA algoritmasına uygulanır.
- ii. Elde edilen ÖKF, $\varphi_i(n)$ 'ler EADA algoritmasına uygulanır. $i=1,2,\dots,L$ ve L toplam ÖKF adedini temsil eder.
- iii. Her $\varphi_i(n)$ için EADA eğimi α_i hesaplanır.
- iv. α_i 'lerin istatistiki olarak değerlendirmek için dağılımın basıklık değeri, b bulunur, $b = \frac{E(\alpha - \bar{\alpha})^4}{\sigma^4} = \frac{\frac{1}{L} \sum_{i=1}^L (\alpha_i - \bar{\alpha})^4}{\left(\frac{1}{L} \sum_{i=1}^L (\alpha_i - \bar{\alpha})^2 \right)^2}$.
- v. M kanallı EEG kayıtları için, $\bar{b} = \frac{1}{M} \sum_{i=1}^M b_i^2$ şeklinde ortalaması alınır.
- vi. Yukarıdaki işlemler bir sonraki epok için tekrarlanır.


burada $E(\cdot)$ beklenen değer operatörü, $\bar{\alpha}$ ÖKF eğimlerinin ortalaması ve σ ise standart sapmasıdır. Önerilen EADA ve GKA tabanlı epileptik EEG analizinin temelini oluşturan EADA eğim grafiği normal ve epileptik EEG için Şekil 4.35'de verilmiştir.



Şekil 4.35: EEG sinyalleri için ÖKF'lerin EADA eğimleri.

Şekil 4.35 incelendiğinde epileptik EEG için ilk 1 ya da 2 ÖKF'ler için EADA eğimlerinin daha düşük çıktığı görülmektedir. Bu grafikteki değerleri baz alarak önerilen yöntemde bu EADA eğimlerinin dağılımları basıklık değeri ile nitelendirilebilmektedir.

Böylece 58 epok için ÖKF'lerinin EADA basıklık değerleri çıkarılmıştır ve Şekil 4.36'da verilmiştir.




Şekil 4.36: GKA-EADA tabanlı epileptik EEG analiz sonuçları.

Toplam 58 epok ve 20000 örnek EEG sinyali için ÖKF'lerin EADA'ye uygulanması neticesinde elde edilen üstellerinin eğimini basıklık metodu ile analizi EEG sinyalleri için ayırt edici özellik göstermektedir. 11, 12 ve 15. epileptik epoklar ise normal EEG sonuçları ile örtüşmektedir. Böylece %94.9 başarı oranına sahip zaman bölgesi ölçütü kullanılarak epileptik EEG analizi yapılmıştır.

Çok kanallı EEG analizi için gün içi uzun süreli kayıtlardan oluşan CHB- MIT EEG veri seti kullanılmıştır. 23 kanallı EEG kayıtlarına uygulanan yöntem tek kanal için uygulanan yöntem neticesinde elde edilen basıklık değerinin 23 kanal için ortalaması alınarak hesaplanır. Çok kanallı EEG için önerilen GKA ve EADA içerikli yöntem sonucu Şekil 4.37'de gösterilmiştir.

Çok kanallı epileptik atak analizinde frekans bölgesi sonuçlarında da görüldüğü gibi zaman bölgesi yönteminde de örtüşen değerler olabilmektedir. Bu örtüşme epileptik atak sinyalinin çok zayıf olduğu kanallara da her iki sinyal işleme yöntemi uygulanması neticesinde oluşmaktadır ve başarı düşmektedir. Genel olarak bu yüzden tek kanal sinyaller üzerinde yapılan uygulamalar daha başarılıyken, frekans bölgesi ölçütü ise zaman bölgesi ölçütüne göre daha başarılı bir yöntemdir.



Şekil 4.37: 23 kanallı EEG için GKA-EADA tabanlı epileptik EEG analizi.

4.2.3. Çok Değişkenli Görgül Kip Ayrışımı Tabanlı Epileptik EEG Analizi

ÇDGKA ile önerilen epileptik ve normal EEG analizi için referans tabanlı yöntem adı da verilebilir. Bu yöntemde birer epok normal $x_{No}(n)$ ve epileptik EEG $x_{Ep}(n)$ sinyalleri sabit kalmak şartı ile analiz edilmek istenen EEG $x_{EEG}(n)$ sinyaliyle birlikte ÇDGKA'ya aşağıdaki denklem (3.35) gibi uygulanır.

$$\mathbf{x} = \begin{bmatrix} x_{EEG}(n) \\ x_{Ep}(n) \\ x_{No}(n) \end{bmatrix} \quad (4.1)$$

Elde edilen ÖKF'lerin özellikleri incelenerek analiz tamamlanır. Bu yöntemin işlem adımları;

- i. Analiz edilecek $x_{EEG}(n)$ x'e yukarıdaki gibi entegre edilir ve ÇDGKA'ya uygulanır.
- ii. Sırası ile analiz edilecek EEG, epileptik ve normal EEG ÖKF'leri; $\varphi_i^{EEG}(n)$, $\varphi_i^{Ep}(n)$ ve $\varphi_i^{No}(n)$ elde edilir. Burada $i=1,2,\dots,L$ ve L toplam ÖKF adedini temsil eder.

iii. $\varphi_i^{EEG}(n)$, $\varphi_i^{Ep}(n)$ ve $\varphi_i^{No}(n)$ için güç izgesel yoğunlukları

$$\hat{P}_i^{EEG}(f) = \frac{\Delta t}{N} \left| \sum_{n=0}^{N-1} \varphi_i^{EEG}(n) e^{-j2\pi fn} \right|^2, \quad \hat{P}_i^{Ep}(f) = \frac{\Delta t}{N} \left| \sum_{n=0}^{N-1} \varphi_i^{Ep}(n) e^{-j2\pi fn} \right|^2$$

$$\hat{P}_i^{No}(f) = \frac{\Delta t}{N} \left| \sum_{n=0}^{N-1} \varphi_i^{No}(n) e^{-j2\pi fn} \right|^2 \quad -1/2\Delta t < f \leq 1/2\Delta t \text{ olarak periodogram ile}$$

kestirilir.


iv. Benzerlik Öklit uzaklığı kullanılarak belirlenir,

$$D_{EEG,Ep} = \left\| \hat{\mathbf{P}}^{EEG} - \hat{\mathbf{P}}^{Ep} \right\| = \sqrt{\sum_{i=1}^L (\hat{P}_i^{EEG} - \hat{P}_i^{Ep})^2}$$

$$D_{EEG,No} = \left\| \hat{\mathbf{P}}^{EEG} - \hat{\mathbf{P}}^{No} \right\| = \sqrt{\sum_{i=1}^L (\hat{P}_i^{EEG} - \hat{P}_i^{No})^2}.$$


v. Eğer $D_{EEG,Ep} < D_{EEG,No}$ ise $x_{EEG}(n)$ epileptik EEG'dir. Eğer $D_{EEG,Ep} > D_{EEG,No}$ ise $x_{EEG}(n)$ normal EEG'dir.

Böylece elde edilen EEG ÖKF'lerinin güç dağılımının benzer olduğu epileptik veya normal EEG'ye göre tanılama yapabilmeye olanağı sağlanmış olur. ÇDGKA tabanlı epileptik EEG analizinin temelini ÇDGKA sinyal uyarlamalı süzgeç öbeği yapısı oluşturmaktadır. Frekans bölgesinde benzer özelliklere sahip giriş sinyallerinin ÖKF'leri de benzer özelliklere sahip olmaktadır. Bu benzerlik en temel frekans bölgesi analiz tekniği olan GİY'lerinin bulunması ile incelenebilmektedir. Bu özellik Şekil 4.38'de ve Şekil 4.39'da gösterilmiştir.



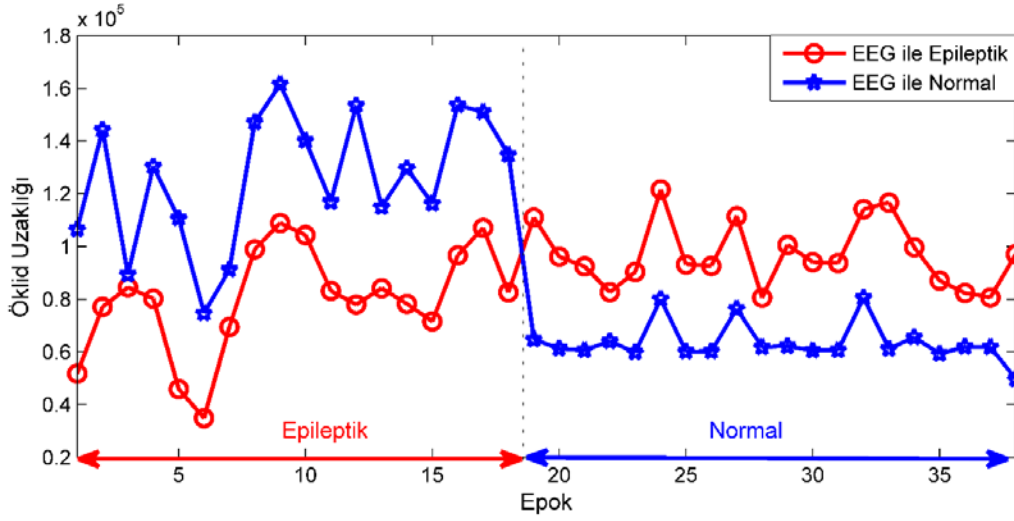
Şekil 4.38: Epileptik ÖKF'ler ile güç izgesel yoğunluk benzerliği.

