



**T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



DOKTORA TEZİ

**ÇOK DEĞİŞKENLİ SİNYAL İŞLEME TEKNİKLERİ KULLANARAK EEG
İLE DUYGU DURUM ANALİZİ**

Pınar ÖZEL

**DANIŞMAN
Prof. Dr. Aydın AKAN**

**II. DANIŞMAN
Prof. Dr. Bülent YILMAZ**


Biyomedikal Mühendisliği Anabilim Dalı


Biyomedikal Mühendisliği Programı


İSTANBUL-2019

Bu çalışma 18.01.2019 tarihinde ařağıdaki jüri tarafından Biyomedikal Mühendisliğı Anabilim Dalı Biyomedikal Mühendisliğı Programında Doktora Tezi olarak kabul edilmiştir.

Tez Jürisi


Prof. Dr. Aydın AKAN (Danışman)
İzmir Katip Çelebi Üniversitesi
Mühendislik Fakültesi


Dr. Mahmut ÖZTÜRK
İstanbul Üniversitesi-Cerrahpařa
Mühendislik Fakültesi


Doç. Dr. İsa YILDIRIM
İstanbul Teknik Üniversitesi
Elektrik-Elektronik Fakültesi


Prof. Dr. Fırat KAÇAR
İstanbul Üniversitesi-Cerrahpařa
Mühendislik Fakültesi


Prof. Dr. Tülay YILDIRIM
Yıldız Teknik Üniversitesi
Elektrik-Elektronik Fakültesi

20.04.2016 tarihli resmi gazetede yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi'nin aboneli olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

Bu çalışma İstanbul Üniversitesi Cerrahpaşa Bilimsel Araştırma Projeleri Yürütücü Sekreterliğinin numaralı projesi ile desteklenmiştir.

Bu tez numaralı proje ile tarafından desteklenmiştir

ÖNSÖZ

Tez çalışmalarım boyunca kıymetli görüşlerini paylaşan ve her türlü desteğini esirgemyen değerli hocam ve tez danışmanım Prof. Dr. Aydın AKAN' a bütün içtenliğimle teşekkür ederim. Ayrıca, ikinci danışmanım olan ve rasyonel katkılarıyla tezimi zenginleştiren Prof. Dr. Bülent YILMAZ' a teşekkürü bir borç bilirim. Tez izleme komitesinde yer alan ve çalışma boyunca önemli noktalarda değerli fikirleri ile yol gösteren Doç. Dr. İsa YILDIRIM ve Prof. Dr. Fırat KAÇAR' a teşekkürlerimi sunarım.

Tezime katkıları olan değerli hocalarımdan yanısıra, eğitim hayatım boyunca her türlü desteğini esirgemeyen anne ve babama bütün kalbimle teşekkür ederim.

Ocak, 2019

Pınar ÖZEL

İÇİNDEKİLER

Sayfa No

ÖNSÖZ	i
İÇİNDEKİLER	iv
ŞEKİL LİSTESİ	vii
TABLO LİSTESİ	ix
SİMGE VE KISALTMA LİSTESİ	xiii
ÖZET	xv
SUMMARY	xvii
1. GİRİŞ	1
1.1. TEZİN KATKILARI	2
2. GENEL KISIMLAR	5
2.1. ÖNERİLEN YÖNTEMLERLE İLGİLİ ÇALIŞMALAR	8
2.2. KANAL SEÇİMİ	13
2.3. HİBRİD MODELLER	19
2.3.1. Özgül Kip Fonksiyonu Seçimi	20
2.4. DUYGU DURUM MODELLERİ	21
2.4.1. Ayrık Modeller	22
2.4.2. Boyutsal Modeller	24
2.4.2.1. İki Boyutlu Modeller	24
2.4.2.2. Üç Boyutlu Modeller	29
2.4.3. Hem Ayrık ve Boyutsal Olan Modeller	31
2.5. DUYGU DURUM ANALİZİ	33
2.5.1. Kullanıcıya dayalı ve Kullanıcıdan bağımsız Analiz	33
2.5.2. Çevrimiçi ve Çevrimdışı Duygu Durum Analizi	33
2.6. DUYGU DURUM VERİ KÜMESİ	34
2.6.1. DEAP Veri Kümesi	34
2.7. DUYGU DURUM TAHMİNİ İÇİN KULLANILAN SAYISAL YÖNTEMLER	38

3. MALZEME VE YÖNTEM	42
3.1. LOKALİZE ZAMAN FREKANS GÖSTERİMLERİ	42
3.1.1. Veri Bağımlı Zaman Frekans Analizi	42
3.1.1.1. Görgül Kip Ayırışımı	42
3.1.1.2. Çok Değişkenli Görgül Kip Ayırışımı	45
3.1.1.3. Gürültü Destekli Çok Değişkenli Görgül Kip Ayırışımı	49
3.1.1.4. Görgül Dalgacık Dönüşümü	51
3.1.2. YENİDEN ATAMA YÖNTEMLERİ	53
3.1.2.1. Senkrosıkıştırma Dönüşümü	53
3.1.2.2. Senkrosıkıştırma Dönüşümü Kullanarak Çok Değişkenli Zaman Frekans Analizi	56
3.1.2.3. Çok değişkenli zaman-frekans gösterimi:	61
3.2. SINIFLANDIRMA	63
3.2.1. Destek Vektör Makinesi	64
3.2.2. Topluluk Sınıflandırıcı	66
3.2.3. En Yakın Komşu Sınıflandırıcı	66
3.2.4. Karar Ağacı	67
3.3. ÇAPRAZ DOĞRULAMA YÖNTEMLERİ	69
3.3.1. Dışarda Tutma ÇDY	69
3.3.2. K-Katlamalı ÇDY	70
3.3.3. Birini Dışarda Bırak ÇDY	70
3.4. GRAM-SCHMIDT YÖNTEMİ İLE ORTOGONALLEŞTİRME	71
3.5. TEKİL DEĞER ANALİZİ	73
3.6. ÇOKLU ÇÖZÜNÜRLÜK ANALİZİ	73
4. BULGULAR	76
4.1. EEG SİNYALLERİ YOLUYLA DUYGU DURUM SINIFLANDIRIMADA ÇOK DEĞİŞKENLİ SENKRO SIKIŞTIRMA YÖNTEMİ KULLANIMI ..	76
4.1.0.1. Değerlendirme	87
4.2. DUYGU DURUM ANALİZİ İÇİN EEG SİNYALLERİ KULLANILARAK GÜRÜLTÜ DESTEKLİ ÇOK DEĞİŞKENLİ GÖRGÜL KİP AYRIŞTIRMA YÖNTEMİ	88
4.2.0.1. Değerlendirme	99
4.3. ÇDGKA-ÇÇA VE ÇDGKA-SSD DOMENİNDE ÇOK KANALLI EEG SİNYALLERİNDEN DUYGU DURUM ANALİZİ	100
4.3.0.1. Değerlendirme	102

4.4. ADAPTİF ORTOGONAL SİNYAL AYRIŞTIRMA TEMELLİ DUYGU DURUM ANALİZİ	110
4.4.0.1. Değerlendirme	110
5. TARTIŞMA VE SONUÇ	115
KAYNAKLAR	123
ÖZGEÇMİŞ	141

ŞEKİL LİSTESİ

	Sayfa No
Şekil 2.1: Beynin kesit analizi	6
Şekil 2.2: Uluslararası 10-20 Sistem Kanal Yerleşimi	14
Şekil 2.3: Altı Temel Duygu İfadesi	22
Şekil 2.4: Parrots'un Ağaç yapısı diagramı	23
Şekil 2.5: Circumplex-(Değerlik-Aktivasyon) Modeli	24
Şekil 2.6: Vektör Modeli	25
Şekil 2.7: PANA Modeli	26
Şekil 2.8: rSASM Modeli	27
Şekil 2.9: 12-PAC Modeli.....	28
Şekil 2.10: PAD-(Değerlik-Uyarılma-Baskınlık) Modeli	29
Şekil 2.11: Löwheim Kübü	30
Şekil 2.12: Plutchik'in Duygu Çarkıfeleği.....	31
Şekil 2.13: Kumsaati Modeli	32
Şekil 2.14: Öz-değerlendirme Anketi (SAM) - Baştan aşağı; değerlik aktivasyon, baskınlık etiketleri	35
Şekil 2.15: EEG sinyalleri için Deap Veri kümesi İçeriği	36
Şekil 2.16: Diğer fizyolojik sinyaller için Deap Veri Kümesi İçeriği	37
Şekil 2.17: Duygu Durum Tahmini İşlem Basamakları	38
Şekil 3.1: GKA algoritmasının akış şeması. (orijinal veri x, r= artık, i= ayrıştırma yineleme.)	44
Şekil 3.2: Örneklemeye	Yönergeleri
*	46
Şekil 3.3: GKA'yi bir filtre bankası olarak kullanırken her ÖKF için mod karıştırma sorunu gösterimi.....	48
Şekil 3.4: ÇDGKA'yi bir filtre bankası olarak kullanırken her ÖKF için iyi tanımlanmış anlık frekansların gösterimi.....	49
Şekil 3.5: GDD yönteminin akış şeması	51

Şekil 3.6: Senkrosıkıştırma Dönüşümü (SSD) Algoritmasının Akış Şeması	55
Şekil 3.7: $B_{l,m}$ olarak verilen çok değişkenli bant genişliğine sahip bölünmüş frekans alanı.	59
Şekil 3.8: Makina Öğrenme çeşitleri	64
Şekil 3.9: DVM'nin geometrik çizimi.....	65
Şekil 3.10: Topluluk Sınıflandırıcı Akış Şeması	66
Şekil 3.11: En yakın komşu sınıflandırıcı grafik çizimi	67
Şekil 3.12: Bir karar ağacının şematik temsili	68
Şekil 3.13: Dışarda Bırakma ÇDY	70
Şekil 3.14: K-Katmanlı ÇDY	71
Şekil 3.15: Birini Dışarda Bırak ÇDY	71
Şekil 3.16: Dalgacık ayrışmasının filtre bankası uygulaması	74
Şekil 4.1: EEG sinyalleri yoluyla Duygu Durum Sınıflandırmada Çok Değişkenli Senkro Sı- kıştırma Dönüşümü ile Önerilen Yöntemin basamakları	77
Şekil 4.2: İki boyutlu duygu uzayı bölümlemesi	78
Şekil 4.3: Üç boyutlu duygu uzayı bölümlemesi.....	80
Şekil 4.4: DEAP Veri Setinde ÇDSSD ve kanallara ayrı ayrı SSD uygulanmasının temsili gösterimi	
*	84
Şekil 4.5: Önerilen GD-ÇDGKA tabanlı duygu durumu modeli	89
Şekil 4.6: ÇDGKA'yi bir filtre bankası olarak kullanırken, kullanılan 26 kanalda her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu	90
Şekil 4.7: ÇDGKA kullanarak EEG sinyalinin ÖKF'lerine açılımı	91
Şekil 4.8: GD-ÇDGKA'yi bir filtre bankası olarak kullanırken, kullanılan 26 kanalda her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu çözümü	92
Şekil 4.9: GD-ÇDGKA kullanarak EEG sinyalinin ÖKF'lerine açılımı	93
Şekil 4.10: GD-ÇDGKA ve ÇDGKA kullanarak EEG sinyalinin ÖKF'lerine açılımlarının farkları	94
Şekil 4.11: GD-ÇDGKA'yi bir filtre bankası olarak kullanırken, kullanılan 26 kanalda her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu çözümü ($V=64$)	95
Şekil 4.12: GD-ÇDGKA'yi bir filtre bankası olarak kullanırken, kullanılan 26 kanalda her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu çözümü ($V=32$)	95

Şekil 4.13: GD-ÇDGKA'yi bir filtre bankası olarak kullanırken, kullanılan 26 kanalda her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu çözümü ($V=128$)	96
Şekil 4.14: Fark kanalları kullanılmadan (ilk 18 kanal kullanılarak) , GD-ÇDGKA'yi bir filtre bankası olarak kullanırken, her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu çözümü.....	96
Şekil 4.15: Fark kanalları kullanılmadan (ilk 18 kanal kullanılarak) , ÇDGKA'yi bir filtre bankası olarak kullanırken, her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu	97
Şekil 4.16: ÇDGKA'yi bir filtre bankası olarak kullanırken, her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu ($V=128$).....	97
Şekil 4.17: ÇDGKA-(ÇÇA&SSD) domenlerinde önerilen duygu durum analizi	100
Şekil 4.18: Adaptif ortogonal sinyal ayrıştırma temelli duygu durum analizi için önerilen yöntemin şeması.....	109

TABLO LİSTESİ

Sayfa No

Tablo 2.1: EEG sinyalleri kullanılarak gerçekleştirilen DDA çalışmalarında kanal seçimi (2004-2012 yılları arası)	17
Tablo 2.2: EEG sinyalleri kullanılarak gerçekleştirilen DDA çalışmalarında kanal seçimi (2012-2018)	18
Tablo 2.3: EEG'den Duygu Tanıma Çalışmalarında Öznitelikler, Verisetleri, Öznitelik Çıkarma Yöntemleri, Sınıflandırma Başarısı (2013-2015 yılları arası).....	40
Tablo 2.4: EEG'den Duygu Tanıma Çalışmalarında Öznitelikler, Verisetleri, Öznitelik Çıkarma Yöntemleri, Sınıflandırma Başarısı (2016-2018 yılları arası).....	41
Tablo 3.1: EEG sinyallerinin 128Hz'lik örnekleme frekansına sahip farklı frekans bantlarına ayrılması.	75
Tablo 4.1: ÇDSSD kullanarak 2D değerlik- aktivasyon kombine alanı için dört duygusal ifade	79
Tablo 4.2: ÇDSSD kullanarak 3D değerlik- aktivasyon-baskınlık kombine etki alanı için sekiz duygusal ifade.....	81
Tablo 4.3: 26 girişli EEG kanalımızı ayrı ayrı incelemek için her bir kanal için SSD kullanan 3D değerlik- aktivasyon-baskınlık kombine alanı için sekiz duygusal ifade	85
Tablo 4.4: GD-ÇDGKA ve ÇDGKA algortima sonucu elde edilen ÖKF lerin özniteliklerinin DVM, KA, EYKS, TS kullanarak sınıflandırılması.	93
Tablo 4.5: Alfa beyin dalgacığında Db4 fonksiyonu kullanılarak yüksek / düşük aktivasyon değerlik, baskınlık boyutları için doğruluk oranları.....	102
Tablo 4.6: Beta beyin dalgacığında Db4 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	102
Tablo 4.7: Teta beyin dalgacığında Db4 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	103
Tablo 4.8: Gama beyin dalgacığında Db4 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	103
Tablo 4.9: Delta beyin dalgacığında Db4 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	103
Tablo 4.10: Alfa beyin dalgacığında Db8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	103
Tablo 4.11: Beta beyin dalgacığında Db8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	104

Tablo 4.12: Teta beyin dalgacığında Db8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	104
Tablo 4.13: Gama beyin dalgacığında Db8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	104
Tablo 4.14: Delta beyin dalgacığında Db8fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	104
Tablo 4.15: Alfa beyin dalgacığında Sym8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	105
Tablo 4.16: Beta beyin dalgacığında Sym8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	105
Tablo 4.17: Teta beyin dalgacığında Sym8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	105
Tablo 4.18: Gama beyin dalgacığında Sym8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.	105
Tablo 4.19: Delta beyin dalgacığında Sym8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.	106
Tablo 4.20: Alfa beyin dalgacığında Coif5 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	106
Tablo 4.21: Beta beyin dalgacığında Coif5 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	106
Tablo 4.22: Teta beyin dalgacığında Coif5 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.....	106
Tablo 4.23: Gama beyin dalgacığında Coif5 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.	107
Tablo 4.24: Delta beyin dalgacığında Coif5 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.	107
Tablo 4.25: Aktivasyon- Değerlik ve Baskınlık Paremetreleri ile CDGKA-SSD yönteminde sınıflandırma oranları.	108
Tablo 4.26: Karar Ağacı Sınıflandırıcısı kullanarak Duygu Durum sınıflandırma doğruluk oranları.	111
Tablo 4.27: Topluluk Sınıflandırıcı Sınıflandırıcısı kullanarak Duygu Durum sınıflandırma doğruluk oranları.	112
Tablo 5.1: Duygu Durum Analizinde Hibrid Modeller.....	118
Tablo 5.2: Duygu Durum Analizinde Çok Değişkenli Hibrid Modeleler.	119
Tablo 5.3: Duygu Durum Analizinde 3 Boyutlu Duygu Durum Sınıflandırma Sonuçları.....	120

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
$v(t)$	: Orjinal Sinyal
$e_l(t)$	: Alt Zarf
$e_u(t)$	: Üst Zarf
$\bar{m}(t)$	: Lokal Ortalama
$r(t)$	: Artık Sinyal
$a_i(t)$	: Genlik Fonksiyonu
$Q_i(t)$	: Faz Fonksiyonu
$w_i(t)$	: Anlık Frekans
$x^{(Q_k)}$	: Yön Vektörü
$v(t)_{t=1}^T$	: Giriş Sinyali
$p^{(Q_k)}(t)_{k=1}^K$	: Yansıma Kümesi
$e^{(Q_k)}(t)_{k=1}^K$	: Çok Değişkenli Zarf Eğrileri
$t_j^{Q_k}$	: Zaman Sabiti
b	: İlintisiz Beyaz Gauss Gürültüsü Zaman Serisi Kanalı
$2\tau_n$	: Geçiş Fazı
$v(x)$	: Meyer Dalgacık Yardımcı İşlevi
$W_f^e(n, t)$	: Ampirik Dalgacıklar
$f_k(t)$	: Ampirik Modlar
$W_s(a, b)$	: $s(t)$ Sinyalinin Sürekli Dalgacık Dönüşümü
ψ^*	: Ana Dalgacıkların Karmaşık Konjugesi
$w_s(a, b)$	: Anlık Frekans
Δa_k	: Ölçeklendirme Adımı
$T(w_l, b)$	: Senkrosıkıştırma Katsayısı
$a(t)$	: Sinyalin Genliği
$\Phi(t)$	: Sinyalin Fazı
$x_+(t)$	: Analitik Sinyal
$a_{N_c}(t)$	: Her Bir Kanal için Genlik
$\Phi_{N_c}(t)$	: Her Bir Kanal için Faz
$w_x(t)$	: Ortak Anlık Frekans

$\Im$	: Kompleks Sinyalin İmajiner Parçası
$\Phi_{n_c}^l(t)$	: Her Kanalin Anlık Frekansı
$v_x(t)$	: Ortak Anlık Band Genişliği
$v_x(t)^2$	: Ortak Anlık Band Genişliğinin Karesi
$S_x(w)$	: Ortak Analitik Spektrum
$X_+(w)$	: Analitik Sinyalin Fourier Dönüşümü
E_x	: Fourier Katsayılarının Toplam Enerjisi
$\bar{\omega}_x$	: Ortal Global Ortalama Frekans
$\bar{\sigma}_2^x$	: Ortak Analitik Spektrumun Spektral Sapması
$\sigma_2^x(t)$	: Ortak Anlık İkinci Merkezi Moment
$B_{l,m}$	: Çok Değişkenli Band Genişliği
l	: Seviye
m	: İndeks
R_Ψ	: Normalizasyon Katsayısı
$\Phi_{(l,m)}(w)$	: Sütün Vektörü
δ_{ij}	: Kronecker Deltası
$\Omega_k^n(b)$	: Her Bir Kanal Bandı k için Anlık Frekans
$A_k^n(b)$	: Her Bir Kanal Bandı k için Anlık Genlik
$\Omega_k^{coklu}(b)$	: Çok Değişkenli Anlık Frekans
$A_k^{coklu}(b)$	: Çok Değişkenli Anlık Genlik
XI	: Öklid Uzaklığı
S	: Her Bir Değişkenin Entropisi
S_v	: S'nin Alt Kümesi
$G(S,A)$	: Bilgi Kazanımı
U	: Ortanormal Matris
V	: Ortanormal Matris
A	: Yaklaşım Katsayısı
D	: Detay Katsayısı
$f(t)$	: Sürekli Fonksiyon

¹ Bütün simgeler kendi bölümü içerisinde değerlendirilmelidir. Simge sırasında bölüm sırası takip edilmiştir

Kısaltmalar	Açıklama
<i>DDA</i>	: Duygu Durum Analizi
<i>GKA</i>	: Görgül Kip Ayırışımı
<i>ÇDGKA</i>	: Çok Değişkenli Görgül Kip Ayırışımı
<i>SSD</i>	: Senkrosıkıştırma Dönüşümü
<i>ÇDSSD</i>	: Çok Değişkenli Senkrosıkıştırma Dönüşümü
<i>GD-ÇDSSD</i>	: Gürültü Destekli-Çok Değişkenli Senkrosıkıştırma Dönüşümü
<i>GDD</i>	: Görgül Dalgacık Dönüşümü
<i>ÇDGDD</i>	: Çok Değişkenli Görgül Dalgacık Dönüşümü
<i>ÇÇA</i>	: Çoklu Çözünürlük Analizi
<i>KZFD</i>	: Kısa Zaman Fourier Dönüşümü
<i>BGG</i>	: Beyaz Gauss Gürültüsü
<i>TGKA</i>	: Topluluk Görgül Kip Ayırışımı
<i>TTGKA</i>	: Tamamlayıcı Topluluk Görgül Kip Ayırışımı
<i>ÖKF</i>	: Özgül Kip Fonksiyonu
<i>SDD</i>	: Sürekli Dalgacık Dönüşümü
<i>ADD</i>	: Ayrık Dalgacık Dönüşümü
<i>DVM</i>	: Destek Vektör Makinesi
<i>KA</i>	: Karar Ağacı
<i>EYKS</i>	: En Yakın Komşu Sınıflandırıcı
<i>TS</i>	: Topluluk Sınıflandırıcı
<i>BBA</i>	: Beyin Bilgisayar Arayüzü
<i>dBBA</i>	: Duygusal Beyin Bilgisayar Arayüzü
<i>fMRG</i>	: Fonksiyonel Mantetik Rezonans Görüntüleme
<i>DİY</i>	: Deri İletkenlik Yanıtları
<i>KH</i>	: Kalp Hızı
<i>EEG</i>	: Elektroensefalografi
<i>MEG</i>	: Magnetoensefalografi
<i>HAF</i>	: Hibrid Adaptif Filtreleme
<i>YSG</i>	: Yüksek Sıra Geçişleri
<i>GSY</i>	: Güç Spektral Yoğunluğu
<i>TMS</i>	: Transkraniyal Manyetik Stimulasyon
<i>YAY</i>	: Yeniden Atama Yöntemi
<i>OBP</i>	: Olay Bağlı Potansiyeller

<i>YDS</i>	: Yüksek Dereceli Spektra
<i>HHS</i>	: Hilbert-Huang Spektrumunu
<i>HHD</i>	: Hilbert-Huang Dönüşümü
<i>FGG</i>	: Fraksiyonel Gauss Gürültüsü
<i>SS</i>	: Sinüzoidal Sinyal
<i>ÇDY</i>	: Çapraz Doğrulama Yöntemleri
<i>TDA</i>	: Tekil Değer Analizi
<i>SGO</i>	: Sinyal Gürültü Oranı
<i>EMG</i>	: Elektromiyografi
<i>FAA</i>	: Frekans Akımları Analizi
<i>YSA</i>	: Yapay Sinir Ağları
<i>EKA</i>	: Eşzamanlı Kümeleme Analizi
<i>HFD</i>	: Hızlı Fourier Dönüşümü
<i>GKKT</i>	: Genlik Karesi Koherans Tahmini
<i>KYSA</i>	: Konvansiyonel Yapay Sinir Ağları
<i>KYSA</i>	: Derin Yapay Sinir Ağları
<i>QDA</i>	: Kuadratik Diskriminant Analizi
<i>MM</i>	: Mahalanobis Mesafe
<i>LDA</i>	: Lineer Diskriminant Analizi
<i>ÇKA</i>	: Çok Katmanlı Algılayıcı
<i>SÖM</i>	: Sınırdaki Öğrenme Makinası
<i>KVP</i>	: Kan Volumu Pulsu
<i>PDYA</i>	: Pozitif Değerlik Yüksek Aktivasyon
<i>NDYA</i>	: Negatif Değerlik Yüksek Aktivasyon
<i>PDDA</i>	: Pozitif Değerlik Düşük Aktivasyon
<i>NDDA</i>	: Negatif Değerlik Düşük Aktivasyon
<i>PDYAYB</i>	: Pozitif Değerlik Yüksek Aktivasyon Yüksek Baskınlık
<i>PDYADB</i>	: Pozitif Değerlik Yüksek Aktivasyon Düşük Baskınlık
<i>NDYAYB</i>	: Negatif Değerlik Yüksek Aktivasyon Yüksek Baskınlık
<i>NDYADB</i>	: Negatif Değerlik Yüksek Aktivasyon Düşük Baskınlık
<i>PDDAYB</i>	: Pozitif Değerlik Düşük Aktivasyon Yüksek Baskınlık
<i>PDDADB</i>	: Pozitif Değerlik Düşük Aktivasyon Düşük Baskınlık
<i>NDDAYB</i>	: Negatif Değerlik Düşük Aktivasyon Yüksek Baskınlık
<i>NDDADB</i>	: Negatif Değerlik Düşük Aktivasyon Düşük Baskınlık

ÖZET

DOKTORA TEZİ

Çok Değişkenli Sinyal İşleme Teknikleri Kullanarak EEG ile Duygu Durum Analizi

Pınar ÖZEL

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Danışman : Prof. Dr. Aydın AKAN

II. Danışman : Prof. Dr. Bülent YILMAZ

Sinyal işleme yöntemlerini kullanarak duygu tespiti ve duygusal modellemede sınıflandırma süreci için kullanılacak optimum öznitelik kümesi elde etmek, üzerinde yoğun olarak çalışılan bir konudur. Son yıllarda Hilbert tabanlı Görgül Kip Ayrışımı yöntemi kullanılarak yapılan duygu durum analizi araştırmaları beyin bilgisayar arayüzü çalışmalarında önemli bir yer tutmaktadır. Daha yeni çalışmalarda ise Görgül Kip Ayrışımı (GKA) sonrası elde edilen özgül kip fonksiyonlarına uygulanan zaman, frekans, zaman-frekans bölgesindeki özniteliklerle sınıflandırmalar gerçekleştirilmiştir. Bu tezde, EEG sinyalleri yoluyla Görgül Kip Ayrışımı'nın çok değişkenli uzantısı kullanılarak elde edilen özgül kip fonksiyonlarına çoklu çözünürlük analizi ve senkrosıkıştırma yöntemi uygulandıktan sonra elde edilen özniteliklerle sınıflandırmanın yapıldığı bir duygu durum analizi önerilmiştir. Ayrıca yöntemdeki mod karıştırma, ortogonalite gibi eksiklere çözüm olarak önerilen Gürültü Destekli Çok Değişkenli Görgül Kip Ayrışımı ve Adaptif Ortogonal Çok Değişkenli analiz yöntemleri de duygu durum analizi modeli olarak değerlendirilmiştir. Öte yandan, Çok Değişkenli Senkrosıkıştırma Dönüşümü kompakt bir lokalize zaman-frekans temsiliyi oluşturmak için bir işlem sonrası tekniğidir. EEG sinyalleri kullanılarak Çok Değişkenli Senkrosıkıştırma Dönüşümü ile üç boyutlu duygusal durum sınıflandırması için bir yaklaşımı da tez çalışmasında önerilen diğer bir konudur. Ortak protokol oluşturması amacı ile ve önerilen yöntemlerle elde edilen öznitelikleri DEAP veri setindeki genel olarak bütün katılımcıların EEG sinyalleri kullanılarak, çıkış vektörü olarak öz-değerlendirme-anketi etiketleri, sınıflandırma sürecinde en

yakın komşu sınıflandırıcı, karar ağacı, topluluk sınıflandırıcı, destek vektör makineleri kullanılarak duygusal durum sınıflandırmaları değerlendirilmiştir.

Ocak 2019, 142 sayfa.

Anahtar kelimeler: EEG, Duygu Durum Analizi, Çok Değişkenli Sinyal İşleme Teknikleri

SUMMARY

Ph.D. THESIS

Emotion State Analysis by Using Multivariate Signal Processing Techniques via EEG Signals

Pınar ÖZEL

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Biomedical Engineering

Supervisor : Prof. Dr. Aydin AKAN

Co-Supervisor : Prof. Dr. Bulent Yilmaz

Emotion detection by utilizing signal processing methods and the optimum feature set to be used for the classification process in emotional modelling is a challenging area. In recent years, utilizing Hilbert-based Empirical Mode Decomposition for emotional state sensing researches attracted attention in the brain computer interfaces. In more recent studies, models of emotional state recognition have been presented in which the classification is performed by utilizing the features obtained after applying the time, frequency, and time-frequency domain methods to intrinsic mode functions achieved by operating Empirical Mode Decomposition. In this thesis, an emotion recognition model is proposed in which the classification process of the features obtained after Multi-resolution Analysis and Synchrosqueezing methods are applied to the intrinsic mode functions obtained using the multivariate extension of the Empirical Mode Decomposition from EEG signals. Furthermore, Noise-assisted multivariate methods of empirical mode decomposition and Adaptive orthogonal multivariate method of it are also evaluated as an emotion analysis model as a solution of mod mixing and orthogonality problems of the intrinsic mode functions. On the other hand, an approach for emotional state classification by the investigation of EEG signals via Multivariate Synchrosqueezing Transform is presented for a 3D dimensional emotion space because of the fact that Multivariate Synchrosqueezing Transform is a post-processing technique to compose a compact localized

time-frequency representation yielding multivariate synchrosqueezing coefficients. For the purpose of setting a common protocol for all proposed methods, the features sets of all the proposed methods in this thesis are categorized using EEG signals of all participants in the DEAP dataset in the classification process in which self-evaluation questionnaire tags are used as output vectors and the nearest neighbor classifier, decision tree, ensemble classifier, support vector machines are used for classifiers.

January 2019, 142 pages.

Keywords: EEG, Emotion Recognition, Multivariate Signal Processing Techniques

1. GİRİŞ

İnsanların duygusal aktiviteleri sosyal etkileşiminde önemli ve belirgin bir rol oynar. Günümüzde insanlar kişisel bilgisayarlar, tabletler ve akıllı telefonlar gibi dijital cihazlarla çok zaman geçirmektedirler. Akıllı sistemler, kullanıcılar arasında çeşitli yöntemler ve teknolojiler kullanarak iletişim araçları sağlayarak ilerlemektedir. İnsan makina etkileşiminin artması sebebi ile, beyin bilgisayar arayüzü çalışmalarında duygu durumunu da kapsayan yeni ihtiyaçlar ortaya çıkmaya başlamıştır. Duygu durum analizinin temel amacı, insanlığın farklı duygusal durumlarını tasvir etmek ve kullanıcılarının ihtiyaçlarını anlamak için farklı özellikteki arayüzleri kişiselleştirmeye çalışmaktır. Daha açık bir ifade ile, duygusal hesaplama bilgisayarlar kullanıcıların zihinsel durumlarını tanıma, anlama ve adapte etme ve ardından dijital cihazlar ile kullanıcıları arasındaki etkileşimleri geliştirme yeteneğini vermeyi amaçladığı fikrini taşımaktadır. Bu duyguları doğru tanımlamak ve tanımak bu sebeple önemlidir. Dolayısı ile duyguları tasvir etme ihtiyacı, psikoloji, biyomedikal mühendisliği, makine öğrenimi ve bilişsel bilimler başta olmak üzere birçok alanda araştırmacıların ilgisini çekmiştir.

Araştırmacılar, EEG'den farklı öznitelik çıkarma yöntemleri ve sonrasında tanımlanmış duygu kategorileri için farklı yaklaşımlar kullanmıştır. Genellikle, EEG öznitelikleri zaman bölgesinden, frekans bölgesinden ve zaman-frekans bölgesinden çıkarılır. Zaman bölgesi analizi yöntemi esas olarak EEG'lerin geometrik özelliklerini analiz eder. Güç spektrum analizine dayanan frekans alanında öznitelik çıkarımı olgun bir sürece sahiptir ve EEG analizinde yaygın olarak kullanılmaktadır. Ve güç spektrumunun farklı frekanslara oranı, alt bant güç spektral yoğunluğu, güç spektrumu enerjisi gibi duygusal EEG'yi ayırmada bazı genel öznitelikler kullanılmaktadır. Zaman-frekans karakteristiği, sinyal frekansı ve değişen zaman arasındaki ilişkiyi açık bir şekilde tanımlayan zaman bölgesi ve frekans bölgesinin enerji dağılımı hakkında bilgi sağlar. Son yıllarda zaman-frekans bölgesindeki öznitelik çıkarma yöntemleri daha fazla tercih edilmeye başlanmıştır.