Şekil 4.38'de analiz edilmek istenen EEG sinyali epileptik olması durumunda, bu sinyalin ÖKF'lerinin GİY grafikleri referans epileptik ÖKF'leri ile benzerlik gösterir. Fakat referans normal ile benzer GİY'lere sahip değildir. Önerilen ÇDGKA ile eğer analiz edilmek istenen EEG sinyali normal sağlıklı örnek ise GİY benzerlikleri Şekil 4.39'daki gibidir.



Şekil 4.39: Normal ÖKF'ler ile güç izgesel yoğunluk benzerliği.

Bu benzerlik bu çalışmanın temelini oluşturur ve bilinmeyen EEG sinyalinde epileptik atak varlığını algılamak için kullanılabilir. Bu yöntemin geçerliliğinin testi için 38 adet epok üzerinde denenmiştir ve başarı sonuç verdiği görülmüştür. Bu benzerliği algılamak için ölçüt olarak Öklit uzaklığı kullanılarak analiz edilmeye çalışılmıştır. Analiz edilmek istenen EEG ÖKF'lerinin güçleri ile referans olarak kullanılan normal ve epileptik EEG ÖKF'lerinin güç dağılımı arasında Öklit uzaklığı hesaplanarak Şekil 4.40'da verilmiştir.



Şekil 4.40: ÇDGKA ile epileptik ve normal EEG için analiz sonuçları.

Böylece önerilen ÇDGKA tabanlı ÖKF'lerin GİY'lerinin Öklit uzaklığı kullanarak gerçekleştirilen bu analiz yönteminde analiz edilmek EEG sinyalinin tipine göre referans olarak kullanılan EEG sinyaline olan Öklit uzaklığı değişmektedir. Bu ölçütün başarısı ÇDGKA'nın süzgeç öbeği yapısı ile sağlanmaktadır ve elde edilen ÖKF GİY'lerini frekans bölgesindeki benzerliği ile oluşmaktadır. Böylece 38 epok için %100 doğrulukla epileptik EEG atak tespiti yapılabilmektedir.

4.3. EEG SİNYALLERİ İLE DUYGU DURUM ANALİZİ


Bilişsel iki boyutlu duygulanım haritasında uyarılma ve değerlilik değerlerinin EEG sinyalleri kullanılarak tahmin edilmesi için uluslararası 10/20 elektrot yerleşimi düzeninde kaydedilen EEG sinyalleri kullanılmıştır. Her katılımcı için 40 video ve 40 video esnasında kaydedilen 32 kanal EEG sinyallerinden oluşan DEAP EEG veri seti elde

önerilen duygu durum analizi için kullanılmıştır. Orijinal EEG kayıtları 512 Hz örnekleme frekansı ile örneklenmiş olup, EOG ve şebeke gürültüleri temizlenip 128 Hz aşağı örnekleme ile yeniden oluşturulmuştur. Bu işlenmiş verilerin en önemli özelliği ise; katılımcıların durgun durumdaki (video başlamadan önce) kayıtları, video esnasındaki kayıtlardan çıkarılarak, duygulanım esnasındaki EEG sinyalleri değişimi bu veri setinde hazır olarak sunulmaktadır.

Duygulanma merkezinin beyin ön lobunda bulunması sebebiyle ön lobda bulunan EEG kanallarından alınan sinyallerin analizi EEG tabanlı duygu durum çalışmalarında kullanılan zorunlu kanallar olarak ifade edilebilir. Bu sebeple ÇDGKA çok kanallı yapısıyla da uyumlu olarak Şekil 4.41’de gösterilen kanallardan alınan sinyaller duygu durum analizi için kullanılmıştır.

Toplam 18 adet EEG kanalı; 8 adet sol, 8 adet sağ ve 2 adet merkez kanalı şeklinde ön lob kanallarına ait sinyaller bu çalışmada kullanılmıştır. Bu çalışmada Şekil 4.41’de verilen 18 EEG kanalı ortak referanslı sisteme göre kayıt edilmiş olup bu merkez kanallar (Cz ve Fz) hariç sol ve sağ lop kanallarının farkı alınarak (örnek, Fp1-Fp2, AF3-AF4... T7-T8) 8 adet sanal kanal EEG sinyali elde edilmiştir. Toplam olarak 26 kanal EEG sinyali ÇDGKA’ya uygulanmıştır ve her ÖKF için öznitelik çıkarma işlemi zaman ve frekans uzayında sinyal işleme teknikleri uygulanarak elde edilmiştir. Önerilen duygu durum öznitelik çıkarma ve sınıflandırma Şekil 4.42’de verilmiştir.

Önceki bölümlerde değinilen çeşitli bantlardaki spektral gücün temel alındığı yöntemlerden farklı olarak çok değişkenli ÇDGKA tabanlı duygu durum analizi gerçekleştirilmiştir. Çok kanallı EEG sinyallerinin ÇDGKA algoritması ile çok kanallı ÖKF’leri elde edilir ve her ÖKF için frekans ve zaman uzayında analizler gerçekleştirilerek öznitelikleri elde edilir. ÇDGKA algoritmasının süzgeç öbeği yapısı özelliği ile her ÖKF’nin bant aralığı farklı olmaktadır. Yüksek frekanslı birinci ÖKF’den düşük frekanslı sonuncu ÖKF’ye doğru elde edilen tüm salınımlar ÇDGKA süzgeç yapısı ile elde edilmektedir. Diğer çalışmalarda bantların spektral gücü esas alınırken bu çalışmada GKA sonucu elde edilen ÖKF’lerin çeşitli frekans aralıklarında salınıma sahip olmaları esas alınır. 20 katılımcı için 40 video izletilmesi sonucunda elde edilen 32 kanalıdan yukarıda bahsedildiği gibi 18 gerçek ve 8 sanal kanal olmak üzere toplam 26 kanallı EEG kayıtları bu çalışmada kullanılmıştır.



Şekil 4.41: Duygu durum EEG kanalları.

Her katılımcı için $40 \times 26 \times 2560$ (video*EEG kanalı*Örnek adedi) EEG sinyali ÇDGKA, öznitelik çıkarma ve sınıflandırma algoritmalarına uygulanır. Öznitelik çıkarma yöntemlerine ait eşitlikler aşağıda verilmiştir.

$$P_i^M = \frac{1}{N} \sum_{n=0}^{N-1} \varphi_i^M(n)^2 \quad (4.2)$$

$$P_i / P_M = \frac{\frac{1}{N} \sum_{n=0}^{N-1} \varphi_i^M(n)^2}{\frac{1}{N} \sum_{n=0}^{N-1} x^M(n)^2} \quad (4.3)$$

$$\widehat{P}_i^M = \frac{1}{2\pi N} \left| \sum_{n=0}^{N-1} \varphi_i^M(n) e^{-j\omega n} \right|^2 \quad (4.4)$$

$$\text{Aktivite}_i^M = \frac{1}{N} \sum_{n=0}^{N-1} [\varphi_i^M(n) - \bar{\varphi}_i]^2 \quad (4.5)$$

$$\text{Mobilite}_i^M = \sqrt{\frac{\text{Aktivite} \left(\frac{d\varphi_i^M}{dt} \right)}{\text{Aktivite}_i^M}} \quad (4.6)$$

$$\text{Komplekslik}_i^M = \sqrt{\frac{\text{Mobilite} \left(\frac{d\varphi_i^M}{dt} \right)}{\text{Mobilite}_i^M}} \quad (4.7)$$