Öte yandan, teknolojinin gelişmesiyle çok kanallı kayıt yapabilen sensörler geliştirilmiş ve bu sensörlerin kullanımının sonucu olarak çok kanallı sinyal analizi için çok değişkenli öznitelik çıkarma yöntemleri geliştirilmiştir. Bu amaçla, kompakt bir zaman-frekans gös-

terimi sunmasının yanı sıra, çoklu kanal bağımlılıklarını çok kanallı sinyallerin ortak osilasyon yapısını modelleyerek ortak anlık frekans ve bandgenişliği özelliklerini kullanıp çok değişkenli uygulamalara göre genişleterek hesaplayan Çok Değişkenli Senkrosıkıştırma Dönüşümü önerilmiştir. Ayrıca, kanallar arası bağımlılıkları sinyali değişen uzaylarda farklı yönler boyunca yansıtarak çok boyutlu zarfların ortalaması prensibi ile elde eden Çok Değişkenli Görgül Kip Ayrışımı farklı uygulama alanları bulmuştur.

1.1. TEZİN KATKILARI

Bu tez araştırmasının temel motivasyonu; günlük hayattaki otonom sinir sistemi uyarılmalarını hisseden ve iletişim kuran bir bilgisayar arayüzü için yeni metodlar önerip, EEG sinyallerinden faydalananarak duyguların uzaysal yakınlıklarını araştırmak ve modellemektir. Araştırmanın odak noktası beyin dalgalarını kullanarak, herhangi bir kişinin duygusal durumunu ölçebilen duygu sezi sistemi tasarlamak amacıyla sinyal işleme düzeneği geliştirmektir. Ayrıca, çok değişkenli sinyal işleme uygulamalarının gerekliliği ve yeni oluşumu göz önüne alınarak Görgül Kip Ayrışımı, Fourier ve Dalgacık Dönüşümü yöntemlerine dayalı uygulamaların tek başına yetersiz kaldığı ve de yeni önerilen hibrid çalışmalar referansı ile duygu durum analizi için çok değişkenli ve hibrid model uygulamaları önermektedir. Bu tezin katkıları şunlardır:

- Bilgisayarlı duygu durumu değerlendirmesinde önemli noktaları belirleme: Duygunun ortaya çıkması, temel bulguların tanımı ve ortak deney seti kullanımının gözlemlenmesi bu tezin amaçlarından biridir. Birçok duygu durum analizi çalışmasında farklı deneysel protokol ayarı ile spesifik duygu örnekleri, duygu durum analizi işleminde kullanılmıştır, ancak bir çok durumda, belirsizlik ve temel bulgu tanımında genellikle tartışmalı seçimler vardır. Bu tezde, kullanılan veri-seti üzerinden temel bulguların tasnif edilmesi için dört farklı model araştırılmış, tartışılmış ve analiz edilmiştir. Literatürdeki bazı çalışmalarda değerlik ve aktivasyon bölgelerini ayırmak için belirli formüller kullanılıp sınıflandırıcıya verilerek sonuçlar değerlendirilmiştir. Ancak çoğu çalışmada da sınıflandırma öncesi formül kullanılmayıp, sınıflandırma aşamasında sonuçlar incelenmiştir. Buna göre, temel bulgular açısından, bu tez çalışmasında Çok Değişkenli Görgül Kip Ayrışımı ve Çok Değişkenli Senkrosıkıştırma Dönüşümü temelli, değerlik, aktivasyon ve baskınlık bölgeleri grup-

landırmasında formül kullanılmadan sırası ile öznitelik vektörü ve sınıflandırma algoritmaları ile sonuçlar değerlendirilmiştir.

- Yeni zaman-frekans analizi yöntemlerinin kullanımının araştırılması: Hilbert Tabanlı Çok değişkenli Görgül Kip Ayırışımı, Yeniden Atama temelli Senkro-Sıkıştırma Yöntemlerinin, EEG analizi ve duygu sınıflandırma yöntemlerinde kullanımı henüz yaygın değildir. Görgül Kip Ayırışımı son zamanlarda, EEG kullanarak duygu durum analizi çalışmalarında kullanılmıştır ve nitelikli sonuçlar ortaya çıkarmıştır. Ancak, bu ayırıştırma yöntemi tamamen veri bağımlıdır ve ayırıştırma sonuçlarının sinyalin zaman domeninde bölgesel özelliklere, kaydedilen deneylere ve EEG kanallarına göre değişen ayırıştırma seviyeleri sayısına bağlıdır. Bunun bir sonucu olarak, ortak bir öznitelik uzayı tanımlamak neredeyse imkansızdır. Bu sorunu çözmek için, Görgül Kip Ayırışımı'nın genişletilmiş versiyonu olan Çok Değişkenli Görgül Kip Ayırışımı, EEG sinyalleri kullanarak sabit bir veri kümesi üzerinde araştırılmış, analiz edilmiş ve değerlendirilmiştir. Ek olarak, Yeniden atama Yöntemleri son zamanlarda Görgül Kip Ayırışımı kullanım alanlarına alternatif olarak önerilmiştir. Yeniden atama yöntemlerinin spesifik bir türü olan Senkrosıkıştırma yöntemi de bunlardan biridir. Dolayısıyla, bu tezde duygu durum analizi çalışmalarında Çok Değişkenli Görgül Kip Ayırışımı ve Senkrosıkıştırma Dönüşümü uygulamalarına daha çok dikkat çekilmeye çalışılmıştır.
- Görgül Kip Ayırışımı ürünü Özgün Kip Fonksiyonlarından sonra altbant önerme: Son zamanlarda önerilen öznitelik çıkarma yöntemlerinden faydalanarak, Çok Değişkenli Görgül Kip Ayırışımı sonrası elde edilen özgün kip fonksiyonlarının sınıflandırma öncesi dağılımından öznitelikler çıkarıp sınıflandırıcıda kullanmak tezin amaçlarından biridir. Buna göre, bu tezde, tek değişkenli senkrosıkıştırma dönüşümü ve çoklu çözünürlük analizi yöntemleri öznitelik çıkarmada altband olarak, Adaptif Ortogonal Duygu Durum Modelleme çalışmamızda da Çok değişkenli Görgül Kip ayırışımından sonra elde edilen özgün kip fonksiyonlarına Gram Schmidt Ortogonalleştirme Yöntemi uygulanıp, daha sonra ikinci altband olarak farklı öznitelik çıkarma yöntemi gerçekleştirmek amacı ile seçilen ortogonal özgün kip fonksiyonlarına Görgül Dalgacık Dönüşümü uyguladıktan sonra, sunulan kanallara ayrı ayrı sınıflandırma süreci önerilmiştir.


- Çok Değişkenli Senkrosıkıştırma Yöntemi ile üç boyutlu duygu durum analizi: Çok değişkenli senkro sıkıştırma yöntemi, yöntem sonrasında elde edilen Çok Değişkenli Senkrosıkıştırma Katsayılarını, sınıflandırma sürecinde giriş vektörü olarak kullanılıp üç boyutlu duygu durum sınıflandırması gerçekleştirilmiştir. Özellikle çok değişkenli senkro sıkıştırma yönteminin duygu durum analizinde yapılacak yeni çalışmalara katkı sağlaması beklenmektedir.
- EEG Duygu Durum Analizi sınıflandırmaları için bir çerçeve tanımı ve sunulması: EEG sinyalleri kullanarak duygu durum analizinde En Yakın Komşu Sınıflandırıcı, Destek Vektör Makinesi, Topluluk Sınıflandırıcı, Karar Ağacı sınıflandırma algoritmaları incelenmiş ve uygulanmıştır. Sınıflandırma sürecinde performans ve uygulama sınırlamaları DEAP veri kümesi üzerinde sonuçlarıyla sunulmuştur. Duygu durum analizi çalışmalarında iki boyutlu ve üç boyutlu sınıflandırma karşılaştırmalarına çok rastlanmadığı gibi iki boyutlu çalışma sonuçları uzaysal düzlemdeki çakışmalardan dolayı üç boyutlu sınıflandırmada farklı sonuçlar vermektedir. Bu tezde, iki farklı sınıflandırma boyutu kullanıp karşılaştırarak sınıflandırma algısına yeni bir bakış açısı getirmek hedeflenmektedir.
- Kanal Seçimi : Duygu durum analizi çalışmalarında kanal seçimi de tartışmalı bir konudur. Adaptif Ortogonal Duygu Durum Modelleme çalışmamızda kullanılan kanallar ayrı ayrı değerlendirilerek duygu durum analizinde kanal seçimi çalışmalarına katkı sağlanmaya çalışılmıştır.
- Duygu Durum Analizinde Gürültü Destekli Çok Değişkenli Görgül Kip Ayrışımı Uygulaması: Amaçlarımızdan biri de, duygu durumu analizinde, EEG sinyallerinin işlenmesinde Gürültü Destekli Çok Değişkenli Görgül Kip Ayrışımı potansiyelini değerlendirmek ve Çok Değişkenli Görgül Kip Ayrışımı ile sonuçları karşılaştırmaktır. Gürültü Destekli Çok Değişkenli Görgül Kip Ayrışımı'nın analizde, giriş gürültüsü alt uzayı içindeki eklenen gürültülerin filtreleme sürecine katkısı ayrıntılı olarak gösterilerek, mod-hizalama ve filtre bankı özellikleri sunulup yeni elde edilen özgül kip fonksiyonlarının zaman frekans dağılımları ile sınıflandırma gerçekleştirilmiştir.

2. GENEL KISIMLAR

Duygusal durum, psikolojik ve fizyolojik açıdan duyguların ve davranışların birbirleriyle bağlantılı olduğu ve bir bağlamda değerlendirilebildiği durumu ifade eder. EEG sinyallerinden duygu durum analizi ise, insan-makine etkileşimi (İME) için önemli bir faktör olarak düşünülen kullanıcının “içsel” durumunun direk olarak değerlendirilmesine olanak sağlayan bir alandır (Scherer, 2005).

Genel olarak, beyinde ventral ve dorsal sistemlerde gerçekleşen duygusal süreçlerin fonksiyonel olarak farklı olduğu ifade edilmiştir (Philips *ve diğ.*, 2003). Ventral anterior singulat girus ve prefrontal korteks in bazı ventral alanları (ventromedial prefrontal korteks ve medial orbitofrontal kortekste) dahil olmak üzere ventral sistem, duygu durumu üretimi ve etkisel cevapların düzenlenmesine katılıyorken, dorsal anterior singulat girus ve Prefrontal korteksin bazı dorsal alanları (dorsolateral posterior dorsolateral ve orta dorsolateral prefrontal korteks) olmak üzere dorsal sistem ve hipokampus duygu düzenlenmesi ve senkron davranışta rol oynar. **Şekil 2.1:**'de beynin ilgili bölümlerinden bir kesit görülmektedir.

Son zamanlarda, duygu durum analizi (DDA), İME'ye duyguyu dahil ederek, birleşik bir teknoloji olarak ortaya çıkmıştır (Philips *ve diğ.*, 2003). DDA aritmetiği, genellikle duygu bilincinde olan hesaplama türü olarak kullanılır ve duygu durumunu fizyolojik ve davranışsal sinyaller ile ölçerek ve hesaplama modelleri geliştirip insan ve bilgisayar arasında duygusal etkileşimi oluşturur (Philips *ve diğ.*, 2003; Luneski *ve diğ.*, 2010). Duyguların yoğunluğu, süresi ve gerçeklik bulgusunun güvenilirliği otomatik duygu tanıma da önemli bir faktör olup, yeni çalışmalar ve yeni bulgular DDA yöntemlerini geliştirmeye devam etmektedir (Jenke *ve diğ.*, 2014; Kim *ve diğ.*, 2013). Psikolojik açıdan, duygusal durum uzayı temel olarak ayırık veya boyutsal model ile incelenebilir. Ayırık model, öfke, korku, tikslenme, şaşkınlık, mutluluk ve üzüntü veya bunların bir kombinasyonu dahil temel duyguların birine karşılık gelen, ayırık durumların sonlu sayıda kümesi olarak tanımlanır (Barrett, 1998). Boyutsal model, değerlik, aktivasyon, baskınlık gibi duygunun temel boyutları ile uzaysal olarak duygu durumunu tanımlar ve her bir boyutun seviyesine göre duyguyu yorumlar (Mauss ve Robinson, 2009). Bu duygu modelleri, duygunun çok yönlü ve siste-



Şekil 2.1: Beynin kesit analizi

matik analizi için kullanılmaktadır. Duygu modellerine göre, duygu durumunun altındaki nöro-fizyolojik mekanizma dinamik bir şekilde incelenmektedir.

İME'deki son çalışmalar, bilgisayar-insan uyumunu daha uyarlanabilir hale getirmeyi hedeflemesinden dolayı, kullanıcının duygusal durumu hakkında bilgi alışverişi önemli bir faktör olarak düşündürür. Duygular, iletişimin yanı sıra, olayları doğru yorumlamada önemlidir. Farklı modaliteler (örneğin yüz, duruş, hareket, ses) kullanılarak yapılan duygu tanıma çalışmaları son yıllarda artmaktadır ve özellikle son zamanlarda duygusal beyin-bilgisayar arayüzleri (dBBA) terimini kazandıran beyin-bilgisayar arayüzleri ilgi görmüştür (Frantzidis *ve diğ.*, 2010). DDA'da temel unsurlardan biri kişilerin davranışsal ve fizyolojik yanıtlarından kişinin duygusal durumunu tahmin eden mekanizmadır (Cacioppo, 2004). Duygusal tanıma, psikiyatrik sağlık hizmet kalitesini arttırmak amacıyla ve duygusal kullanıcı ara-yüzleri yaratmak için bilgisayarın katkısını artırmayı hedeflemektedir. Öz-raporlama, irkilme tepkisi, davranışsal cevap, otonom ölçüm ve nöro-fizyolojik ölçüm olmak üzere duygu tanıma için çeşitli ölçümler kullanılmıştır (Mauss ve Robinson, 2009). Öz-raporlama, duygu modelleme çerçevesine göre duygusal tepkileri kolayca elde eder, ancak hızlı duygusal değişiklikleri takip etmeyi zorlaştıran ve duygu durumunun

öz-tahmininden ortaya çıkan sonuca güvenilmemesi gerçeğine dayalı bir sonuca sahiptir (Mauss ve Robinson, 2009).

Bunların dışında, elektrofizyolojik ve nörogörüntüleme tekniklerine dayalı nöro-fizyolojik ölçüm, duygu durumun ortaya çıktığı beyindeki temel yapıya direk erişimi sağlayarak duygu durumunun dinamiklerini geniş bir açıdan inceler (Mauss ve Robinson, 2009; Vytal ve Hamann, 2010). Deri İletkenlik Yanıtları (DİY) ve Kalp Hızı (KH) gibi otonom ölçümler, otonom sinir sisteminin fizyolojik tepkileriyle bağlantılı duyguları objektif olarak algılayabilir ancak duygu durumunun sadece altuzaylarına erişebilirler (Mauss ve Robinson, 2009; Panksepp, 2007). Elektromiyografi (EMG) kullanarak uyarılma tepkisi büyüklüğü miyonöral tepkileri ölçer ancak duygunun sadece kısmı yönlerini değerlendirir (örneğin, uyarılma seviyesi) (Mauss ve Robinson, 2009; Robinson ve Clore, 2002). Davranışsal ölçümler, EMG veya video görüntüsü kullanarak, yüz veya bütün vücut davranışındaki değişiklikleri algılar ancak EMG sinyallerinin doğrudan belirli bir duygusal duruma karşılık geldiği varsayımına ihtiyaç duyar (Mauss ve Robinson, 2009; Christie ve Friedman, 2004). Bu nedenlerle, nörofizyolojik ölçümler DDA için en doğrudan ve kapsamlı aracı sağlar ve araştırmaların büyük bir bölümü insanlar üzerinde farklı noninvaziv sensor modaliteleri kullanarak, her biri uzaysal çözünürlük ve hareketliliğe göre benzersiz özelliklere sahip, duygunun nöral bağlantılarını araştırmaktadır. Magnetoensefalografi (MEG)'de hassas uzamsal ve zamansal çözünürlüklerle, spesifik kaynaklardan duyguyla ilgili nöral sinyalleri tam zamanında bulmak amacıyla kullanılmıştır (Hamalainen *ve diğ.*, 1993). Fonksiyonel manyetik rezonans görüntüleme (fMRG), duygusal durumları kapsayan korteks ve korteks altı yapıları araştırmak amacıyla kullanılmaktadır (Peyk *ve diğ.*, 2008). Ancak, maliyetleri ve taşınmazlıkları nedeniyle, fMRG ve MEG cihazları duygu tanıma sistemleri olarak pratikte kullanılması tercih edilmez (Ray ve Bowyer, 2010; Davidson *ve diğ.*, 2007). Elektroensefalografi (EEG), zayıf uzamsal çözünürlüğü ve gürültüye karşı yüksek hassasiyet göstermesine rağmen, zamansal çözünürlüğü ile duygusal uyarılara hızlı tepkilerinin algılanmasını sağladığı için, duygularla ilgili beyin dinamiğini araştırmakta yaygın olarak kullanılmaktadır (Murugappan *ve diğ.*, 2010; Hausdorff *ve diğ.*, 2000). EEG cihazı, düşük maliyeti (Khosrowabadi ve Rahman, 2010), portatif kolaylığı ile de pratik kullanımda önemli avantaja sahiptir ve bu nedenle çevrimiçi duygu tanıma sistemleri geliştirilmesi için ilk seçenek olmuştur.