$$H(\varphi_i^M) = -\sum_j P_j(\varphi_i^M) \log P_j(\varphi_i^M) \quad (4.8)$$

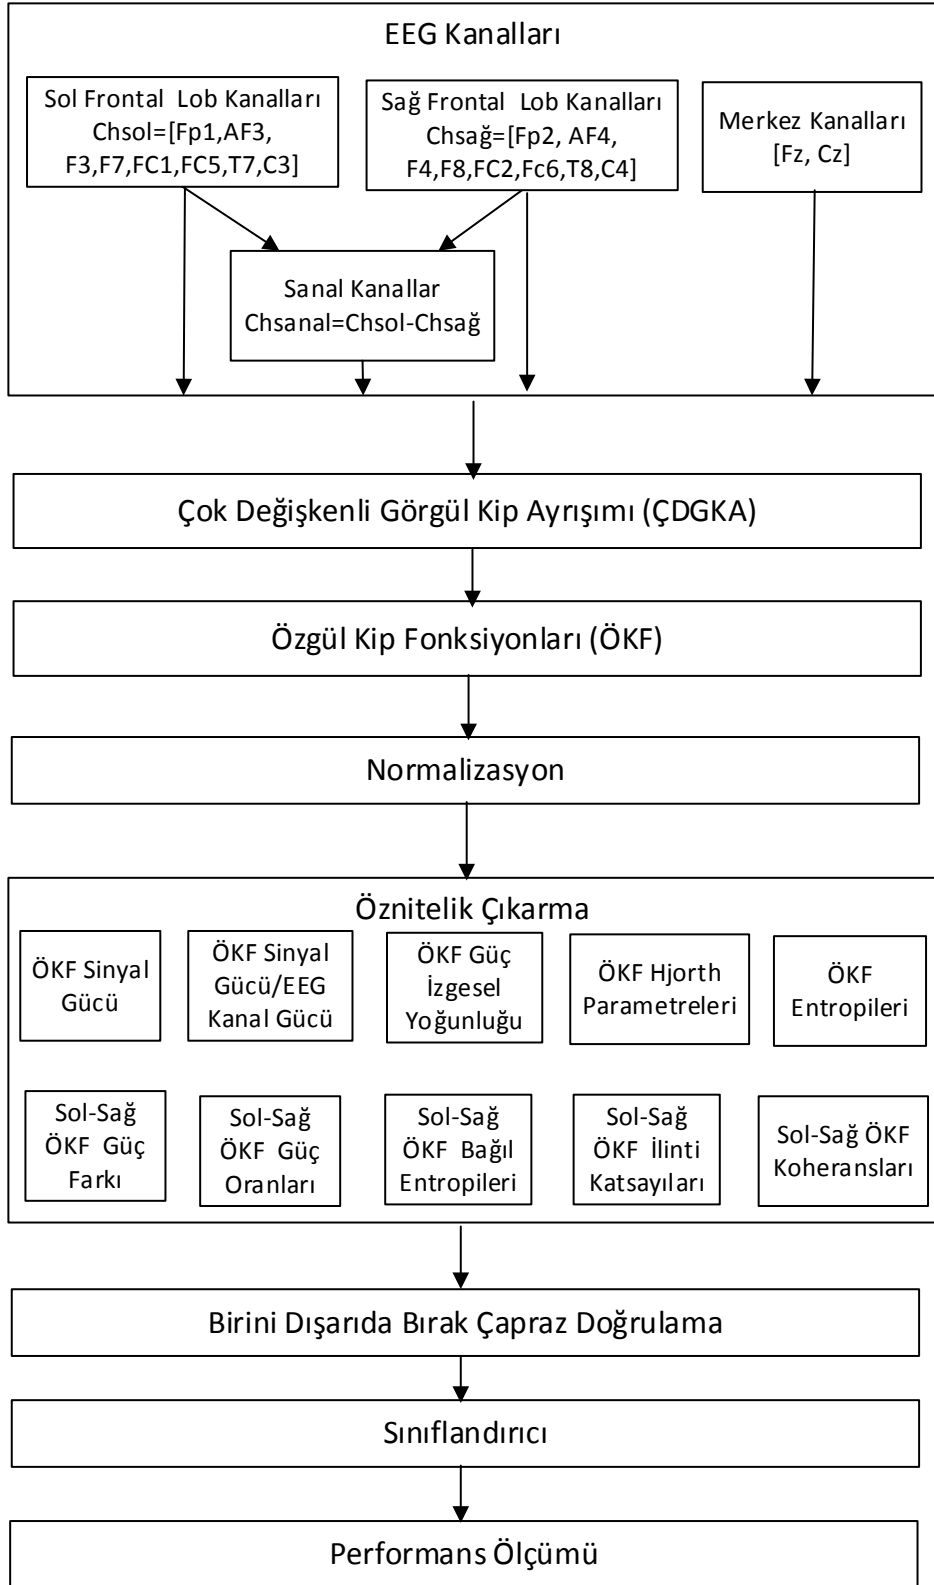
$$P_{i_{\text{Fark}}}^M = \frac{1}{N} \sum_{n=0}^{N-1} \varphi_i^M(n)^2 - \frac{1}{N} \sum_{n=0}^{N-1} \varphi_i^{M+8}(n)^2 \quad (4.9)$$

$$P_i^M / P_i^{M+8} = \frac{\frac{1}{N} \sum_{n=0}^{N-1} \varphi_i^M(n)^2}{\frac{1}{N} \sum_{n=0}^{N-1} \varphi_i^{M+8}(n)^2} \quad (4.10)$$

$$D_{KL}(\varphi_i^M \parallel \varphi_i^{M+8}) = -\sum_j P_j(\varphi_i^M) \log \frac{P_j(\varphi_i^M)}{P_j(\varphi_i^{M+8})} \quad (4.11)$$

$$\text{İlinti}(\varphi_i^M, \varphi_i^{M+8}) = \frac{\frac{1}{N} \sum_{n=0}^{N-1} (\varphi_i^M - \bar{\varphi}_i^M)(\varphi_i^{M+8} - \bar{\varphi}_i^{M+8})}{\sqrt{\frac{1}{N} \sum_{n=0}^{N-1} (\varphi_i^M - \bar{\varphi}_i^M)^2 \frac{1}{N} \sum_{n=0}^{N-1} (\varphi_i^{M+8} - \bar{\varphi}_i^{M+8})^2}} \quad (4.12)$$

$$\text{Koherans}(\varphi_i^M, \varphi_i^{M+8}) = \frac{\left| \sum_{k=-\infty}^{\infty} R_{\varphi_i^M \varphi_i^{M+8}}(k) e^{-j\omega k} \right|^2}{\widehat{P}_i^M \widehat{P}_i^{M+8}} \quad (4.13)$$



Şekil 4.42: Önerilen duygu durum sınıflandırma diyagramı.

Burada N ve M EEG kanallarında alınan sinyalin örnek sayısını ve kanal ifade etmektedir. $i = 1, 2, 3, \dots, L$ olarak elde edilen toplam ÖKF adedidir. Böylece Tablo 4.4'de özetlenen öznitelikler elde edilmiştir.


Tablo 4.4: Duygu durum tespiti için elde edilen öznitelikler.

Katılımcı sayısı	20
Video ve Duygu durum haritası	40
Toplam Örnek	800
Toplam öznitelik	7419

Elde edilen 800×7419 boyutlu duygu durum verisi için öncelikle bağımsız bileşen analizi ile indirgeme yapılır. Bu sınıflandırma işlemi bir katılımcıyı (katılımcının 40 video neticesinde vermiş olduğu 40 uyarılma/değerlilik değerleri) dışarıda bırak çapraz doğrulama yöntemi ile her katılımcı için sınıflandırma değerleri eğitim kümesi olarak kullanılmak üzere yapay sinir ağı (YSA) sınıflandırıcı ile uyarılma ve değerlilik seviyeleri belirlenmeye çalışılmıştır. YSA çıkışından elde edilen sınıflandırma sonuçları ile gerçek değerler kıyaslanarak önerilen yöntemin başarısı değerlendirilir.


Bu çalışmada önerilen, ayrıntıları verilmiş ÇDGKA algoritması tabanlı öznitelik çıkarma işlemi neticesinde elde edilen 7419 boyutlu öznitelik vektörü öncelikle bağımsız bileşen analizi (BBA) ile boyutu indirgenir. Şekil 4.43'de verilen en yüksek özdeğere sahip 250 bağımsız bileşen (BB) alınarak sınıflandırma işlemi için kullanılır.

250 adet BB seçildiğinde % 97.24 öz değer oranı ile veri temsil edilebilmektedir. Böylece elde edilen 250 boyutlu öznitelik vektörüne sahip örnekler bir katılımcıyı dışarıda bırak çapraz doğrulama yöntemi ile test ve eğitim verisi belirlenerek iki gizli katmanlı YSA ile sınıflandırılır.




Şekil 4.43: Özniteliklerin BBA sonunda elde edilen öz değerleri.

Yüksek-düşük uyarılma sınıflandırma için Şekil 4.44’de gösterilen uyarılma/değerlilik duygular durum haritası 1. ve 2. bölgeler yüksek uyarılma seviyesi sahip bölgeler olup katılımcının vermiş olduğu değerler ile sınıflandırıcı değerleri kıyaslanmıştır.



Şekil 4.44: Uyarılma/değerlilik bilişsel duygular durum haritası.


Düşük uyarılma yüksek değerlik (DUYD), yüksek uyarılma yüksek değerlik (YUYD), düşük uyarılma düşük değerlik (DUDD) ve yüksek uyarılma düşük değerlik (YUDD) bölgeleri için DEAP duygu durum EEG veri seti orijinal çalışmasında [11] yüksek/düşük uyarılma ve yüksek/düşük değerlik için sınıflandırma yapılarak önerilen yöntemler değerlendirilmiştir. Bu sebeple bu tez kapsamında önerilen ÇDGKA tabanlı öznelik çıkarma yöntemi yüksek/düşük değerlik ve uyarılma seviyeleri birini dışarıda bırak çapraz doğrulama ve YSA sınıflandırıcı kullanılarak elde edilmiştir ve orijinal çalışma ile kıyaslanmıştır. Bu sebeple önerilen yöntem ile yüksek/düşük uyarılma sınıflandırma doğruluk değerleri ve ortalaması Şekil 4.45’de gösterilmiştir.



Şekil 4.45: YSA ile yüksek-düşük uyarılma doğruluk sonucu.

Uyarılma seviyesi sınıflandırma sonucunda 13. Katılımcının duygu durumu sınıflandırmasında %95 ile en yüksek doğruluk elde edilirken, en düşük doğruluk %65 ile 11. katılımcıda elde edilmiştir. Tüm bu sınıflandırmanın ortalaması ise %75 (± 7.48)’dir.

Yüksek-düşük uyarılma seviyesi sınıflandırma için uygulana yöntem sınıf değerleri yüksek/düşük değerlilik için değiştirilerek YSA ve bir katılımcıyı dışarıda bırak teknikleri ile sınıflandırılmıştır. Elde edilen değerlilik sınıflandırma sonuçları Şekil 4.46’da verilmiştir.



Şekil 4.46: YSA ile yüksek-düşük değerlilik doğruluk sonucu.

Yüksek-düşük değerlilik sınıflandırma sonucunda 5. Katılımcıda %82.5 doğruluk oranı ile en yüksek başarı elde edilirken, %65 ile en düşük başarı 1. Katılımcıda görülmüştür. Tüm bu sınıflandırmanın ortalaması ise %72.87 (\pm %4.68)'dir.


DEAP EEG duygu durum veri seti ile yapılan bu çalışma, bu veri setini hazırlayan yazarların yapmış olduğu ilk çalışma ile kıyaslanmıştır ve Tablo 4.5'de verilmiştir.

Tablo 4.5: ÇDGKA ve YSA yöntemlerinin kıyaslanması.

Çalışma	Sınıflandırma	Doğruluk
DEAP EEG Duygu Durum Veri Seti	Uyarılma	%62.00
	Değerlilik	%57.60
Bu çalışma (YSA ve ÇDGKA tabanlı)	Uyarılma	%75.00
	Değerlilik	%72.87

Tablo 4.5 referans alındığında önerilen yöntem ile daha başarılı sonuçlar elde edilmektedir. Özellikle değerlilik seviyesinin belirlenmesinde yüksek başarı sağlanmıştır. Önerilen görgül kip ayrışımı tabanlı duygu durum öznelik çıkarma ve analiz yöntemi diğer yöntemlere alternatif ve başarılı bir yöntem olarak kullanılabilir.


YSA sınıflandırıcı ve ÇDGKA kullanılarak önerilen EEG sinyalleri duygu durum tespiti yöntemi ile elde edilen başarı DEAP veri seti çalışması ile kıyaslanmış ve daha yüksek başarıya sahip olduğu görülmüştür. Fakat ÇDGKA tabanlı öznelik çıkarma yöntemi sabit kalmak şartı ile YSA yerine k-NN sınıflandırıcı kullanılarak denenmiştir. Yüksek/düşük uyarılma tespiti için yapılan değerlendirme sonuçları Şekil 4.47’de gösterilmiştir.



Şekil 4.47: k-NN kullanılarak yüksek/düşük uyarılma sonuçları.

k-NN ve bir katılımcıyı dışarıda bırak yöntemi ile elde edilen ortalama doğruluk değeri 51.01 ± 15.69 olarak elde edilmiştir. YSA ve orijinal DEAP çalışması ile kıyaslandığında düşük ortalama doğruluk değerine sahip olmakla birlikte katılımcıya göre çok değişim göstermektedir. Yüksek/düşük değerlik değeri tespiti için k-NN sınıflandırıcı ile elde edilen doğruluk değeri Şekil 4.48’de verilmiştir.

Yüksek/düşük değerlik seviyeleri k-NN sınıflandırıcı ile gerçekleştirildiğinde doğruluk değeri 67 ± 9.60 olarak elde edilmektedir.



Şekil 4.48: k-NN kullanılarak yüksek/düşük değerlik sonuçları.


YSA kullanılarak elde edilen değerden düşük faka DEAP veri seti çalışmasından daha yüksektir. k-NN sınıflandırıcı sonuçları Tablo 4.6’da kıyaslamak için verilmiştir.

Tablo 4.6: ÇDGKA ve k-NN yöntemlerinin Kıyaslanması.

Çalışma	Sınıflandırma	Doğruluk
DEAP EEG Duygu Durum Veri Seti	Uyarılma	%62.00
	Değerlilik	%57.60
Bu çalışma (k-NN ve ÇDGKA tabanlı)	Uyarılma	%51.01
	Değerlilik	%67.00

Yüksek başarı ile EEG sinyalleri kullanarak duygu durum tespiti yapılabilen YSA sınıflandırıcı ve önerilen ÇDGKA tabanlı yöntem neticesinde yüksek/düşük uyarılma ve yüksek/düşük değerlik seviyeleri baz alınarak iki boyutlu bilişsel duygu durum haritası üzerinde dört sınıflı duygu tespit çalışması genişletilmiştir.

İki boyutlu bilişsel harita üzerinde Şekil 4.49’da verildiği gibi 4 duygu seçilmiştir ve bulanık mantık sınıflandırıcı yardımı ile bu dört duygu tipi belirlenmiştir.




Şekil 4.49: Seçilen dört duygu.


Seçilen dört duygu mutlu, sakin, üzgün ve öfkeli için YSA sınıflandırıcı ile elde edilen yüksek/düşük uyarılma ve değerlik değerleri bulanıklaştırılarak bu dört sınıflı duygu sınıflandırma işlemi tamamlanır. Kullanılan 4 sınıflı duygu durum tespiti akış şeması Şekil 4.50’de verilmiştir.

Şekil 4.42’de izahı yapılmış olan ÇDGKA tabanlı öznitelik çıkarma yöntemi neticesinde elde edilen öznitelikler bir katılımcıyı dışarıda bırak doğrulama yöntemi ile yüksek/düşük uyarılma ve değerlilik değerleri YSA sınıflandırıcı ile sınıflandırılır. Bu ikili sınıflandırma iki boyutlu bilişsel duygu durum haritasında bulanık mantık sınıflandırıcı ile bölgeleri ve dolayısı ile mutlu, öfkeli, üzgün ve sakin durumu tespit edilir.

Önerilen yöntem ve bulanık mantık sınıflandırıcı ile bir katılımcıyı dışarıda bırak doğrulama yöntemi ile her iterasyonda katılımcıya ait 40 duygu durumunu sınıflandırarak elde edilen başarı oranı Şekil 4.51’de verilmiştir.



Şekil 4.50: Dört duygu sınıflandırma akış şeması.



Şekil 4.51: Dört duygu sınıflandırma doğruluk oranı.

4 sınıflı başarı oranı önceden bahsi geçen YSA ile yapılan yüksek/düşük uyarılma ve değerlilik ikili sınıflandırmasına göre başarı seviyesi düşmektedir. 20 katılımcı için doğruluk değeri 45.76 ± 6.20 'dir. Bu tez kapsamında önerilen yüksek/düşük uyarılma ve yüksek/düşük değerlilik sınıflandırma ile bu yöntemin genişletilmiş hali olarak da nitelendirilebilen bulanıklaştırıcı yardımı ile dört duygu durumlu sınıflandırma metoduyla elde edilen doğruluk değerleri Tablo 4.7'de verilerek kıyaslanmıştır.

Bu tez çalışmasında kullanılan veri seti kapsamında ve yine bu seti kullanarak yapılan diğer çalışmada [11, 75] elde edilen doğruluk değerleri ile kıyaslandığında önerilen ÇDGKA tabanlı yöntem ve YSA ile yüksek/düşük uyarılma ve değerlilik seviyeleri sınıflandırma çok daha başarılı sonuçlar vermektedir. Bu ikili sınıflandırma başarısına bulanıklaştırma eklenerek elde edilen dört sınıflı duygu sınıflandırma da ise başarı biraz düşmektedir.

YSA ile yapılan sınıflandırma k-NN'göre daha başarılı olmakla birlikte, genel olarak ÇDGKA neticesinde elde edilen EEG kanallarına ait ÖKF'lerin zaman ve frekans uzayı sinyal işleme yöntemleri neticesinde analiz edilerek öznelik çıkarma yöntemi EEG sinyalleri kullanılarak duygu durum belirleme çalışmalarında başarıyla kullanılabilir.

Tablo 4.7: Duygu durum sınıflandırma karşılaştırması.