Kişinin duygularını tanımak için gerçek zamanlı EEG kullanarak çok sayıda kullanıma yönelik çalışma da yapılmıştır. Örneğin, ticari bir ürün olarak geliştirilen EmoRate (Emotiv Corp, CA, ABD), kullanıcı bir film izliyorken duygusal durum akışını tespit eder (Sourina ve Liu, 2011). Brown ve diğ. (2011), değerlik durumunu ölçen ve bunu kablosuz bağlantı üzerinden ileten EEG tabanlı bir duygusal bilgisayar sistemi önermiştir. Cho ve diğ. (2015), kullanıcının yüz ifadesinden duygu tahmini yapan “Emotional Avatar” programını geliştirmişlerdir. Lan ve diğ. (2016) ise çalışmalarında EEG tabanlı duygu durum analizi yaparken, yüz ifadesi odaklı çalışan “Emotional Avatar ve Twin Girls” yazılımlarını eş zamanlı kullanarak deney katılımcılarının, beyin sinyallerinin yanı sıra, yüz ifadesinden de duygu durum analizi tahmini elde etmeye çalışmışlardır. EEG tabanlı duygu tanıma sisteminin gelişmesi, duygu durumunun EEG sinyallerinde nasıl temsil edildiğinin ve kişinin nasıl EEG sinyallerinden duygu durumunu tahmin edebileceğini tanımlayan bilgisayar modelleri gerektirir. EEG’nin duygu indislerini aramanın uzun bir geçmişi olmasına rağmen, duygu durum tahmini için bilgisayar modelleriyle daha az ilgilenilmiştir (Jenke ve diğ., 2014).

EEG gibi durağan olmayan sinyaller için kullanılan sinyal işleme yöntemleri son yıllarda farklı yöntemler önerilerek gelişmektedir. Durağan olmayan sinyallerin analizi Kısa Zaman Fourier Dönüşümü (KZFD) ve Sürekli Dalgacık Dönüşümü (SDD) gibi geleneksel zaman-frekans yöntemleri kullanılarak gerçekleştirilmekteydi. Ancak, bu yöntemler belirsizlik prensibi (*ing:Uncertainty Principle*) nedeniyle (Auger ve diğ., 2013), hem zaman hem de frekans osilasyon komponentlerini eş zamanlı olarak çözmede temel olarak yeterli değildir. Bu yetersizliği çözmek için Görgül Kip Ayırışımı (Huang ve diğ., 1998) ve çok değişkenli uzantıları ve Yeniden Atama Yöntemi (*ing-Reassignment*) (YAY) ve YAY’nın spesifik bir uygulaması olan Senkrosıkıştırma (*ing-Synchrosqueezing*) dönüşümü (SSD) gibi çok sayıda çalışma önerilmiştir (Rehman ve Mandic, 2011; Auger ve diğ., 2013).

2.1. ÖNERİLEN YÖNTEMLERLE İLGİLİ ÇALIŞMALAR

Geçmişten günümüze, duygu modellemesine yönelik çalışmaların bir amacı da gelişmiş sinyal işleme tekniklerini kullanarak duygusal formları daha iyi kavramaktır. Kısa Zaman Fourier Dönüşümü (Rabiner ve Allen, 1977), Ayırık Dalgacık Dönüşümü (Shensa, 1992), Dalgacık Dönüşümü (Daubechies, 1990), Wigner Ville Dağılımı (Bartelt ve diğ.,

1980), Hilbert Huang Dönüşümü (Huang *ve diğ.*, 1998), Gabor Dönüşümü (Yao *ve diğ.*, 1995), Kalman Filtresi (Kalman, 1960), S Dönüşümü (Stockwell *ve diğ.*, 1996), Görgül Dalgacık Dönüşümü (Gilles *ve diğ.*, 2013), sinyal işleme alanında son yıllarda farklı amaçlar için önerilmiştir. Bu yöntemlerin çoğu öznitelik çıkarma işlemi için duygu tanıma alanında kullanılmıştır (Murugappan *ve diğ.*, 2010; Lin *ve diğ.*, 2010; Ozel *ve diğ.*, 2017a). Duygusal durum analizinde, en çok tercih edilen yöntemlerden biri bu sinyal işleme teknikleri arasında Hilbert tabanlı Görgül Kip Ayrışımı (GKA)'dır.(Hadjidimitriou *ve diğ.*, 2012; Zhuang *ve diğ.*, 2017, 2018; Petrantonakis ve Hadjileontiadis, 2010).

GKA, sinyali özgün kip fonksiyonlarına göre (ÖKF) göre analiz edebilir. Bant sınırlı özelliklere sahip sonlu frekans ve genlik modülasyonlu (FM-GM) bileşenlere dönüştürerek sinyali parçalara ayırır. Ayrıca, GKA vasıtasıyla ÖKF'lerine açılımı gerçekleştirdikten sonra, bir ÖKF'nin anlık faz bilgisi edinilebilir. Bu nedenle GKA, duygu tespiti çalışmalarında EEG sinyali gibi doğrusal olmayan ve durağan olmayan sinyallerin araştırılması için önemli bir seçimdir. Doğrusal olmayan ve durağan olmayan veriler için bu yöntemin avantajlarına rağmen, sinyaller her zaman kanallar arası korelasyonu göz önünde bulundurmayıp, kanal olarak ayrı ayrı ele alınır. Ek olarak, GKA yönteminin temel dayanağı, yerel maksimum ve minimum noktaları arasında ardışık olarak interpolasyon yoluyla elde edilen, üst ve alt zarfların ortalaması alınarak hesaplanan yerel ortalamanın saptanmasıdır. Bununla birlikte, çok değişkenli sinyaller söz konusu olduğunda yerel maksimum ve minimum direk olarak karakterize edilemez ve aynı zamanda bir ÖKF'yi tanımlayan "salınım modları" kavramları çok değişkenli sinyaller için önemli ölçüde kullanım kargaşasına yol açmaktadır. Bu amaçla Rehman ve Mandic (2010), GKA yönteminin çok değişkenli uzantısı Çok Değişkenli Görgül Kip Ayrışımı (ÇDGKA) yöntemiyle n-boyutlu uzayda farklı yönler boyunca sinyal projeksiyonları alınarak n-boyutlu zarfların üretildiği, bu zarf eğrilerinin ortalaması bulunduğu ve daha sonra yerel ortalamanın elde edildiği bir yöntem önermiştir. Son yıllarda, sadece veriye dayalı bir teknik olduğu ve tamamen matematiksel ifadelerle gösterilemediği için GKA yöntemi ve çok değişkenli uzantıları için önemli ölçüde araştırma yapılmıştır. Mod karıştırma, son etkisi, durdurma kriteri, interpolasyon süreci vb. gibi GKA algoritması için bazı eksiklikleri çözmek için önerilen çok sayıda metodoloji bunlardan birkaçıdır (Rehman *ve diğ.*, 2013; Torres *ve diğ.*, 2011; Wu ve Huang *ve diğ.*, 2009; Zhu *ve diğ.*, 2013; Singh *ve diğ.*, 2013; Pao *ve diğ.*, 2010; Mattei ve Meignen , 2013; Tianlu ve Zengli, 2013; Niang *ve diğ.*, 2010; Yeh *ve diğ.*, 2010). ÖKF'lerin ortogonallik problemi de önerilen çalışmalardan biridir. (Hu *ve diğ.*, 2018; Hu-

ang ve Kunothe, 2013; Cherian *ve diğ.*, 2014; Oberlin *ve diğ.*, 2012; Ren *ve diğ.*, 2007; Lou ve Huang, 2015, 2007; Huang *ve diğ.*, 2008). Sınırlı sayıda çalışma olması dolayısıyla, hemen hemen hepsi GKA'dan elde edilen ÖKF'lere ve ortogonalite bağlarına odaklanmaktadır. Bununla birlikte, son yıllarda ÇDGKA ların GKA'ye tercih edilmesine rağmen ÇDGKA'den elde edilen ÖKF'lari ve onların ortogonalliklerini dikkate alan bir çalışma bulunamamıştır. Bu eksikliği gerçekleyebilmek için, bu tezde ÇDGKA ile Gram-Schmidt Ortogonalleştirme Yöntemine bağlı yeni bir yöntem olarak ÖKF'lerin ortogonalitesi ve tamamen ortogonal ÖKF'leri elde etme üzerine bir çalışma sunulmuştur.

Günümüzde, Görgül Dalgacık Dönüşümü (GDD) olarak adlandırılan yeni bir yöntem Gilles tarafından sunulmuştur (Gilles *ve diğ.*, 2013). Bu yaklaşım, işlenen sinyale dahilinde spektrum bilgisine bağlı olarak bir adaptif dalgacık filtresi üretmektedir. GDD'nin amacı, spektrum segmentlere ayırmak ve eşleşen bir dalgacık filtre bankası geliştirmektir. Geleneksel GKA yöntemiyle karşılaştırıldığında, GDD tekniği daha tutarlı bir analize sahiptir ve bilimsel teoriye sahip bir alt yapısı vardır (Hu *ve diğ.*, 2017). GDD farklı alanlarda kullanılmasına rağmen duygu durum analizi çalışmalarında henüz kullanılmamıştır.

GKA'nın çok değişkenli uzantısı, tek değişkenli GKA'nı kullanılarak her bir kanalın işlenmesinden daha kolay ve tutarlı olmasının yanında, her bir EEG kanalının ÖKF'lerinde benzer dalgalanma, band genişliği ve otokorelasyon özelliklerine sahip olup, zaman ve frekans domeninde yakın özelliklere sahiptir. Tek değişkenli GKA her bir EEG kanalına ayrı ayrı uygulandığında, her bir kanaldaki ÖKF'lerin sayısı değişmekte birlikte, ÖKF'ler farklı istatistiksel özelliklere sahip olmaktadır (Mert, 2015). Şimdiye kadar, GKA tabanlı duygu tanıma yöntemleri, EEG sinyallerinin standart tekli ve çoklu kanallarını (Zhuang *ve diğ.*, 2017, 2018; Zhang *ve diğ.*, 2016; Petrantonakis ve Hadjileontiadis, 2010, 2012; Khasnobish *ve diğ.*, 2013; Santillan *ve diğ.*, 2013; Petrantonakis ve Hadjileontiadis, 2013; Shannaz *ve diğ.*, 2016; Rutkowski *ve diğ.*, 2008; Bajaj ve Pachori, 2011) kullanarak çalışılmış ve ayrıca çok kanallı algoritma fikri ile ÇDGKA kullanılarak da literatürde duygu durum çalışmaları gerçekleştirilmiştir (Guitton, 2010; Ozel *ve diğ.*, 2017a; Mert ve Akan, 2018; Xu, 2012; Tonoyan *ve diğ.*, 2016). Doğrusal ve durağan olmayan (Huang *ve diğ.*, 1998) veriler için GKA metodunun avantajlarına rağmen, GKA algoritmasını yerel sinyal değişimlerine duyarlılığı çoğunlukla dekompozisyonları beraberinde getirebilir (Wu *ve diğ.*, 2011). Bununla birlikte, GKA yönteminin sonucu, çoğunlukla ÖKF spektrumlarının üst üste binmesi nedeniyle oluşan "mod karıştırma" (*ing-mod mixing*)

ve alt-nyquist extrem örneklemesinin sebep olduğu “örtüşme” (*ing-aliasing*) eğilimlidir. ÇDGKA’da, çok değişkenli durağan olmayan sinyalleri işlerken belirli avantajlara sahip olmasına rağmen, bir dereceye kadar mod karıştırma özelliğine yapısal olarak sahiptir ve bu durum da Gürültü Destekli Çok Değişkenli Görgül Kip Ayrışımı (GD-ÇDGKA)’nın geliştirilmesini motive etmiştir (Rehman *ve diğ.*, 2013).

Veri bağımlı analizde önemli bir adım olan GD-ÇDGKA’nın uygulamaları şu ana kadar zaman-frekans ekseninde dopler radar sinyalleri (Ahrabian *ve diğ.*, 2012), bilgisayar simülasyonları ve “BCI competition IV” veri setlerinden motor imajeri EEG verileri ile (She *ve diğ.*, 2017), ani çözünürlüklü nöronal popülasyonların zaman-frekans analizinde (Cortés *ve diğ.*, 2016), faz senkronizasyonunu kullanarak epileptik nöbetlerin EEG tabanlı tahmininde (Cho *ve diğ.*, 2016), akciğer-kalp sesi ayırımında (Lin *ve diğ.*, 2013) çok kanallı EMG sinyalleri (Zhang *ve diğ.*, 2017) ve VLF-EM (çok düşük frekanslı elektromanyetik yöntem) verisinde bulunan istenmeyen gürültüyü filtrelemede (Sungkono *ve diğ.*, 2017) olumlu sonuçlar elde edilerek kullanılmıştır. Ek olarak, çok değişkenli sinyallerin ayrıştırılması için geliştirilmiş gürültü destekli bir yöntem olarak, Huang *ve diğ.* tarafından kısmi gürültü destekli çok değişkenli GKA önerilmiştir (Huang *ve diğ.*, 2017). Son zamanlarda, Beyaz Gauss Gürültüsü (BGG) (*ing-WGN*) (Rehman ve Mandic, 2011)’den ayrı olarak giriş sinyali için asistan sinyalinin Fraksiyonel Gauss Gürültüsü (FGG) (Hao *ve diğ.*, 2016) ve Sinüzoidal Sinyal (SS) (Ge *ve diğ.*, 2018) kullanıldığı daha farklı yöntemler önerilmiştir.

Senkro Sıkıştırma (SSD), çok bileşenli sinyal işleme ve ayrıştırma için önemli bir araçtır. Kompakt bir zaman frekansı gösterimi ve sinyallerin yeniden yapılandırılmasını sağlar. Teorik olarak güçlü bir matematiksel alt yapı sunar. (Daubechies *ve diğ.*, 2011; Ahrabian *ve diğ.*, 2015; Wu *ve diğ.*, 2011; Huang *ve diğ.*, 2016; Daubechies *ve diğ.*, 2016; Hu *ve diğ.*, 2018). Şimdiye kadar, SSD, uykuda bulunan bir örnek olan ve NREM uykusunun ikinci fazını sınıflandıran K-kompleks çalışmasında kullanılmıştır (Ghanbari ve Moradi, 2017). Ayrıca, Rutkowski (2014) EEG sinyalleri uyarlamalı filtreleme tabanlı SSD kullanarak, tamamen mekansal ses SSVEP beyin dalgası yanıtı sonifikasyon işlemi gerçekleştirmiştir (Rutkowski , 2014). Vasquez-Correa *ve diğ.* (2016) sürekli dalgacık dönüşümü ve biyonomik dalgacık dönüşümü ile zaman frekansı temsiline ek olarak, duygusal ses modellemek için senkro-sıkıştırılmış dalgacık tabanlı zaman frekansı temsiliinin enerji içeriğine bağlı olarak yeni bir öznelite sunmuştur (Vasquez-Correa *ve diğ.*, 2016).

Ek olarak, çocuklarda ve erişkinlerde evre 2 hızlı-olmayan göz hareketi (NREM) uyku özelliklerinin ve EEG olayının önemli bir özelliği olan uyku iğlerinin saptanması için SSD kullanılmıştır (Kabir *ve diğ.*, 2015). Bai *ve diğ.* (2017) uyarılmış EEG osilasyonu ve Transkraniyal Manyetik Stimulasyon (TMS) spektrumundaki geçici aktiviteyi keşfetmede Hilbert-Huang dönüşümü (HHT) ve Dalgacık dönüşümü (WT) ile kıyaslandığında, SSD'nin daha iyi performans gösterdiğini ifade etmişlerdir. Ali *ve diğ.* (2016) çalışmalarında, frekans bileşenlerinin yüksek çözünürlükte lokalizasyonu için EEG sinyalleri ile SSD tabanlı zaman-frekans koheransının KZFD tabanlı süreçten daha iyi sonuç verdiğini gözlemlemiştir. Ayrıca, başka bir biyomedikal sinyal işlemenin bir örneği olarak, SSD, farklı apne türleri hakkında bilgi veren, giyilebilir piezo-elektrik bantları kullanılarak yakalanan torasik (THO) ve abdominal (ABD) hareket sinyallerinde kaydedilen gürültünün etkisini azaltmak için kullanılır (Lin *ve diğ.*, 2017). Benzer şekilde Ferdous ve Ali *ve diğ.* (2017), SSD'nin artefakt tespiti için zaman-frekans gösterimi olasılığını belirtmişlerdir. SSD metodu şimdiye kadar EEG sinyalleri ayrışması için kullanılmasına rağmen duygu durum analizinde henüz kullanılmamıştır.


Öte yandan, teknolojinin gelişmesiyle çok kanallı kayıt yapabilen sensörler geliştirilmiş ve çok kanallı sinyal analizi için bu sensörler aracılığıyla çok değişkenli öznitelik çıkarma yöntemleri geliştirilmiştir. Bu nedenle, bu yöntemler için yeni metodolojiler geliştirilmelidir. Son zamanlarda tek değişkenli modüle sinyaller, çok kanallı sinyallerin ortak osilasyon yapısını modellemek amacıyla ortak anlık frekans ve bandgenişliği özellikleri kullanılarak çok değişkenli uygulamalara göre genişletilmiştir (Ahrabian *ve diğ.*, 2015). Çok değişkenli zaman frekans algoritmaları son zamanlarda sayı olarak artmaktadır (Bhattacharyya ve Pachori, 2017). Bu amaçla Lilly ve Olhede (2009, 2012); Olhede ve Walden (2004) tarafından geliştirilen ilkelere dayalı olarak, çok kanallı sinyallerin kompakt bir zaman-frekans gösterimini geliştiren SSD dayalı zaman frekans algoritması geliştirilmiştir. Çok değişkenli sinyallerin analizinde SSD yöntemini kullanmak için, her bir kanal için modüle edilmiş osilasyon komponentlerinin bilindiği varsayımıyla, modüle edilmiş osilasyonların yeterince birbirine yakın olması koşulu ile ortak anlık frekans belirlenebilir. Bu bakış açısı ile, zaman frekans domeninin ilk bölümü K frekans bandına bölünür. Bu basamak verilen çok değişkenli sinyalden eşleştirilmiş tek değişkenli sinyal ayırt edilmesini sağlar. Bu frekans bandlarında sunulan anlık genlik ve frekanslar, GKA algoritmasındaki ÖKF'larına benzer şekilde genlik ve frekans moduleli osilasyonları üreterek belirlenebilir (Ahrabian *ve diğ.*, 2015). Şimdiye kadar Çok Değişkenli Senkrosıkıştırma Dönüşümü ile

duygu durum analizinde zaman frekans çalışması yapılmamıştır.

Ayrıca, Alfa, Beta, Teta, Gama ve Delta bandı arasında aktivasyon, değerlik ve baskınlık boyutlarıyla ilişki bulmak literatürde incelenmiştir. Bu şekilde Aydın ve ark. (Aydın ve diğ., 2016), grafik kodlama tasarımı yoluyla “db5” dalgacık fonksiyon sinyalinin kullanarak beş frekans bandında (Alfa, Beta, Teta, Gama ve Delta) ayrıştırılmış EEG’yi kullanarak duygu tanıma için dalgacık tabanlı bir özellik çıkarma tekniği önermişlerdir. (Bos, 2006) Beta-Alfa (güç) oranının aktivasyon boyutuyla ilişkili olduğunu, Alfa (güç) Asimetrisinin değerlik boyutuyla ilişkili olduğunu belirtmiştir. (Liu ve Sourina, 2012) ise EEG’den yüksek ve düşük baskınlık seviyesindeki duyguları ayırt etmek için Beta / Alfa oranını kullanan kullanıcıya dayalı bir algoritma önermişlerdir. Ayrıca, (Reuderink ve diğ., 2013) yaptıkları çalışmada teta bandındaki frontal güçte önemli azalmanın ilerledikçe pozitif değerlikle ilişkili olduğunu ve Alfa bandında güçte önemli ölçüde artışın duygusal uyarılmadaki artışla ilişkili olduğunu belirtmektedir. Delta bandında ise, önemli bir önemli sağ posterior güç artışı artan aktivasyon ve değerlik ile düşük alfa aralığındaki güçte asimetri ile ilgilidir. Ek olarak, serebral kortekste önemli olan Beta bandı, heyecanlı duygu durum hali ile ilgilidir (Zhang ve diğ., 2016). Ayrıca, (Blaiech ve diğ., 2013; Vamvakousis ve Ramirez, 2012; Kirke ve Miranda, 2011; Ramirez ve Vamvakousis, 2012; Ramirez ve diğ., 2015) aktivasyon / değerlik ve Alfa bant aktivitesi arasında bir bağlantı bulmak için farklı stratejiler önermişlerdir. Aslında, tüm bu çalışmalara rağmen, Alfa, Beta, Delta, Teta ve Gama bantları ve aktivasyon, değerlik ve baskınlık boyutları arasındaki ilişkiyi örtmek için sayısal olarak daha tatmin edici çalışmalar gereklidir.

2.2. KANAL SEÇİMİ

Son yıllarda, zaman domen, frekans domen, ortak zaman-frekans domen teknikleri, standartlaştırılmamış kanallar ve öznitelik seçimi önerileri ile yapılan çalışmalarda duygu modellemesi tartışmalı bir konudur. Özellikle, farklı dataseti ve farklı kanalların kullanılmasıyla dataseti grupları ve kanallar arasında birbirinden farklı öznitelik çıkarma teknikleri yöntem performansları karşılaştırmayı zorlaştırır. Bu nedenle, daha iyi sınıflandırma sonuçları elde etmek için yöntemlerin farklı kanallar gerektirip gerektirmediğini veya duygusal durum analizinde seçilen doğru kanalların daha iyi sınıflandırma sonuçları verdiğini anlamak için kanalları ve datasetini sabit tutan bir inceleme gereklidir.



Şekil 2.2: Uluslararası 10-20 Sistem Kanal Yerleşimi

Duygusal durum analizi göz önüne alındığında kanal seçimi beyinin tüm bölümlerinin duygu tanımda işlevi olmadığından önemli bir problemidir. Özellikle, frontal lob üzerine yerleştirilen kanallar duygusal durum analizi çalışmalarında kullanılır. Ancak, tercih ettikleri kanal düzenlemesinde seçilenleri veya kanallardan sadece birini kullanan çalışmalar da vardır. **Tablo 2.1:** ve **Tablo 2.2:**'de, nöro-bilimsel bilgiye dayanarak literatürde kullanılan kanallara göre de bilgi sunmaktadır.

Öznitelik seçimi göz önüne alındığında, Alarcao ve Fonseca (2017), duygu tanıma tercihinde en çok kullanılan kanalların F4 (% 82.9), F3 (% 77.14), T7 (% 65.7), FP1 (% 65.7) FP2 (% 60), T8 (% 60), F7 (% 60), F8 (% 60), Oİ (% 54.3), P7 (% 54.3), P8 (% 51.4), O2 (% 51.4), FC5 (% 40), FC6 (% 40), C4 (% 40), C3 (% 34.3), AF3 (% 34.3), AF4 (% 34.3), P3 (% 28.6), P4 (% 25.7)) olduğu sonucuna ulaşmışlardır. Kanalların yerlerini tespit etmek için Uluslararası 10-20 Sistem Kanal Yerleşimi **Şekil 2.2:** de

sunulmuştur. Diğer taraftan, Jenke, farklı öznitelik çıkarma teknikleri (Yüksek Sıra Geçişleri (YSG), Hjorth'ın Karmaşıklığı, Durağan Olmayan Indis, Fraktal Boyut (*ing-Higher Order Crossings*, *Hjorth's Complexity*, *Non-stationary Index*, *Fractal Dimension*)) farklı kanal konumları için farklı sonuçlar verdiğini ortaya koymuştur (Jenke ve diğ., 2014). Ayrıca Cohen'in etki büyüklüğüne (f_2) bağlı olarak istatistiksel olarak esinlenen bir kanal / özellik seçim süreci önermişlerdir (Jenke ve diğ., 2013). Ek olarak, Zhang ve diğ. (2016) EEG-temelli duygu tanıma için ReliefF-tabanlı kanal seçim hesaplarını incelemişlerdir, Hatamika ve diğ. (2016), farklı duygusal sınıflar için kanal azaltımı için Ortak Uzaysal Örüntü Yöntemini (*ing-Common Spatial Pattern Method*) kullanmışlardır. Zhuang ve diğ. (2018), Minimal Fazlalık Maksimal Uygunluk (*ing-Minimal Redundancy Maximal Relevance (MRMR)*) yöntemi ile duygu algılama için kanalların göze çarpan özelliklerini ve dağılımlarını incelemiş ve beyin topoğrafya haritasına göre kanal dağılımını belirtmişlerdir. Ayrıca, aynı çalışma arkadaşları başka bir çalışmada, GKA ile ÖKF 1'in öznitelik çıkarmada kullanılması koşuluyla önemli kanalları seçmek için Fisher Mesafesi (*ing-Fisher Distance*)'ı kullanmışlardır (Zhuang ve diğ., 2017). Ozerdem ve Polat ve diğ. (2017), kanal seçimi için Çok Katmanlı Yapay Sinir Ağları'nı (*ing-Multilayer Perceptron Neural Network (MLPNN)*) kullanmışlardır ve buna göre her bir kişinin bağımsız olarak değerlendirilen 32 kanalından EEG kayıtları ve en üstün performansı gösteren beş EEG kanalı kademeli olarak kararlaştırılmıştır.

Bununla birlikte, duygu tanıma konusundaki kanal tercihleri, yukarıda bahsedilen kanallar için öznitelik seçim yöntemlerinden ziyade **Tablo 2.1:** ve **Tablo 2.2:**'de gösterildiği gibi nörobilimsel bilgiye de dayanmaktadır. Nöro bilime dayanarak seçilen kanala göre çalışmalar ile öznitelik seçimi uygulanarak seçilen kanallı çalışmalar çoğunlukla aynı kanal gruplarını içermemektedir. Dolayısıyla, duygu tanımda sınıflandırma için sayısal olarak daha başarılı kanalları ayırt edecek daha fazla çalışmaya ihtiyaç vardır.

Öte yandan, literatürde simetrik elektrot çiftlerini kullanarak çalışmalar mevcuttur. Bu çalışmalardan, DEAP veri kümesi 32 kanaldan güç spektral öznitelikleri elde edilmesinin yanı sıra, 14 elektrot çifti için duygusal uyaranlara bağlı beyin aktivitelerindeki olası asimetriyi ölçmek için sağ ve sol hemisferdeki tüm simetrik elektrot çiftlerinin spektral gücü arasındaki farklar da çıkarılmıştır (Koelstra ve diğ., 2012). (Hadjidimitriou ve diğ., 2012) çalışmalarında, yedi simetrik kanal çiftinin her biri için tahmini öznitelikleri elde etmek amacı ile kanal farkını alıp diferansiyel asimetri indeksi kavramından faydalanmışlardır.

Bunların dışında, (Lin *ve diğ.*, 2010), (Kroupi *ve diğ.*, 2011), (Mert ve Akan, 2018) ve (Rozgic *ve diğ.*, 2013) çalışmalarında elektrot çifti farkını kullanmışlardır

Dolayısıyla, bütün bu verilerden faydalanarak, bu çalışmada sağ frontal ağırlıklı lobun (Fp2, AF4, F4, F8, FC2, FC6, T8, C4), sol ağırlıklı frontal lobun (Fp1, AF3, F3, F7, FC1, FC5, T7, C3), sağ ve sol frontal ağırlıklı lob farkları (Fp1-Fp2, AF3-AF4, F3-F4, F7-F8, FC1-FC2, FC5-FC6, T7-T8, C3-C4) ve 2 merkez kanalı (Fz, Cz), giriş verileri olarak toplamda 26 kanallı EEG sinyali giriş olarak oluşturulmuştur. Bu bölgedeki EEG kanalları, beynin frontal lobundaki afektif alanın varlığı nedeniyle duygusal durum analizi çalışmalarında kullanılır.

Tablo 2.1: EEG sinyalleri kullanılarak gerçekleştirilen DDA çalışmalarında kanal seçimi (2004-2012 yılları arası)

Yazar	Kanallar
(Takahashi, 2004)	3 Kanal
(Bos, 2006)	F3, F4, Fpz
(Balconia ve Lucchiari, 2006)	Fz,Cz, Pz, Oz, F3, F4, C3, C4, T3, T4, P3, P4, O1, O2
(Baumgartner ve diğ., 2006)	F7, F3, FT7, FC3, F4, F8,FC4, FT8, TP7, CP3, P7, P3, CP4, TP8, P4, P8
(Ansari-Asl ve diğ., 2007)	CP5, CP6, F3, F4, Afz
(Chanel ve diğ., 2007)	64 Kanal
(Murugappan ve diğ., 2007)	63 ve 24 Kanal
(Horlings ve diğ., 2008)	32 Kanal
(Khalili ve Moradi, 2008)	Fp1, Fp2, F7, F8, F3, F4, Fz, T7, T8, C3, C4, Cz, P7, P8, Pz, P3, P4, O1, O2
(Li ve Lu, 2009)	64 Kanal
(Frantzidis ve diğ., 2010)	Fc, Cz, Pz
(Petrantonakis ve Hadjileontiadis, 2010)	Fp1, Fp2, F3/F4
(Lin ve diğ., 2010)	30 Kanal, 12 Simetrik Kanal Çifti
(Khosrowabadi ve Rahman, 2010)	P3, P4, T7, T8, C3, C4, F3, F4
(Hosseini ve diğ., 2010)	Fp1, Fp2, T3, T4, Pz
(Hosseini ve diğ., 2010)	Fp1, Fp2, T3, T4, Pz
(Nie ve diğ., 2011)	62 Kanal
(Makeig ve diğ., 2011)	128 Kanal
(Brown ve diğ., 2011)	Fp1, Fp2, F3, F4, F7, F8, C3, C4
(Kroupi ve diğ., 2011)	32 Kanal
(Wang ve diğ., 2011)	62 Kanal
(Sourina ve Liu, 2011)	AF3, F4, FC6
(Liu ve Sourina, 2012)	AF3, F7, F3, FC5, FC6, F8, AF4, P7, P8, T8, F4, F8, AF4
(Konstantinidis ve diğ., 2012)	19 Kanal

Tablo 2.2: EEG sinyalleri kullanılarak gerçekleştirilen DDA çalışmalarında kanal seçimi (2012-2018)