Çalışma	Sınıflandırma	Doğruluk(%)	Yöntem
DEAP EEG	Yüksek/Düşük Uyarılma	62.00	EEG bant güçleri
Duygu Durum Veri Seti[11]	Yüksek/Düşük Değerlilik	57.60	Simetrik kanal güç farkı Bayes sınıflandırıcı
Jirayucharoensak ve ark.[75]	Yüksek/Düşük/Nötral Uyarılma	52.03±9.74	EEG bant güçleri Simetrik kanal güç farkı
	Yüksek/Düşük/Nötral Değerlilik	53.42±9.64	Temel bileşen analizi Derin öğrenme ağı
Bu çalışma	Uyarılma	51.01 ±15.69	ÇDGKA BBA
	Değerlilik	67.00 ±9.60	k-NN
Bu çalışma	Uyarılma	75.00 ±7.48	ÇDGKA BBA
	Değerlilik	72.87 ±%4.68	YSA
Bu çalışma	Mutlu/Öfkeli/Üzgün/Sakin	45.76±6.20	ÇDGKA BBA YSA Bulanık mantık

EEG sinyalleri kullanarak duygu durum tespiti yeni ve güncel bir konu olması sebebiyle de yeni çalışmalar ile bu başarı oranı yükseltilebilir.

5. TARTIŞMA VE SONUÇ

Saçlı deriye veya kafatası içerisine yerleştirilen elektrotlar yardımı ile alınan EEG kayıtları beyinde bulunan sinirlerin elektriksel aktivitesi hakkında bilgi içermektedir. Beyin fonksiyonlarının incelenmesinde sıklıkla tercih edilen EEG sinyallerinin analizi ile epilepsi gibi hastalık teşhisi, duygu durum tespiti veya kontrol gibi beyin bilgisayar ara yüzü çalışmaları yapılabilmektedir. EEG sinyallerinin çok zengin bilgi içeriyor olması sebebiyle geniş çerçevede farklı kullanım alanları ortaya çıkmaktadır.

On milyar civarı olan beyin sinir hücresi, farklı bölgelerde çok farklı görevlerin yürütülmesi gibi çeşitlilik EEG sinyallerinin analizi için çok çeşitli sinyal işleme yöntemlerinin kullanılmasını zorunlu kılmaktadır. Fakat beyin karmaşık sinirsel yapısı ve tüm vücutta oluşan diğer biyolojik kaynaklı sinyallerin varlığı ile birlikte EEG sinyalleri ile yapılacak olan analizin başarısını etkilemektedir. Bununla birlikte analizlerin çeşitliliği her analiz için farklı tekniklerin tek başına veya birlikte kullanımını zorunlu kılmaktadır. Örnek olarak EEG sinyallerinden şebeke gürültüsünü filtrelemek için çentik süzgeç yeterli olmaktadır, EKG ve EMG gibi diğer kas ve sinirsel aktivite sonucu oluşan sinyallerin ayrıştırılması için bağımsız bileşen analizi gibi kör kaynak ayrışımı gibi yöntemler gerekmektedir. Bu yöntemler gürültüden arındırılan EEG sinyallerinin epileptik atak tespiti veya beyin bilgisayar ara yüzü uygulamalarında zaman, frekans ve zaman-frekans bölgesi yöntemleri kullanılmaktadır. Fakat her yöntemin başarısı uygulandığı alana göre değişmekle beraber kusursuz analiz yöntemi yoktur.

Görgül kip ayrışımı (GKA) sinyal işleme yöntemleri içerisinde durağan olmayan sinyaller için geliştirmiş yeni bir yöntemdir. Fourier Dönüşümü (FD) gibi frekans bölgesi yönteminde veya zaman-frekans yöntemi olan dalgacık dönüşümündeki (DD) gibi belirli bir taban seçimi yapmadan sinyali kendi içinden çıkardığı özgül kip fonksiyonları (ÖKF) cinsinden ifade etmeye dayanmaktadır. Algoritma tabanlı yapısı ile tamamen sinyal uyarlamalı ve sinyal tarafından belirlenen özelliklere sahip analiz yöntemidir.

Bu tez çalışmasında GKA'nın sinyal uyarlamalı özellikleri irdelenerek epileptik EEG sinyal analizi ve EEG sinyalleri ile duygu durum tespiti için özgün ve yeni yöntemler önerilmiştir. İlk olarak gürültü temizleme yöntemleri, sonrasında epileptik EEG tespiti ile

duygu durum analizi bu tez çalışmasında önerilen yöntemler ile irdelenmiştir ve sonuçları verilmiştir.

GKA tabanlı yöntemlerin temelini sinyalin içerdiği salınımların bulunarak bunların analizi oluşturmaktadır. ÖKF olarak isimlendirilen bu salınımların herhangi bir analitik izahı olmadığı için yada diğer bir ifadeyle GKA'nı sinyal uyarlamalı bir algoritma olması sebebiyle, ÖKF'lerin elde edilmesine müteakip analiz veya test edilmesi gerekmektedir. Bu açıdan GKA algoritması ve ÖKF'lerinin uygulamalı olarak anlaşılabilmesi için çeşitli gürültü temizleme yöntemleri önerilmiştir.

GKA ile gürültü temizleme yöntemlerinin temeli gürültülü sinyalin ÖKF'lerinin birkaçının gürültünün bileşenlerinin oluşturmasıdır. Tez kapsamında önerilen ortak bilgi (OB), Hilbert-Huang Dönüşümü (HHD) ve hiyerarşik kümeleme ve eğimden arındırılmış dalgalanma analizi (EADA) tabanlı sinyal işleme yöntemleriyle elde edilen metrikler yardımıyla ÖKF'ler test edilmiş ve gürültülü bileşenler başarılı biçimde tespit edilmiştir. OB ve HHD ve hiyerarşik kümeleme ile önerilen yöntemlerde gürültü içeren ÖKF'ler tespiti için önerilen yöntemlerde kullanılan eşikleme yöntemi DD yöntemindeki gibi sert eşikleme olup eşik seviyesi de bu yöntemlerde sinyal uyarlamadır. Eşik seviyesi her iterasyon için yeniden belirlenmektedir. EADA tabanlı ölçüt için bu yöntemin sinyallerin istatistikî özelliklerine göre sabit değer verme özelliğinden faydalanılarak gürültülü ÖKF'lerin tespiti için sabit eşik değeri kullanılmıştır. Beyaz gürültü için bu eşik 0.5 ± 0.25 eşik aralığı iken EEG sinyallerinden EOG gürültü temizleme için bu değer 0.5'den küçük olarak seçilmektedir. Diğer bir deyişle temizlenecek salınımları tespit eden bir değer ile bu eşik belirlenmiştir. Tüm bu yöntemlerde sabit veya sinyal uyarlamalı eşiklere göre belirlenen gürültü içeren ÖKF'lerin atılması ile diğer ÖKF'ler ile gürültüsüz sinyal oluşturulmuştur. Bu yöntemlerin başarısı DD tabanlı eşikleme yöntemleri ile kıyaslanarak değerlendirilmiştir. Önerilen GKA tabanlı gürültü temizleme yöntemleri genelde başarılı olmakla birlikte düşük sinyal gürültü oranına (SNR) sahip sinyallerde daha başarılı olmaktadır.

Gürültü temizleme performansını etkileyen faktörlerin başında önerilen eşik belirleme yöntemlerinden ziyade GKA algoritmasının ortak mod etkisi olarak bilinen dezavantajı yer almaktadır. Bu yüzden gürültü ile orijinal sinyalin bileşenleri birden fazla ÖKF'lere dağılmaktadır. Önerilen gürültü temizleme yöntemlerindeki eşik ile atılan veya kalan

ÖKF'lerin bir kısmı hem gürültüyü hem de sinyali içermektedir. Böylece atılan ÖKF ile yeniden oluşturulmak istenen sinyalin bir kısım bileşenleri de atılabilmektedir. Tam tersi şekilde de dahil edilen ÖKF'ler bir kısım gürültü içerebilmektedir. Bu dezavantaj GKA algoritmasında yapılacak iyileştirmeler ile önlenebilir.

GKA ile epileptik EEG analizi için zaman ve frekans bölgesinde üç adet farklı yöntem önerilmiştir. GKA frekans bölgesi yöntemi için GKA algoritmasının sinyal uyarlamalı süzgeç öbeği yapısı referans alınmıştır. Sinyale göre değişen süzgeç yapısı öbeği neticesinde ÖKF'lerin sahip olduğu enerji ve enerji dağılımları farklı olmaktadır. Bu dağılım epileptik EEG için ÖKF 1'de en yüksek seviyeden atığa doğru düşüş gösterme eğilimindedir. Normal EEG ise daha dengeli bir dağılım görülmektedir. Bu dağılımı varyans ile tanımlayıp, varyans değerleri ile EEG sinyali ile epileptik atak anı tespit edilebilir. Bu yöntem ile başarı %100 olarak tespit edilmiştir.

GKA ve EADA ile EEG ÖKF'leri zaman bölgesinde öz-iliinti özellikleri ölçülerek epileptik EEG analizi gerçekleştirilmiştir. EADA üsteli ile ÖKF'lerin istatistiki özelliklerindeki değişim değeri ölçülür. Epileptik atak anında sinirlerin ani ve birlikte kontrolsüz deşarjı sonucunda oluşan EEG sinyalinin istatistik özelliklerinin daha hızlı değişmesine sebep olmaktadır ve bu dalgalanma EADA ile başarı ile ölçülür. Her iki sinyal için ÖKF'lerin EADA üstel değerleri ve dağılımları farklıdır. Bu farklılık basıklık değeri kullanılarak ifade edilir. Önerilen zaman bölgesi analizi %94.9 başarı oranı ile önerilen frekans bölgesine göre başarısı biraz düşüktür.

GKA tabanlı frekans ve zaman bölgesi ölçütlerinde herhangi birçok boyutlu öznitelik vektörü ve karmaşık yapay öğrenme algoritmalarına gerek duyulmaması bu yöntemlerin avantajlarından. Her iki yöntem neticesinde elde edilen skalar bir değer seviyesine göre normal veya epileptik EEG analizi başarı ile yapılabilmektedir. Bu yöntemlerde başlangıçta hasta atak geçirmezken alınan EEG sinyalleri ile bir seviye belirlenir ve belirli bir koruma aralığı da eklenerek eşik belirlenir. Bunun üstünde değer oluşması epileptik atak olarak değerlendirilir.

Çok değişkenli görgül kip ayrışımı (ÇDGKA) çok kanallı EEG sinyallerini analiz edebilmek için çok uygun bir sinyal işleme yöntemidir. Önerilen ÇDCKA yönteminde, ÇDGKA süzgeç öbeği yapısı sebebiyle elde edilen ÖFK'lerin benzer bantlarda bileşen

içermesi sebebiyle kıyaslamaya veya referans almaya olanak tanıyor olmasıdır. Referans olarak kullanılan normal ve epileptik EEG sinyalleriyle birlikte analiz edilmek istenen EEG sinyalinin ÇDGKA'ya uygulanması neticesinde elde edilen ÖKF'ler arası benzerlik analiz edilir. Eğer analiz edilmek istenen sinyal epileptik ise referans epileptik EEG ÖKF'leri ile benzerlik gösterdiği tespit edilmiştir. Bu benzerlik ÖKF'lerin güç izgesel yoğunlukları (GİY) arasında Öklit uzaklığı ile tespit edilmiştir. Bu başarı oranı %100 olarak tespit edilmiştir. Böylece epileptik EEG analizi için GKA algoritması kullanılarak önerilen sinyal işleme yöntemleri ile başarı ve işlevsel olarak etkin epileptik atak tespiti yapılabilen yöntemler geliştirilmiştir.

ÇDGKA algoritması kullanılarak çok kanallı EEG sinyalleri analiz edilerek duygu durum tespiti yöntemi ise diğer bir çalışmadır. İki boyutlu bilişsel duygulanım haritasında uyarılma/değerlilik seviyelerini sınıflandırmak için kullanılan EEG kanallarının alfa, beta, gama ve teta bantlarındaki güçleri veya GİY'leri ile bunların sağ ve sol kanallar arası farkları, EEG sinyalleri kullanarak duygu durum tespiti için temel yöntemlerdir. Bu tez çalışmasında ÇDGKA ile çok kanallı EEG sinyallerinin ÖKF'lerinin analizi ile duygu durum tespiti için yeni bir yöntem başarı ile geliştirilmiştir. ÖKF'lerin belirli bant genişliklerine sahip olması sebebiyle, çeşitli bantlarda da analizi gerçekleştirilmiş olur. Bir katılımcıyı dışarıda bırak çapraz doğrulama yöntemiyle eğitilen ve test edilen yapay sinir ağı (YSA) ve k-en yakın komşu (k-NN) yapay öğrenme algoritmaları ile yapılan ikili sınıflandırma neticesinde yüksek/düşük uyarılma seviyesi tespiti için %75 ve %51.01 doğruluk elde edilmiştir. Yüksek/düşük değerlilik için ise %72.87 ve %67 elde edilmiştir. Veri setini kullanarak yapılan çalışmalar ile kıyaslandığında yüksek/düşük uyarılma ve değerlilik ikili sınıflandırma için daha yüksek başarı elde edilmiştir. İkili sınıflandırma neticesinde elde edilen yüksek/düşük uyarılma ve yüksek/düşük değerlilik seviyeleri ile bulanık sınıflandırıcı yardımı ile dört duygu (mutlu, öfkeli, üzgün, sakin) için başarı %45.76'dır. GKA ile elde edilen ÖKF'lerin analizi duygu durum çalışmalarında başarı ile kullanılabilir.

GKA algoritması ile sinyalin oluşturan bileşenlerinin analiz edilmesi ve birbiriyle karşılaştırılması başarılı sonuçlar vermektedir. Gürültü temizleme yöntemlerinde gürültülü ÖKF'nin tespit edilmesi veya GKA frekans bölgesi yönteminde ÖKF'lerin güçlerinin kıyaslanması analiz yöntemini başarılı kılmaktadır. Epileptik ve normal EEG

sinyalinin güçlerini kıyaslamak veya EADA üstellerini kıyaslamak başarılı sonuçlar vermezken bu sinyallerin ÖKF'lerini güçlerini ve EADA üstellerini kıyaslamak başarıyı arttırmaktadır ve %100'lere varan başarı oranı sağlamaktadır.

KAYNAKLAR

- [1]. Polat, K., Gunes, S., 2007, Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast fourier transform, *Applied mathematics and computation*, 187, 1017–1026.
- [2]. Subasi, A., Gursoy, M.I., 2010, EEG signal classification using pca, ica, lda and support vector machines, *Expert systems with applications*, 37, 8659–8666.
- [3]. Wu, C.H., Chang, H.C., Lee, P.L., Li, K.S., Sie, J.J., Sun, C. W., Shyu, K.K., 2011, Frequency recognition in an ssvep-based brain computer interface using empirical mode decomposition and refined generalized zero-crossing, *Journal of neuroscience methods*, 196, 170–181.
- [4]. Orosco, L., Laciari, E., Correa, A. G., Torres, A., Graffigna, J. P., 2009, An epileptic seizures detection algorithm based on the empirical mode decomposition of EEG. *Engineering in medicine and biology*, 3-5 Eylül 2009, Minneapolis, IEEE, 2651–2654.
- [5]. Güler, N. F., Übeyli, E. D., Güler, I., 2005, Recurrent neural networks employing lyapunov exponents for EEG signals classification, *Expert systems with applications*, 29, 506–514.
- [6]. Accardo, A., Affinito, M., Carrozzi, M., Bouquet, F., 1997, Use of the fractal dimension for the analysis of electroencephalographic time series, *Biological cybernetics*, 77, 339–350.
- [7]. Aydin, S., Saraoğulu, H.M., Kara, S., 2009, Log energy entropy based EEG classification with multilayer neural networks in seizure, *Annals of biomedical engineering*, 37, 2626–2630.
- [8]. Kiyimik, M. K., Guler, I., Dizibuyuk, A., Akin, M. , 2005, Comparison of stft and wavelet transform methods in determining epileptic seizure activity in EEG signals for real-time application, *Computers in biology and medicine*, 35, 603–616.
- [9]. Adeli, H., Zhou, Z., & Dadmehr, N. , 2003, Analysis of EEG records in an epileptic patient using wavelet transform, *Journal of neuroscience methods*, 123, 69–87.
- [10]. Lin, Y. P., Wang, C. H., Jung, T. P., Wu, T. L., Jeng, S. K., Duann, J. R., Chen, J. H., 2010, EEG-based emotion recognition in music listening, *IEEE transactions on biomedical engineering*, 57, 1798–1806.
- [11]. Koelstra, S., Mühl, C., Soleymani, M., Lee, J. S., Yazdani, A., Ebrahimi, T., Patras, I., 2012, DEAP: A database for emotion analysis; using physiological signals, *IEEE transactions on affective computing*, 3, 18–31.
- [12]. Daimi, S. N., Saha, G. , 2014, Classification of emotions induced by music videos and correlation with participants' rating, *Expert systems with applications*, 41, 6057–6065.