Yazar	Kanallar
(Hadjidimitriou ve diğ., 2012)	19 Kanal
(Rozgic ve diğ., 2013)	32 Kanal
(Reuderink ve diğ., 2013)	32 Kanal
(Liu ve Sourina, 2013)	32/14 Kanal
(Jirayucharoensak ve diğ., 2014)	p1, AF3, F3, F7, FC5, FC1, C3, T7, CP5, CP1, P3, P7, PO3, O1, Oz, Pz, Fp2, AF4, Fz, F4, F8, FC6, FC2, Cz, C4, T8, CP6, CP2, P4, P8, PO4, O2
(Jie ve diğ., 2014)	F3, CP5, FP2, Fz, FC2
(Jenke ve diğ., 2014)	P9, P5, P7, P1, FC2, CP2, CP1, F5, T8, P10, C2, Cz, CP5, CP3, P3, F7
(Paul ve diğ., 2015)	F3, F4, Fz, P3, P4, T3, T4
(Lu ve diğ., 2015)	62 Kanal
(Gao ve diğ., 2015)	Fp1, Fp2, C3, C4, F3, F4
(Vaid ve diğ., 2015)	Fp1, Fp2, F3, P3, F4, T7, T8, P4, O1, Pz, PO3, O2, P7, CP2, C4
(Zhang ve diğ., 2016)	F3, F4
(Kumar ve kumar ve diğ., 2016)	32 Kanal
(Lopez-Gil ve diğ., 2016)	AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4
(Zhuang ve diğ., 2017)	Fp1, Fp2, F7, F8, T7, T8, P7, P8
(Thammasan ve diğ., 2017)	Fp1, Fp2, F3, F4, F7, F8, Fz, C3, C4, T3, T4, Pz
(Liu ve diğ., 2017)	32 Kanal
(Tripathi ve diğ., 2017)	32 Kanal
(Al-Nafjan ve diğ., 2017)	Fz, AF3, F3, AF4, F4
(Cai ve diğ., 2018)	Fp1, Fp2, Fpz
(Mohanapriya ve diğ., 2018)	14 Kanal
(Katsigiannis ve Naeem, 2018)	14 Kanal
(Zhuang ve diğ., 2018)	62 Kanal

2.3. HİBRİD MODELLER

Duygu durum analizi çalışmalarında Hibrid Model kavramı son yıllarda Görgül Dalgacık Dönüşümü ve Görgül Kip Ayırışımı yöntemlerinden elde edilen ÖKF'ler sonrası osilasyonun taşıdığı bilgiden daha fazla faydalanmak için farklı bir yöntem daha önerilmesi ile elde edilir. İlk olarak, Petrantonakis ve Hadjileontiadis (2010) duyguya bağlı EEG özelliklerinin etkin bir şekilde çıkarılması için yeni bir filtreleme prosedürü olan Hibrid Adaptif Filtreleme (HAF) yöntemini, EEG sinyallerinin GKA analizine dayalı temsiline Genetik Algoritma uygulanarak geliştirmiştir. Ek olarak, HAF filtreli sinyallerden öznitelik çıkarımı gerçekleştirilmesi için YSG analizi kullanılmıştır. Benzer şekilde Zhang *ve diğ.* (2016) önerdikleri EEG tabanlı duygu durum analizi modelinde GKA sonrası elde edilen ÖKF'lere Örnek Entropi-(*ing Sample Entropy*) yöntemini uygulayarak duygu durum sınıflandırması çalışmışlardır. Das ve Bhuiyan (2016), EEG sinyaline GKA uygulamasından sonra ADD yöntemi kullanılarak spektral entropi bazlı öznitelikleri epilepsi hastalığı çalışmasında kullanmışlardır. Shannaz *ve diğ.* (2015) mevcut ses sinyallerini doğrudan işlemek yerine, önce GKA yöntemini kullanarak ÖKF'leri çıkarıp ve daha sonra baskın ÖKF'lere ADD uygulamıştır.

Bunların dışında, son yıllardaki GKA'nın çok değişkenli uzantısının önerilmesi ile hibrid model kullanımında ÇDGKA yöntemine doğru geçiş olmuştur. Mert ve Akan (2018), ÇDGKA algoritmasından elde edilen ÖKF kümelerinin güç spektral yoğunluğu (GSY), entropi, Hjorth parametreleri, korelasyon ve sol ve sağ yarıküredeki asimetrik özellikleri hesaplayarak duygu tanıma doğruluğunu arttırmak için özellik vektörünü zenginleştirerek sınıflandırmayı gerçekleştirmiştir. Tonoyan *ve diğ.* (2016) çok değişkenli çoklu ölçekli entropi (*ing multivariate, multiscale entropy*) uzantılı ÇDGKA ile duygu durum analizi değerlendirmesi gerçekleştirmişlerdir. Ek olarak, (Xu ve Plataniotis, 2015) ve Guitton (2010) çalışmalarında ÇDGKA sonrası elde edilen ÖKF'lere farklı yöntemler uygulayarak elde edilen özniteliklerle duygu durum analizi sınıflandırması gerçekleştirmişlerdir.

Hibrid GKA ve ÇDGKA yöntemlerinden farklı olarak, Huang *ve ark.* (Huang *ve diğ.* (2017) çalışmasından GDD yöntemini kullanarak sinyali ÖKF lerine ayırıp, seçilen ÖKF lerin Otoregresif Model (*ing Autoregressive Model*) katsayılarını hesaplamışlardır. Ayrıca, duygu durum analizi çalışmaları dışında ÖKF'den sonra kullanılacak optimum yöntem önerisi üzerine çalışmalar da devam etmektedir (Huang ve Kunoth , 2013; Yin *ve diğ.*,

2012; Chen *ve diğ.*, 2018, 2017; Azami *ve diğ.*, 2016; Khosropanah *ve diğ.*, 2017).

GKA ve SSD algoritmalarındaki kısıtlamaları minimize etmek için de yeni çalışmalar ortaya çıkmaya başlamıştır. (Chui ve Mhaskar, 2016; Chui *ve diğ.*, 2016) çalışmalarında, SSD algoritması GKA uygulandıktan sonra oluşan ÖKF'lerine uygulayarak hibrid bir GKA-SSD modeli önermişlerdir. Bununla birlikte, GKA-YAY (Pouryazdian *ve diğ.*, 2015) çalışması da hibrid model olarak uygulanmıştır.

2.3.1. Özgül Kip Fonksiyonu Seçimi

Analiz edilecek olan ÖKF'lerin seçimi, genellikle kullanıcının görsel veya deneyim ölçütleriyle gerçekleştirilir. Dolayısıyla, sinyal hakkındaki ilk bilgiye bağlıdır. Bu şekilde süreç otomatik değildir ve kullanıcı ile etkileşim gereklidir ancak tekniği daha hızlı hale getirmek için Ricci ve Pennacchi (2011) Merit İndeks'i (*ing-merit index*) önermişlerdir. She *ve diğ.* (2017) ise GD-ÇDGKA kullanarak elde ettikleri ÖKF'ler için ve Jensen-Shannon Mesafe (*ing-Jensen-Shannon Distance (JSD)*) ölçütlerine dayanarak, ön bilgi olmaksızın ilgili ÖKF'lerin yeni bir ayırt etme yöntemini önerilmiştir. Ek olarak, Cho *ve diğ.* (2014), çalışmalarında ÖKF'lerin güç ve harmoniklik indeksini temel alarak bir kriter oluşturup ÖKF seçimlerini gerçekleştirmişlerdir. Boutana *ve diğ.* (2010) çalışmalarında, Minkowski mesafesine ve sıra α (α -JRD) 'nin Jensen Rényi sapmasına dayalı olarak, ayıklanan bir gruptaki uygun ÖKF'leri otomatik olarak seçmek için yeni bir ölçüt önermektedir. Uddin *ve diğ.* (2016) çalışmalarında, ortaya çıkan ÖKF'leri, eğitilmiş bir DVM kullanarak ilgili gürültüden etkilenmeyen ÖKF'ler ve ilgisiz gürültü baskın ÖKF'leri olmak üzere iki kategoriye ayırılır. DVM'nin denetimli eğitimi için Pearson Korelasyon Katsayısı kullanılıp, gürültülü ÖKF'ler daha sonra Savitzky-Golay filtresi kullanılarak gürültüsüz hale getirilmiştir. Zhuang *ve diğ.* (2018) çalışmalarında en yüksek osilasyona sahip ilk ÖKF ile duygu durum analizi çalışmalarını gerçekleştirmiştir. Zhang *ve diğ.* (2011) çalışmalarında, ÇDGKA 'nın çift kutuplu filtre görevi gördüğü ve FGG'nin bu filtrede optimum çıkış verdiği sonucu ile hareket etmişlerdir. Bu nedenle FGG, gerçek EEG sinyallerini temsil eden ÖKF'leri belirlemek için bir referans sinyali olarak düşünülebileceği gerekçesiyle (Hao *ve diğ.*, 2016), FGG'ne ÇDGKA algoritması uygulayıp, elde ettikleri ÖKF lerin ortalama gücünü alarak, çalışmalarındaki ÇDGKA metod uygulayarak elde ettikleri ÖKF lerin ortalama gücü ile karşılaştırıp uygun ÖKF'leri seçmeyi önermişleridir. Ana sinyal ile ÖKF lerin korelasyonuna bakılarak ÖKF seçimi yapan çalışmalarda mevcut-

tur (Kotan ve Aydin, 2018). Zhang ve diğ. Zhang ve diğ. (2016) önemli ÖKF'leri elde etmek için, ÖKF'lerin kümülatif varyans katkı oranı (*ing-Cumulative Variance Contribution Rate*) hesaplamışlardır. Bu tez çalışmasında Zhang ve diğ. (2016) 'ın önerisi referans alınarak ÖKF seçimi yapılmıştır.

2.4. DUYGU DURUM MODELLERİ

Duygu, genellikle ruh hali, mizaç, kişilik, eğilim, motivasyon ve memnuniyet veya belli bir düzeyde memnuniyetsizlik ile iç içe yoğun zihinsel aktivite ile karakterize edilen kişisel bilinçli bir deneyimlerdir. Son zamanlarda, gelişen teknoloji ve insan-makine etkileşiminin artışı sayesinde, etkili bir beyin bilgisayar arayüzü oluşturmak için bir duygunun türlerini ve seviyelerini anlamak ve açıklamak için makineyi uygun sayısal duygu modelleri ile donatmak gerekir.

Duygu sınıflandırması, Ekman ve diğ. (1987) ve Parrot'un ağaç yapısı Parrot (2001) tarafından önerilen mutluluk, üzüntü, korku, sevinç, öfke şaşkınlık ve iğrenme gibi altı temel duygu olarak gerçekleştirilebilir. Bu ayrık duygu etiketleri, genel duygusal etiketler açısından çoğu dil ile aynıdır. Ayrık yaklaşımın avantajı, günlük yaşamda insanların normalde gözlemlenen duyguları ayrı kategoriler açısından tanımlamalarıdır. Dezavantajı ise, doğal iletişimde ifade edilen duyguların kapsamını ayırt edememesidir. Bununla birlikte, duygular sürekli bir olgu halinde olduğu için, duyguların derecesi veya gücü, ayrık duygu etiketleriyle ifade edilemez. Duygular, duygu tanıma için en yaygın kullanılan boyutsal model olarak bilinen Plutchik (1980) ve Russell (1980) tarafından önerilen değerlik ve aktivasyon düzlemi gibi sürekli etiketlerle de ifade edilebilir. Bu düzlemlerde aktivasyon, inaktif (örneğin, kayıtsız, sıkılmış) ve aktif (örn. dikkatli, coşkulu) arasındaki domeni içerirken, değerlik, memnun olmayan (ör. üzgün, stresli) ve memnun (örneğin, neşeli, eğlenirilmiş) arasındaki alanı kapsar. İçsel olarak kişinin duygularını kontrol edememesinden kontrol edebilmesine göre düzenlenen domene göre değişen üçüncü boyut baskınlık da boyutsal modele dahil edilmiş ve duygusal durum analizi için iki boyutlu (2B) (Mert ve Akan, 2018; Liu ve diğ., 2011; Ortman ve diğ., 2013; Khosrowabadi ve diğ., 2010), üç boyutlu (3B) çalışmalar modeller, literatürde değerlik-aktivasyon (DA) boyutu ve baskınlık boyutu dahil olmak üzere değerlik-aktivasyon-baskınlık (DAB) olarak çalışılmıştır (Verma ve Tiwary ve diğ., 2017). Son yıllarda, EEG'ye dayanan farklı duygu tanıma al-

goritmaları da tanıtılmıştır (Petrantonakis ve Hadjileontiadis, 2010). Ancak, farklı boyutlarda sürekli duygusal analiz durumunda daha fazla çalışmaya ihtiyaç vardır. Literatürdeki duygu durum modelleri aşağıdaki gibi özetlenmiştir.

2.4.1. Ayrık Modeller

Ekman ve Friesen Modeli:

Ekman ve diğ. (1987), insanların izole kültürünü incelemeye dayalı altı temel duyguyu tanımlamışlardır. Deney katılımcıları bu altı duyguyu resimler üzerinde tanımlayabilmıştır. Bundan sonra, bu katılımcıların yüz ifadeleri aynı duygularla çekilmiştir ve bu resimleri tüm dünyadaki diğer ırk ve kültürlerden insanlara sunulmuştur.




Şekil 2.3: Altı Temel Duygu İfadesi

² <http://www.grimace-project.net/>

Parrot'un Ağaç yapısı:

Parrot (2001) tarafından üç yapılandırılmış bir liste önerilmiştir; buradaki ilk seviye altı temel duygudan (aşk, sevinç, sürpriz, öfke, üzüntü, korku, şaşkınlık) oluşmaktadır. Parrot'un sınıflandırmasının ilk iki tabakası **Şekil 2.4:**'de gösterilmiştir. Bu sınıflandırma da ikincil duygular, duyguların birleşiminden ziyade birincil olanların türetilmesinden oluşmaktadır .




Şekil 2.4: Parrots'un Ağaç yapısı diagramı

2.4.2. Boyutsal Modeller

2.4.2.1. İki Boyutlu Modeller

Circumplex Model:

Circumplex Modeli (Russell, 1980), James Russell tarafından geliştirilmiş bir model olup, duyguların aktivasyon ve değerlik boyutlarını içeren iki boyutlu dairesel bir alanda dağıtıldığını öne sürmektedir. Aktivasyon dikey eksenini temsil ederken ve değerlik yatay eksenini temsil eder ve dairenin merkezi nötr bir değerliği ve orta seviyedeki uyarımı temsil eder. Bu modelde, duygular, bu etiketlerden birinin veya her ikisinin varoluş seviyesinde ya da nötr seviyesinde temsil edilebilir. Circumplex modeli, değerlik-aktivasyon modeli olarak da bilinir. **Şekil 2.5:**'de Circumplex Modeli sunulmaktadır.




Şekil 2.5: Circumplex-(Değerlik-Aktivasyon) Modeli

Circumplex model, farklı duyguların uzaysal yerinin gösterilebilmesi amacı ile görsel bir çerçeve içinde benzersiz ilişkiler gösteren bir model olarak tasarlanmıştır. Ancak bu model, tüm duygular dizisinin nasıl ilişkili olduğunu yeterince gösterememiştir. Bunun yerine, çapraz eksenler ile çeyreklere ayrılan dairesel bir model ile duygu temsilleri ifade edilmiştir (Verma ve Tiwary ve diğ., 2017).

Vektör Modeli:

Duygu vektör modeli 1992 yılında ortaya çıkmış olup, bu iki boyutlu model, "bumerang şekli" ni temsil eden iki yönde işaret eden vektörlerden oluşur. Model, her zaman altında yatan bir uyarılma boyutunun var olduğunu varsayar ve bu değerlik belli bir duyguya kadar uzanan yönü belirler. Örneğin, modelde pozitif bir değerlik, duyguyu üst vektöre kaydırırken negatif bir değerlik, duyguyu alt vektöre kaydırır. Bu modelde, yüksek uyarılma durumları değerlikleriyle ayrışırken, düşük uyarılma durumları daha nötrdür ve vektörlerin buluşma noktası yakınlarında temsil edilir. Vektör modelleri, kelime ve resim uyaranlarının test edilmesinde en yaygın şekilde kullanılmaktadır (Bradley *ve diğ.*, 1992). **Şekil 2.6:**'da Vektör modeli görülmektedir.




Şekil 2.6: Vektör Modeli

PANA Modeli:

Positif Aktivasyon- Negatif Aktivasyon Modeli - (*ing Positive Activation-Negative Activation Model (PANA)*) ya da duyuşsal duygu modeli ilk olarak 1985'te Watson ve Tellegan tarafından önerilmiştir. Bu modelde pozitif etki ve negatif etkinin iki ayrı sistem olduğu düşünülmektedir. Vektör modeline benzer şekilde, daha yüksek uyarılma durumları, değerlik ile tanımlanmaya eğilimlidir ve düşük uyarılma durumları, değerlik açısından daha nötr olma eğilimindedir. PANA modelinde, düşey eksenler düşükten yükseğe pozitif duy-


guyu gösterirken ve yatay eksen düşükden yükseğe negatif duyguyu temsil eder. Değerlik ve uyarılma boyutları, bu eksenler üzerinde 45 derecelik bir rotasyonda konumlanmıştır (Watson ve Tellegan, 1985). **Şekil 2.7:**'de PANA modeli gösterilmektedir.