- [13]. Petrantonakis, P.C., Hadjileontiadis, L.J., 2010, Emotion recognition from EEG using higher order crossings, *IEEE transactions on information technology in biomedicine*, 14, 186–197.
- [14]. Huang, N.E., Shen, Z., Long, S.R., Wu, M.C., Shih, H.H., Zheng, Q., Liu, H.H., 1998, The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis, *Proceedings of the royal society a: Mathematical, physical and engineering sciences*, 454 (1971), 903-995.
- [15]. Wu, Z.H., Huang, N.E., 2005, *Statistical significance test of intrinsic mode functions*, Hilbert-huang transform and its applications, in: Huang, N.E., Shen S.S.P (ed.), Chapter 5, World Scientific, Singapore, 107-127.
- [16]. Campbell, I.G., 2009, *EEG recording and analysis for sleep research*, *Current protocols in neuroscience*, 10-20.
- [17]. Orhan, U, 2011, *EEG işaretlerinden epilepsi hastalığının teşhisi için yeni yaklaşımlar*, Doktora Tezi, Zonguldak Karaelmas Üniversitesi.
- [18]. Gürkan, G., 2010, *EEG sinyallerinin analizi ile anestezi derinliği tespiti*, Doktora tezi, İstanbul Üniversitesi.
- [19]. Alarcon, G., Binnie, C.D., Elwes, R.D., Polkey, C.E., 1995, Power spectrum and intracranial EEG patterns at seizure onset in partial epilepsy, *Electroencephalography and clinical neurophysiology*, 94, 326–337.
- [20]. Oostenveld, R., Praamstra, P., 2001, The five percent electrode system for high-resolution EEG and ERP measurements, *Clinical neurophysiology*, 112, 713–719.
- [21]. Hart B.M., 2015, http://www.mariusthart.net/downloads/eeg_electrodes_10-20.svg 2014,. [Ziyaret tarihi: 2 Ocak 2015].
- [22]. Shoeb, A. H., 2009, *Application of machine learning to epileptic seizure onset detection and treatment*, Thesis(Ph.D), Massachusetts Institute Technology.
- [23]. Mert, A., Akan, A., 2013, Hilbert-huang transform based hierarchical clustering for EEG denoising, *21st Eusipco*, 9-13 Eylül 2013, Marrakech, IEEE, 1-5.
- [24]. Mert, A., Akan, A., 2013, EEG denoising based on empirical mode decomposition and mutual information, *XIII Mediterranean conference on medical and biological engineering and computing*, 25-28 Eylül 2013, Seville, Springer International Publishing, 631–634.
- [25]. Mert, A., Akan, A., 2014, Görgül kip ayrışımı ve eğimden arındırılmış dalgalanma analizi ile EOG gürültü temizleme, *IEEE 22. sinyal işleme ve iletişim uygulamaları kurultayı*, 23-25 Nisan 2014, Trabzon, IEEE, 544–547.
- [26]. Phegade, M., Mukherji, P., 2013, ICA based ECG signal denoising, *International conference on advances in computing, communications and informatics*, 22-25 Ağustos 2013, Mysore, IEEE, 1675–1680.

- [27]. Malmivuo J., Plonsey R., 1995, *Bioelectromagnetism principles and applications of bioelectric and biomagnetic fields*, Oxford University Press, New York.
- [28]. Goldberger, A.L., Amaral, L. A., Glass, L., Hausdorff, J.M., Ivanov, P. C., Mark, R.G., Stanley, H.E., 2000, PhysioBank, physiokit, and physionet: components of a new research resource for complex physiologic signals, *Circulation*, 101, 215–220.
- [29]. Theodoridis, S., Koutroumbas, K., 2010, *An introduction to pattern recognition: a matlab approach*, Academic Press, New York, ISBN: 0123744865.
- [30]. Cecchin, T., Ranta, R., Koessler, L., Caspary, O., Vespignani, H., Maillard, L., 2010, Seizure lateralization in scalp EEG using hjorth parameters, *Clinical neurophysiology*, 121, 290–300.
- [31]. Ocak, H. , 2009, Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy, *Expert systems with applications*, 36, 2027–2036.
- [32]. Chui, C.K., 1992, *An introduction to wavelets*, Academic Press Professional, San Diego, ISBN: 0121745848.
- [33]. Mallat, S. G., 1989, Theory for multiresolution signal decomposition: the wavelet representation, *IEEE transactions on pattern analysis and machine intelligence*, 11, 674–693.
- [34]. Ekman, P., Friesen, W. V, O’Sullivan, M., Chan, A., Diacoyanni-Tarlatzis, I., Heider, K., Ricci-Bitti, P. E., 1987, Universals and cultural differences in the judgments of facial expressions of emotion, *Journal of personality and social psychology*, 53, 712–717.
- [35]. Kandel, E. R., Schwartz, J. H., Jessell, T. M., 2000, *Principles of neural science. neurology*, McGraw-Hill, New York.
- [36]. Bos, D. O., 2007, *EEG-based emotion recognition: the influence of visual and auditory stimuli, Capita selecta (MSc course)*.
- [37]. Ortigueira, M.D., Batista, A. G., Rato, R. T., 2008, On the HHT, its problems, and some solutions, *Mechanical systems and signal processing*, 22, 1374–1394.
- [38]. Yanli, Y., Changyun, M., Jiahao, D., 2013, An analytical expression for empirical mode decomposition based on b-spline interpolation, *Circuit system signal processing*, 32 (6), 2899-2914.
- [39]. Silong P., Hwang, W.-L., Hu, X., 2012, EMD revisited: a new understanding of the envelope and resolving the mode-mixing problem in AM-FM signals. *IEEE transactions on signal processing*, 60, 1075–1086.
- [40]. Xu, Z., Huang, B., Li, K., 2010, An alternative envelope approach for empirical mode decomposition, *Digital signal processing*, 20, 77–84.

- [41]. Rilling, G., Flandrin, P., 2008, One or two frequencies the empirical mode decomposition answers, *IEEE transactions on signal processing*, 56, 85–95.
- [42]. Flandrin, P., Gonçalves, P., Rilling, G. , 2005, *EMD equivalent filter banks, from interpretation to applications, Hilbert-huang transform and its applications*, In N. E. Huang ve S. S. Shen (Ed.), World Scientific Inc, Singapore, 55-74.
- [43]. Rilling, G., Flandrin, P., Goncalves, P., Lilly, J. M, 2007, Bivariate empirical mode decomposition, *IEEE signal processing letters*, 14, 936 - 939.
- [44]. Rehman U., Mandic, D.P., 2010, Empirical mode decomposition for trivariate signals, *IEEE transactions on signal processing*, 58, 1059–1068.
- [45]. Rehman, N., Mandic, D.P., 2009, Multivariate empirical mode decomposition, *Proceedings of the royal society a: mathematical, physical and engineering sciences*, 466, 1291–1302.
- [46]. Flandrin, P., Goncalves, P., 2004, Empirical mode decompositions as data-driven wavelet-like expansions, *International journal of wavelets, multiresolution and information processing*, 02, 477–496.
- [47]. Flandrin, P., Rilling, G., Goncalves, P., 2004, Empirical mode decomposition as a filter Bank, *IEEE signal processing letters*, 11, 112–114.
- [48]. Ur Rehman, N., Mandic, D. P., 2011, Filter bank property of multivariate empirical mode decomposition, *IEEE transactions on signal processing*, 59, 2421–2426.
- [49]. Peng, C. K., Buldyrev, S. V, Havlin, S., Simons, M., Stanley, H. E., Goldberger, A. L., 1994, Mosaic organization of DNA nucleotides, *Physical review e*, 49, 1685–1689.
- [50]. Hurst, H. E., 1965, *Long-term storage: an experimental study*, Constable, London.
- [51]. Jospin, M., Caminal, P., Jensen, E. W., Litvan, H., Vallverdú, M., Struys, M.M.R. F., Kaplan, D.T., 2007, Detrended fluctuation analysis of EEG as a measure of depth of anesthesia, *IEEE transactions on biomedical engineering*, 54, 840–846.
- [52]. Lee, J. M., Kim, D. J., Kim, I. Y., Park, K. S., Kim, S. I., 2002, Detrended fluctuation analysis of EEG in sleep apnea using MIT/BIH polysomnography data, *Computers biology and medicine*, 32, 37–47.
- [53]. Leistedt, S., Dumont, M., Lanquart, J.-P., Jurysta, F., Linkowski, P., 2007, Characterization of the sleep EEG in acutely depressed men using detrended fluctuation analysis, *Clinical neurophysiology*, 118, 940–950.
- [54]. Güneş, T., Polat, E., 2009, Yüz ifade analizinde öznelik seçimi ve çoklu SVM sınıflandırıcılarına etkisi, *Gazi üniversitesi mühendislik-mimarlık fakültesi dergisi*, 24(1), 7–14.

- [55]. Hyvarinen A., Karhunen, O., Oja, E., 2001, *Independent Component Analysis*, Wiley-Interscience, New York, ISBN: 047140540.
- [56]. Görmez, Z., 2014, *Biyoinformatik uygulamalarında makine öğrenme yöntemlerinin geliştirilmesine yönelik çok kriterli yaklaşım*, Doktora tezi, İstanbul Üniversitesi.
- [57]. Mert, A., Kılıç, N., Akan, A., 2014, An improved hybrid feature reduction for increased breast cancer diagnostic performance, *Biomedical engineering letters*, 4(2), 285–291.
- [58]. CAN, M.S., 2010, *Sayısal sinyal işlemci ile bağımsız bileşen analizinin gerçekleştirilmesi*, Doktora tezi, Kahramanmaraş Sütçü İmam Üniversitesi.
- [59]. Akkan, T., 2009, *Independent component analysis in biomedical applications and accelerometer data logging system*, Doktora tezi, Dokuz Eylül Üniversitesi.
- [60]. Çatak, F. Ö., 2014, *Bulut bilişim sistemlerinde eşle/indirge yöntemi uygulanarak veri madenciliği yazılım çatısının geliştirilmesi*, Doktora Tezi, İstanbul Üniversitesi.
- [61]. Koldere Akın, Y., 2008, *Veri madenciliğinde kümeleme algoritmaları ve kümeleme Analizi*, Doktora Tezi, Marmara Üniversitesi.
- [62]. Mahalanobis, P.C., 1936, On the generalised distance in statistics, *Proceedings of the national institute of sciences*, 2, 49-55.
- [63]. MacQueen, J., 1967, Some methods for classification and analysis of multivariate observations, *Proceedings of the fifth Berkeley symposium*, Haziran 1967, Berkeley , 281–297.
- [64]. Bilski, J., 2005, The ud rls algorithm for training feedforward neural networks, *International journal of applied mathematics and computer science*, 15, 115–123.
- [65]. Andrzejak, R.G., Lehnertz, K., Mormann, F., Rieke, C., David, P., Elger, C. E. , 2001, Indications of nonlinear deterministic and finite dimensional structures in time series of brain electrical activity, *Physical review E*, 64, 061907.
- [66]. Güler, I., Ubeyli, E.D., 2005, Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients, *Journal of neuroscience methods*, 148, 113–121.
- [67]. Larsson P.G, 2015, <http://eeganalysis.web.auth.gr/dataen.htm#EpilepticEEG>, [Ziyaret tarihi: 2 Ocak 2015].
- [68]. Shoeb, A., Edwards, H., Connolly, J., Bourgeois, B., Treves, S.T., Gutttag, J., 2004, Patient-specific seizure onset detection, *Epilepsy & behavior*, 5, 483–498.
- [69]. Donoho, D. L., 1995, De-noising by soft-thresholding, *IEEE transactions on information theory*, 41, 613–627.

- [70]. Donoho, D., Johnstone, J., 1994, Ideal spatial adaptation by wavelet shrinkage. *Biometrika*, 81, 425–455.
- [71]. Akan, A., Mert, A., 2015, *Time-frequency analysis and noise reduction*, Time-frequency signal analysis and processing: a comprehensive review, In: Boashash B. (Ed.), Chapter 15, Academic Press, New York, 243-268.
- [72]. Mert, A., Akan, A., 2014, Detrended fluctuation analysis for empirical mode decomposition based denoising, *Eusipco*, 1–5 Eylül, Lisbon, IEEE, 1-5.
- [73]. Mert, A., Akan, A., 2014, Detrended fluctuation thresholding for empirical mode decomposition based denoising, *Digital signal processing*, 32, 48–56.
- [74]. Mert, A., Akan, A., 2014, Eğitimden arındırılmış dalgalanma analizi ve görgül kip ayrışımı tabanlı EEG analizi, *Tıp teknolojileri ulusal kongresi*, 25-27 Eylül 2014, Kapadokya, 187–190.
- [75]. Jirayucharoensak, S., Pan-Ngum, S., Israsena, P., 2014, EEG-based emotion recognition using deep learning network with principal component based covariate shift adaptation, *The scientific world journal*, ID 627892.

ÖZGEÇMİŞ

Kişisel Bilgiler



Adı Soyadı	Ahmet Mert
Uyruğu	T.C.
Doğum tarihi, Yeri	1982, İznik
Telefon	(530) 464 08 15
E-mail	ahmetmert2002@hotmail.com

Eğitim

Derece	Kurum/Anabilim Dalı/Programı	Yılı
Doktora	İ.Ü. /Fen Bilimleri Enstitüsü/Biyomedikal Mühendisliği	2015
Yüksek Lisans	Marmara Üniv./ Fen Bilimleri Enstitüsü/Mekatronik	2009
Lisans	Marmara.Üniv. Teknik Eğitim Fak./Elektronik ve Hab. Öğr.(İng)	2006
Lise	Ziya Kalkavan A.D.M.L	1999

Makaleler / Bildiriler

<p>Mert, A., Kiliç, N., Bilgili, E., Akan, A., 2015, Breast cancer detection with reduced feature sets, <i>Computational and mathematical methods in medicine</i>, Article ID 265138.</p> <p>Mert, A., Sezdi, M., Akan, A., Test and simulation device for doppler based fetal heart rate monitoring, <i>Turkish journal of electrical and computer sciences</i>, Accepted. doi:, doi:10.3906/ELK-1306-224.</p> <p>Mert, A., Kiliç, N., Akan, A., 2014, Evaluation of bagging ensemble method with time-domain feature extraction for diagnosing of arrhythmia beats, <i>Neural computing and applications</i>, 24, 317–326.</p>
--

- Mert, A., Akan, A., 2014, Detrended fluctuation thresholding for empirical mode decomposition based denoising, *Digital signal processing*, 32, 48–56.
- Mert, A., Kılıç, N., Akan, A., 2014, An Improved hybrid feature reduction for increased breast cancer diagnostic performance, *Biomedical engineering letters*, 4(2), 285–291.
- Akan, A., Mert, A., 2015, *Time-frequency analysis and noise reduction*, Time-Frequency Signal Analysis and Processing: A Comprehensive Review, In: Boashash, B. (Ed.), . Academic Press, 243-268.
- Akan, A., Kara, S., Okkesim, Ş., Tüzün, S., Yıldırım, M. S., Mert, A., Çiftçi, B. T. , 2014., *Biyomedikal Sensörler ve Dönüştürücüler, Biyomedikal Mühendisliğinin Temelleri*, In: Asyalı, M. H., Kara, S., Yılmaz, B. (Ed.), Bölüm 5, Nobel Akademik Yayıncılık, 157-193.
- Mert, A., Akan, A. , 2014, Sürekli vucut sıcaklığı ölçümü için biyotelemetri cihaz tasarımı. *Tıp teknolojileri ulusal kongresi*, 25-27 Eylül 2014, Kapadokya, 312–315.
- Mert, A., Akan, A., 2014, Eğimden arındırılmış dalgalanma analizi ve görgül kip ayrışımı tabanlı EEG analizi, *Tıp teknolojileri ulusal kongresi*, 25-27 Eylül 2014, Kapadokya, 187–190.
- Mert, A., Akan, A., 2014, Görgül kip ayrışımı ve eğimden arındırılmış dalgalanma analizi ile EOG gürültü temizleme. *IEEE 22. sinyal işleme ve iletişim uygulamaları kurultayı*, Trabzon, 544–547.
- Mert, A., Akan, A., 2014, Detrended fluctuation analysis for empirical mode decomposition based denoising. *23rd European signal processing conference*, 5-9 Eylül 2014, Lisbon, 1-5.
- Mert, A., Akan, A., 2013, EEG denoising based on empirical mode decomposition and mutual information, *XIII mediterranean conference on medical and biological engineering and computing 2013*, Seville, 631–634.
- Mert, A., Akan, A., 2013, EEG işaretlerinin görgül kip ayrışımı ve ortak bilgi ile analizi. *IEEE 21. sinyal işleme ve iletişim uygulamaları kurultayı*, Girne, 1–4.
- Mert, A., Akan, A., 2013, Hilbert_huang transform based hierarchical clustering for EEG denoising. *22nd European signal processing conference*, Marrakech, 1–5.
- Mert, A., Sezdi, M., Akan, A., 2012., Röle ile doppler fetal kalp hızı monitörü test cihazı. *Tıp teknolojileri ulusal kongresi*, Antalya, 281–284 .
- Mert, A., Kılıç, N., Akan, A., 2012, Geliştirilmiş morfolojik öznitelikler kullanılarak EKG sinyal analizi, *Akıllı sistemlerde yenilikler ve uygulamaları sempozyumu*, Trabzon, 234–238.
- Mert, A., Kılıç, N., Akan, A., 2012, ECG signal classification using ensemble decision tree, *16th international research/expert conference*, Dubai, 1–4.
- Mert, A., Kilic, N., Akan, A., 2011, Breast cancer classification by using support vector machines with reduced dimension, *53rd International symposium elmar*, Zadar, 14-16.
- Mert, A., Özkaynak, S., Bilgili, E., 2010., Loadcell signal denoising with wavelet Transform and multiresolution analysis. *The 5th International. symposium on wavelets applications to world problems*, İstanbul, 1-4.
- Mert, A., Özkaynak, S., Özkaynak, S., 2010, Design of a labview design of a labview based graphical user interface for Remote control of a computer controlled diesel engine test unit. *International Educational Technology Conference*, İstanbul, 354–358.

Mert, A., Özkaynak, S., Ziarati, R., Özkaynak, S., Küçük, H., 2009, Design and development of a computer controlled marine diesel engine, *International. maritime lecturer associaton conference*, Gana, 1-5.

Mert, A., Özkaynak, S., Küçük, H., 2009, Dizel motor eğitimi için labview tabanlı veri edinimi ve kontrol arayüzü tasarımı, *Makinatek*, Temmuz, Ağustos, 114–115, 114–117.