Şekil 2.7: PANA Modeli

rSASM Modeli:


Yeniden Yapılandırılmış Ses Duygusal Uzak Modeli (*ing-The Recalibrated Speech Affective Space Model (rSASM)*) daha önce kültürel olarak etkilenen konuşma duygusunu tanımak için önerilmiştir. rSASM’de, duygu ilkel değerleri, öznel sınıflandırması için amaçlanan çıktı olarak hazırlanan 4 çeyrek daire duygudan türetilir. Yöntemi kullanan çalışmada için rSASM’ nin yorumu **Şekil 2.8:**’de gösterilmiştir (Ortman ve diğ., 2013).



Şekil 2.8: rSASM Modeli

12-PAC Modeli:

Son zamanlarda önerilen 12 Noktalı Duygusal Circumplex (*ing- 12-Point Affect Circumplex (12-PAC)*), 4 korelasyonel çalışmaya dayalı farklı ruh halleri ve duyguların farklı boyutsal modelini bütünleştirmektedir, dolayısıyla duygu durum analizinde daha yüksek hassasiyette bir geometrik model üretmektedir. Bu modelde, duygu temel değerleri



Şekil 2.9: 12-PAC Modeli


harici değişkenlerin yerleştirilmesine dayanan Yık. ve dig. nin çalışmasına dayanır. **Şekil 2.9:**'da, mutlu, üzgün, korku duygularının tam yerini gösterir. 12-PAC Modelinde, $\theta +$ her bir değişkenin tahmini açısı olarak tanımlanırken, $\zeta +$ CIRCUM modelinde 12-PAC yapısı için açıklanan harici değişkenin oranın karekökü olarak tanımlanır (Ortman ve diğ., 2013). 12-PAC modeli için hem $\theta +$ hem de $\zeta +$ değerlerini kullanarak, değerlik ve uyarılmanın tam duygu temel değerleri v_{pc} ve α_{pc} aşağıdaki Eşitlik 2.1'deki gibi verilir.

$$v_{pc} = \zeta + \cos\theta \qquad \alpha_{pc} = \zeta + \sin\theta \qquad (2.1)$$

2.4.2.2. Üç Boyutlu Modeller

PAD modeli:


Hoşnutluk, uyarılma ve baskınlık (*ing pleasure, arousal, dominance (PAD)*) duygusal durum modeli, duygusal durumları tanımlamak ve ölçmek için Albert Mehrabian ve James A. Russell tarafından geliştirilen psikolojik bir modeldir. PAD tüm duyguları temsil etmek için üç sayısal boyut kullanır. Hoşnutluk-Hoşnutsuzluk ölçeği, bir duygunun ne kadar hoş olabileceğini ölçer. Örneğin, hem öfke hem de korku hoş olmayan duygulardır ve hoşnutsuzluk skalasında yüksek puan alırlar; ama neşe hoş bir duygudur. Bu etiket, Circumflex modelindeki değerlik parametresi ile eşdeğerdir. Uyarılma-uyarılmama ölçeği, duygunun yoğunluğunu ölçer. Örneğin, hem öfke hem de kızgınlık hoş olmayan duygular olsa da, öfke daha yüksek yoğunluğa veya daha yüksek uyarılma durumuna sahiptir. Ancak, aynı zamanda hoş olmayan bir durum olan can sıkıntısı, düşük bir uyarılma değerine sahiptir. Literatürdeki Aktivasyon etiketi ile aynı şartlar için kullanılır. Hakimiyet-itaatkarlık ölçeği, duyguların kontrolünü ve baskın doğasını temsil eder. Örneğin, hem korku hem de öfke hoş olmayan duygular olsa da, öfke baskın bir duygu iken, korku daha itaatkar bir duygudur (Mehrabian ve Russell *ve diğ.*, 1974). **Şekil 2.10:**'da PAD Modeli gösterilmektedir.



Şekil 2.10: PAD-(Değerlik-Uyarılma-Baskınlık) Modeli

Löwheim Kübü

Lwheims duygu küpü, monoamin nörotransmitterler ve duygular için üç boyutlu bir modeldir. Bu modelde, monoamin sistemleri ortogonal eksenler boyunca temsil edilir ve Tomkins tarafından tanımlanan sekiz temel duygu, kübün her bir uç köşesine yerleştirilir. En önemli monoamin nörotransmitterleri serotonin, noradrenalin ve dopamindir. Bu nörotransmitterler duygu ve davranışların kontrolü için önemlidir. Serotonin eksenini özgüven, iç güç ve tatmini temsil ederken, dopamin eksenini ödül, müzakere ve pekiştirme ile ilgilenmektedir. Noradrenalin eksenini aktivasyonu, uyanıklığı ve dikkati temsil eder. Duygu etiketleme, değişen seviyelerde monoamin nörotransmitterleri ve Tomkins tarafından etiketlenen sekiz temel duygunun üzerinde yapılır. Model, psikiyatrik hastalığın anlaşılmasına ve psikotrop ilaçların etkisine odaklanarak nörobiyolojik alanda uygulanabilir. Lwheims küpünün iyi modellenmiş olmasına rağmen, geçerliliğini sağlamak için deneysel olarak test edilmesi gerekir. Model, metin içinde duygu etiketleme için kullanılamaz çünkü üç boyutlu bir kübik modeldir ve metinde monoamin sistemlerinin etkisini tespit etmek zordur (Löwheim ve diğ., 2012). **Şekil 2.11:**'de Löwheim Kübü gösterilmektedir.




Şekil 2.11: Löwheim Kübü

2.4.3. Hem Ayrık ve Boyutsal Olan Modeller

Plutchik Modeli:

Plutchik (1980), duyguları 8 başlangıç sınıfına ayırmıştır buna göre duygular temelde; sevinç, güven, korku, şaşkınlık, üzüntü, tikslenme, öfke ve beklenti olmak üzere modelde zemin oluşturmaktadır. Sonrasında bu 8 duyguyu, 3'lü kategorilere ayırmıştır. **Şekil 2.12:**'de çarkıfeleğin her bir kanadında, her bir duygunun 3 ayrı kategorisi de görülmektedir.

Ek olarak, bu kanatların arasında kalan duyguları da, o iki kanadın birleşmesi ile sınıflandırıp değerlendirmiştir. Örnek olarak, sevinç ve güven bir araya gelince aşkı oluşturmaktadır. Dahası, bu çarkıfeleğin daha da kompleks versiyonlarını da geliştirilmektedir (Plutchik, 1980).³




Şekil 2.12: Plutchik'in Duygu Çarkıfeleği

³ www.6seconds.org

Kumsaati Modeli:

Kumsaati modeli (*ing-Hourglass Modeli*), Plutchik (1980)'in modeline dayanan yeni bir duygusal model olup, hem etiketler aracılığıyla, hem de dört bağımsız, aynı zamanda birbiriyle bağlantılı duygusal boyutlar vasıtası ile tecrübe edilen herhangi bir duygusal deneyimlerin tam aralığını tanımlar. Duyguların Kum Saati, her bir duygusal boyut için çoklu (polarize) aktivasyon seviyeleri kullanılıp, dörde kadar duygunun aynı anda ifade edilebildiği ve cebirsel bir biçimde onlarla ilgili mantıksal çıkarım yapan durumları kapsar. Model aynı zamanda hem tek kelimelerde hem de çok kelimeli ifadelerde duygusal sağduyu muhakemesine izin verir ve duygu analizine ve duygu tanımayı birleştirmeye yönelik ilk açık denemeyi temsil eden duygulara dayalı kutupluluğu hesaplamak için bir formül sağlar (Cambria ve diğ., 2012). **Şekil 2.13:**'de Kumsaati Modeli sunulmuştur.



Şekil 2.13: Kumsaati Modeli

Her modelin kullanım veya uygulama açısından kendi avantajları ve dezavantajları vardır. PANA ve Circumplex modelleri duygusal durumu değerlendirmek için çok güçlü ve basit araçlardır. Duygu, eksenin bir ilgi değişkenine (örneğin uyarılma, değerlik) verildiği bir düzlemde bir nokta olarak modellenir. Böyle bir yaklaşımı temel almak ve anlamak kolaydır. Plutchik ve Kumsaati Modeli değişkenlerin sayısındaki farkla benzer bir yöntem kullanır. PAD modelinde duyguların modellendiği daha fazla eksen vardır. Bu modelde çalışanlar, ayrı modellerle bir çeşit uyumluluğu sağlamak için, belirli bölgelere belirli etiketleri belirli bir şekilde atarlar. Bu modeller, ayrı açıdan daha gelişmiş kompleksiteye ve kompleks duyguları ifade etme yeteneğine sahiptir. Karmaşıklığa rağmen belirtilen modeller kişisel tipolojiyi dikkate almaz. Dolayısıyla bu alan halen gelişime açıktır.

Bunların dışında duygu durum analizi çalışmalarında Navaras Modeli (Kumar ve kumar *ve diğ.*, 2016), GEMs Modeli, Schimmack & Grop Modeli, Thayer's Modeli (Eerola ve Vuoskoski, 2010), Ortony, Clore ve Collins (OOC) modeli, Five Factors Modeli (FFM) (Bruna *ve diğ.*, 2016) gibi farklı modellerde literatürde kullanılmıştır.

2.5. DUYGU DURUM ANALİZİ

2.5.1. Kullanıcıya dayalı ve Kullanıcıdan bağımsız Analiz

Duygu durum analizi sınıflandırma sürecinde, bir başka önemli boyutu sınıflandırıcının kullanıcı bağımlı verilerle eğitilip eğitilmediğidir. Kullanıcıya bağlı veriler durumunda, her kullanıcı için yeni bir model oluşturulur ve test adımı bu kullanıcı verileriyle de yapılır. Genellikle, daha iyi sonuçlar elde edilir, ancak genelleme yapmanın dezavantajını göz önünde bulundurmak gerekir. Kullanıcı bağımsız bir modelde, birden çok kullanıcının verileri hem eğitim hem de test amaçlı kullanılmıştır. Bu, modelde yeni bir model oluşturmaya gerek duyulmadığı yeni kullanıcılara daha kolay uygulanabilir olmasını sağlar (Alarcao ve Fonseca, 2017).

2.5.2. Çevrimiçi ve Çevrimdışı Duygu Durum Analizi

Bazı çalışmalarda, oyun oynama, hasta izleme, uzaktan eğitim gibi konularda yerinde duygu tanıma kavramı oldukça önemlidir, bu nedenle bu uygulamalarda çevrimiçi yöntemler kullanılmalıdır. Gerçek zamanlı uygulamada kullanılması için kullanılacak yön-


temin hızı, doğruluğu ve pratikliği de göz önünde bulundurulmalıdır. Fraktal Dönüşüm ve Dalgacık Dönüşümü bunlardan biridir. Örneğin, Iacoviello *ve diğ.* (2015), dalgacık dönüşümü, kullanarak çevrimiçi uygulamalarda EEG sinyalleri için etkili ve genel bir sınıflandırma yöntemi geliştirmiştir. Sourina ve Liu (2011) müzik uyarımını takiben Fraktal Dönüşümü kullanarak beyin tepkilerini incelemişlerdir. Diğer tip duygu tanıma sistemleri çevrimdışı olarak bilinir. Çalışmaların %90'a yakını çevrimdışı çalışmadır. Sadece bir çalışmada hem çevrimiçi hem çevrimdışı duygu durum analizi sınıflandırması çalışılmıştır (Alarcao ve Fonseca, 2017; Soroush *ve diğ.*, 2017).

2.6. DUYGU DURUM VERİ KÜMESİ

Genel anlamda, duygusal uyaranlar, istenilen uyarılma düzeyleri ve değerlik durumlarını kapsayacak şekilde seçilir ve görsel, işitsel, dokunsal veya koku stimülasyonu dahil olmak üzere farklı modaliteler yoluyla sunulur. Bir uyarıcı tarafından tetiklenen duygu durumu temsilinin temel gerçeği, Uluslararası Duygusal Resim Sistemi (*ing-International Archiving Picture System (IAPS)*), Yüze Ait Duygusal Resimler (*ing-Pictures of Facial Affect (POFA)*), Çin Duyuşsal Resim Sistemi (*ing- Chinese Affective Picture System (CAPS)*), Geneva Duyuşsal Resim Veritabanı (*ing-Geneva Affective PicturE Database (GAPED)*) (Alarcao ve Fonseca, 2017), Uluslararası Duygusal Dijital Ses Sistemi (*ing-International Archiving Digital System (IADS)*), Radboud Yüz Veritabanı (*ing-Radboud Faces Database (RafD)*) (Ortman *ve diğ.*, 2013) gibi standart uyaran setleri kullanılarak veya deneklerin kendini derecelendirmesinin doğruluğunu güvence altına alıp standartlaştırmaktır. IAPS, duygusal değişiklikler ve dikkat seviyelerini tetikleyen duygusal uyaranlar için bir dizi normatif resimler sağlar. IADS, bazen IAPS ile birlikte, duyguları tetiklemek için akustik uyaranları bir bütün halinde toplar. Bu uluslararası duygusal sistemler, kültürden, cinsiyet ve yaştan bağımsız olarak düzenlenmiştir.

2.6.1. DEAP Veri Kümesi

Duygu algılamasındaki son gelişmeler, duygusal durum veritabanlarını oluşturmak için çok sayıda analisti teşvik etmiştir. Duygusal durum veritabanlarının içeriği genel olarak fizyolojik duygu verisi olanlardan bazıları DREAMER (Katsigiannis ve Naeem, 2018), SEED (Zheng ve Lu, 2015), EMOEEG (Conneau *ve diğ.*, 2017), AMIGOS (Correa *ve*



Şekil 2.14: Öz-değerlendirme Anketi (SAM) - Baştan aşağı; değerlik aktivasyon, baskınlık etiketleri

diğ., 2017), ASCERTAIN (Subramanian *ve diğ.*, 2016), MIT (Healey *ve* Picard, 2005), HUMAINE (Douglas-Cowie *ve diğ.*, 2007), MAHNOB-HCI (Soleymani *ve diğ.*, 2012) ve DEAP (Koelstra *ve diğ.*, 2012) ve eNTERFACE (Savran *ve diğ.*, 2006) datasetleridir. Ayrıca, DEAP, DREAMER, EMOEEG, AMIGOS, ASCERTAIN veri tabanları, “değerlik, aktivasyon, baskınlık, beğenme, aşinalık”, “değerlik, aktivasyon, baskınlık”, “değerlik, aktivasyon” gibi katılımcının kendini raporlayan notları içerir. Ancak, yaygın olarak kullanımı düşünüldüğünde, DEAP veri tabanı, literatürde katılımcının **Şekil 2.14:**’de de gösterildiği gibi öz değerlendirmesi açısından bir numaralandırma içermesinin yanı sıra farklı fizyolojik duygusal veriler de içermesi ile yayınlandığı tarihten günümüze farklı veritabanlarını karşılaştıran bir standart olarak kullanılabilen bir veritabanı gereksinimini karşılamıştır. Bu nedenle DEAP veri tabanı bu çalışmada tercih edilmiştir. DEAP veri kümesi içeriği **Şekil 2.15:** ve **Şekil 2.16:**’da gösterilmiştir.

DEAP veritabanında (Koelstra *ve diğ.*, 2012), deneye 19 ila 37 yaşları arasında otuz iki

Kanal-Satır Numarası	Kanal Adı	DEAP VERİ SETİ İÇERİĞİ AÇIKLAMASI (EEG sinyalleri için)
1	Fp1	• Veriler 128 Hz örnekleme frekansı ile aşağı örneklenmiştir. • EOG gürültüsü temizlenmiştir. • 4-45 Hz bant geçiren filtre uygulanmıştır. • Kanallar ortak referansa göre ortalaması alınmıştır. • 3sn video öncesi kayıtlar kaldırılarak 60sn'lik bölümlere ayrılmıştır. • Video sırası katılımcılar aynı sıraya getirilmiştir. • Veri seri,40×32×8064(video×kanal×örnek)örnekten oluşmaktadır. • Etiket olarak,40×4(değerlik, uyarılma,baskınlık ve aşinalık) değerleri aynı olarak mevcuttur.
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	

Şekil 2.15: EEG sinyalleri için Deap Veri kümesi İçeriği

kişiye, duyguları canlandırmak için 40 dakikalık duygusal videolar izletilmiştir. Her deneyin sonunda, katılımcılar her videoda gerçek duyguları hakkında bir öz değerlendirme

Kanal-Satır Numarası	Kanal Adı	DEAP VERİ SETİ İÇERİĞİ AÇIKLAMASI (Fizyolojik sinyalleri için)
33	hEOG	• Veriler 128 Hz örnekleme frekansı ile aşağı örneklenmiştir. • 3sn video öncesi kayırlar kaldırılarak 60sn'lik bölümlere ayrılmıştır. • Video sırası katılımcılar için aynı sıraya getirilmiştir.
34	vEOG	
35	zEMG	
36	tEMG	
37	GSR	
38	Solunum Kemer	
39	Pletismograf	
40	Sıcaklık	


Şekil 2.16: Diğer fizyolojik sinyaller için Deap Veri Kümesi İçeriği

anketi (SAM) doldurmuşlardır. Bu öz değerlendirme modeli, katılımcının video sonrasında dikkatini dağıtmadan, değerlendirme anketini ekranda kolaylıkla algılayıp doldurabilmesi açısından avantaja sahiptir. Literatürde Pozitif (1), Negatif(-1), Nötr (0) olarak üç grupta özdeğerlendirme alan (Zheng ve Lu, 2015) veya PANAS-X anketi gibi özdeğerlendirmede kullanılan başka özdeğerlendirme anketleri de mevcuttur (Blaiech *ve diğ.*, 2013; Wyczesany ve Ligeza , 2015).

Özgün halinde EEG kayıtları 512 Hz örnekleme frekansı ile örneklenmiştir. Sonrasında, şebeke gürültüleri ile elektrookulogram (EOG) temizlendikten sonra, 128 Hz aşağı örnekleme ile tekrar elde edilmiştir. Ön işlem aşaması yapılan verilerde katılımcıların video başlamadan önceki kayıtları video izleme sırasındaki kayıtlardan çıkarılarak, esas duygu oluşumu gösteren EEG sinyalleri değişimi bu veri kümesinde öne çıkarılmıştır. DEAP veri kümesi, sadece akademik uzantılı e-posta adresi kullanılarak ve akademik çalışma amacı ile <http://www.eecs.qmul.ac.uk/mmv/datasets/deap/> adresinden indirilebilir.

2.7. DUYGU DURUM TAHMİNİ İÇİN KULLANILAN SAYISAL YÖNTEMLER

Duygusal durumu tahmin etmek için kullanılan sayısal yöntemler, duygu durum analizi ile ilgili EEG özniteliklerine dayanarak tasarlanmıştır. Çoğu EEG analizi yöntemi, gürültüleri azaltmak için ön işlem basamağı ile birlikte kullanılır. Duygu durum tahmini için takip edilen işlem basamakları **Şekil 2.17:**'de sunulmaktadır.



Şekil 2.17: Duygu Durum Tahmini İşlem Basamakları

Genel duygusal durumu tahmini süreci için EEG sinyalleri duygusal tepkiler sırasında kaydedilir, gürültü azaltma, uzaysal ve zamansal filtreleme dahil ön işleme basamağından geçer. Spektral güç, Olay Bağlı Potansiyeller (*ing-Event Related Potentials (ERP)*) ve faz senkronizasyonu gibi duygusal durumlarla bağlantılı öznitelikler, ön işleme yapılmış EEG sinyalinden çıkar. Genellikle, bu öznitelik seçimi işlemi, maksimum duygusal tahmin doğruluk elde etmek amacıyla matematiksel yöntemler vasıtasıyla optimize edilir. Sınıflandırma basamağı, seçilmiş EEG özelliklerinden en uygun duygu durumunu tahmin eder. Sınıfın sayısı, ayrık durumlar veya değerlik, aktivasyon ve baskınlığın sürekli durumu gibi duygu durum uzayının tanımlanmasına bağlıdır.

Genellikle duygu durum analizi çalışmalarında EEG öznitelikleri zaman, frekans ve zaman-frekans domenlerinden çıkarılır. EEG'den zaman domeni özniteliklerinin sık tercih edilmemesine rağmen, çok sayıda çalışma farklı duygusal durumlar arasında değişen zaman

serilerinin özelliklerini belirlemek için öneride bulunmuştur. Zaman domeni yöntemi temel olarak EEG'nin geometrik özelliklerini analiz eder. OBP, Sinyalin İstatistiği, Hjorth Özelliği, Durağan Olmayan Indis (*ing-Non stationary Index*), YSG, beyin dalgalarının genliği, ortalaması ve varyansı bunlardan bazılarıdır (Jenke ve diğ., 2014).

Frekans alanında öznitelik çıkarımı güç spektral analizine dayanan sık kullanılan bir süreçtir ve EEG analizinde yaygın olarak kullanılmaktadır. Ve güç spektrumunun farklı frekanslarla oranı, alt bant Güç Spektral Yoğunluğu, Yüksek Dereceli Spektra (YDS) (*ing-Higher Order Spectra (HOS)*) gibi duygusal EEG'yi ayırt etmede bazı yaygın özellikler kullanılmaktadır (Jenke ve diğ., 2014; Kim ve diğ., 2013).

Zaman-frekans karakteristiği, zaman frekansı ve değişen zaman arasındaki ilişkiyi açık bir şekilde tanımlayan zaman domeni ve frekans domeninin enerji dağılımı hakkında bilgi sağlar. Hadjidimitriou ve diğ. (2012), duygusal EEG öznitelikleri için Hilbert-Huang spektrumunu (HHS) kullanmışlardır. Bunun dışında ADD de zaman-frekans domeninde duygusal EEG'de öznitelik çıkarımı için kullanılan yöntemlerdendir.

Ek olarak, Çok kanallı Kompleksite, Genlik Karesi Koherans Tahmini (GKKT) (*ing-Magnitude Square Coherence Estimation (MSCE)*), Diferansiyel Asimetri, Rasyonel Asimetri, Asimetri İndeksi, Spektral Asimetri İndeksi, Duygu Değerlik İndeksi (Wu ve diğ., 2017) gibi kanalların kombinasyonundan hesaplanan öznitelikler de duygu durum analizi çalışmalarında yer almıştır.

Ayrıca, beyin oldukça karmaşık ve doğrusal olmayan bir sistem olduğundan, doğrusal olmayan öznitelikler de duygusal EEG'leri analiz etmede dikkate alınmaktadır. Son yıllarda, entropi, korelasyon boyutu ve fraktal boyut gibi doğrusal olmayan özniteliklere daha fazla ilgi gösterilmiştir. Liu ve arkadaşları (Liu ve Sourina, 2013) EEG'lerin doğrusal olmayan özniteliklerini fraktal boyut ile çıkarıp çevrimiçi otomatik duygu tanıma sistemi önermiştir. **Tablo 2.3:** , **Tablo 2.4:**'de duygu durum analizi için DEAP veri kümesi kullanılarak yapılan çalışmalarda öznitelik çıkarma yöntemleri ve sınıflandırma başarıları özetlenmiştir (Jenke ve diğ., 2014).

Tablo 2.3: EEG'den Duygu Tanıma Çalışmalarında Öznitelikler, Verisetleri, Öznitelik Çıkarma Yöntemleri, Sınıflandırma Başarıları (2013-2015 yılları arası)

Yazar	Duygular veya Duygu Durum Etiketleri	Yöntem	Verisetleri	Sınıflandırma Başarıları
(Rozgic ve diğ., 2013)	Değerlik, Aktivasyon Baskınlık, Aşinalık	Teta, Yavaş Alfa, Alfa, Beta, Gama bandlarının Spektral Gücü ve Simetrik Kanal Çiftlerinin Spektral Güç Farkları	DEAP	Aktivasyon:%68.4 Değerlik:%76.9 Baskınlık:%73.9 Aşinalık:%75.3
(Jirayucharoensak ve diğ., 2014)	Değerlik, Aktivasyon	GSY(HFD)	DEAP	%49.52, %46.03
(Pham ve diğ., 2015)	Değerlik 2 seviye sınıf 3 seviye sınıf	GSY, AR	DEAP	%77.30-2 seviye %71.75-3 seviye
(Vaid ve diğ., 2015)	Değerlik, Aktivasyon & Mutluluk, Üzüntü Heyecan, Nefret	Çokludalgacık Dönüşümü & Ortalama, Varyans, Standart Sapma, Shannon Entropi, Hjorth Parametreleri Band Gücü	DEAP	%99.8 %98.3 %95.0 %96.4
(Vijayan ve diğ., 2015)	Değerlik, Aktivasyon & Mutluluk, Üzüntü Heyecan, Nefre	ADD-Gamma bandı AR,Çapraz Korelasyon	DEAP	%94.09

Tablo 2.4: EEG'den Duygu Tanıma Çalışmalarında Öznitelikler, Verisetleri, Öznitelik Çıkarma Yöntemleri, Sınıflandırma Başarısı (2016-2018 yılları arası)

Yazar	Duygular veya Duygu Durum Etiketleri	Yöntem	Verisetleri	Sınıflandırma Başarısı
(Zhang ve diğ., 2016)	Değerlik, Aktivasyon	Güç (HFD)	DEAP	%58.75
(Kumar ve kumar ve diğ., 2016)	Yüksek, Düşük Aktivasyon, Değerlik	Bispektral Analiz	DEAP	%64.84, Aktivasyon %61.17, Değerlik
(Atkinson ve Campos, 2016)	Değerlik, Aktivasyon	İstatistiksel Öznitelikler Farklı Frekansların Band Gücü Hjorth Parametreleri Fraktal Boyut	DEAP	%60.72 %62.4
(Zhuang ve diğ., 2017)	Değerlik, Aktivasyon	GKA & Normalize Enerji	DEAP	Değerlik: % 69.10 Aktivasyon: %71.9
(Liu ve diğ., 2017)	Değerlik, Aktivasyon	ADD, Diferansiyel Asimetri, GSY, Konnektivite Zaman domaini öznitelikleri	DEAP	Yüksek-Düşük Aktivasyon: %74.3±8.4 Değerlik: %77.2±8.6
(Tripathi ve diğ., 2017)	Değerlik, Aktivasyon	DYSA, KYSA	DEAP	DYSA: %58.44 KYSA: %66.79
(Al-Nafjan ve diğ., 2017)	Değerlik, Aktivasyon	Frontal Asimetri GSY	DEAP	%82
(Mert ve Akan, 2018)	Aktivasyon, Değerlik	CDGKA & Güç Oranı GSY, Entropi Hjorth Parametreleri Korelasyon	DEAP	%75.00±7.48 % 72.87±4.68

3. MALZEME VE YÖNTEM

3.1. LOKALİZE ZAMAN FREKANS GÖSTERİMLERİ

Bu bölümde veri bağımlı ve yeniden atama yöntemlerine dayanan zaman-frekans algoritmaları hakkında kısa bilgi verilecektir. Amaç, klasik doğrusal ve kuadratik zaman frekans algoritmalarında olan zaman frekans çözünürlüklerindeki dezavantajları gidermek için zaman frekans gösterimleri sunmak ve duygu durum analizinde bu algoritmalarından faydalanmaktır.

3.1.1. Veri Bağımlı Zaman Frekans Analizi

Veri bağımlı zaman-frekans yöntemleri, yüksek zaman-frekans yerleşmesi sağlayan gösterimler oluşturmak için önerilmiştir. Bu bölümde, son yıllardaki örneklerinden biri olan GKA'dan başlayarak, ilgili çok değişkenli uzantısının verilip, veriye dayalı zaman-frekans algoritmalarına genel bir bakış sunulacaktır.

3.1.1.1. Görgül Kip Ayrışımı

Görgül Kip ayrışımı, lineer ve durağan olmayan sinyaller için yüksek zaman-frekans yerleşmesi elde eden tamamen veri bağımlı bir yöntemdir. Böylece mevcut sinyal, genlik ve frekans moduleli bileşenlerinin sonlu bir seti haline dönüştürülür. Bir sinyalin ÖKF olarak kabul edilmesi için iki şart gereklidir.

- 1) Ekstremum sayısı ve sıfır geçiş sayısı en fazla bir farklı olmalıdır.
- 2) Sırasıyla yerel maksimum ve yerel minimumları bağlayan zarfların ortalaması yaklaşık sıfırdır.

Bu nedenle, Fourier tekniklerine kıyasla GKA'ya avantaj sağlayan bir özellik olarak, her ÖKF dataya özel farklı bir zaman ölçeği yansıtan dar bantlı bir sinyal olarak kabul edilebilir (Huang ve diğ., 1998). GKA yönteminin ayrıntıları Algoritma 1'de verilmiştir.

Algoritma 1: Standart GKA algoritması

- $v(t)$ orijinal sinyal olmak üzere $\bar{v}(t) = v(t)$ olsun.
- $\bar{v}(t)$ 'nin lokal maksimumu ve lokal minimumu bulunur.
- Bütün lokal minimumların enterpolasyonu yapan $e_l(t)$ olarak daha düşük bir alt 'zarf' bulunur.
- Bütün lokal maksimumların enterpolasyonu yapan $e_u(t)$ olarak daha yüksek bir üst 'zarf' bulunur.
- Lokal ortalama hesaplanır, $\bar{m}(t) = (e_l(t) + e_u(t))/2$
- $\bar{v}(t)$ den lokal ortalama çıkartılır, $c_i(t) = \bar{v}(t) - \bar{m}(t)$ (i, ÖKF 'nin sırası olmak üzere)
- $\bar{v}(t) = c_i(t)$ olarak atanır, $c_i(t)$ bir ÖKF olana kadar ikinci basamağa geçilir.

GKA algoritmasının akış şeması **Şekil 3.1:**'de sunulmuştur.

İlk ÖKF orijinal veriden çıkarılır, $r(t) = v(t) - c_1(t)$ ve prosedür, artık daha fazla osilasyon içermeyene kadar veya sabit olana kadar tekrarlı olarak uygulanır. Bu 'eleme işlemi' olarak adlandırılan süreç, tanımlanmış durma kriteri (*ing-stopping criterion*) ile uygun bir şekilde kontrol edilir. Sinyal $v(t)$;


$$v(t) = \sum_{i=1}^M c_i(t) + r(t) \quad (3.1)$$

Burada, $c_i(t), i = 1, \dots, M$ olmak üzere ÖKF'lerdir ve $r(t)$ geriye kalan artıktır. ÖKF'lerin dar bantlı yapısı, lokalize zaman frekans spektrogramı elde etmek amacıyla uygulanabilecek Hilbert Dönüşümü için uygundur.

$$H(c_i(t)) = \frac{1}{\Pi} P \int_{-\infty}^{+\infty} \frac{(c_i(t'))}{(t-t')} dt' \quad (3.2)$$

Burada P sembolü, Cauchy ana değeri (*ing-the Cauchy Principal Value*) 'ni gösterir ve analitik sinyal ise;

$$V(t) = \sum_{i=1}^M (c_i(t) + jH(c_i(t))) = \sum_{i=1}^M a_i(t) e^{jQ_i(t)} \quad (3.3)$$



Şekil 3.1: GKA algoritmasının akış şeması. (orijinal veri x , r = artık, i = ayırıştırma yineleme.)

olarak elde edilir ve genlik ve faz fonksiyonları sırasıyla $a_i(t)$ ve $Q_i(t)$ olarak tanımlanır. Faz fonksiyonu $Q_i(t)$, anlık frekansı elde etmek amacıyla türevi alınarak kullanılır,

$$w_i(t) = dQ_i(t)/dt \quad (3.4)$$

Zaman t ve anlık frekans $w_i(t)$ ye karşı genliğin grafiği , daha açık bir şekilde, zaman frekans ekseninde genlik eğrisinin belirlenmesi Hilbert-Huang Dönüşümü (HHD)

olarak adlandırılır. $H(w, t)$, doğrusal ve durağan bir sinyalin zaman frekans spektrogramını temsil eder.

3.1.1.2. Çok Değişkenli Görgül Kip Ayrışımı

Çok değişkenli GKA (ÇDGKA), Rehman ve Mandic (2010) 'in geliştirdiği standard GKA, iki değişkenli ve üç değişkenli GKA'nın uzantısıdır. Standard GKA, aşağı ve yukarı zarfların ortalamasını kullanarak lokal ortalamayı hesaplar. Ancak, n boyutlu bir sinyalin lokal ortalaması direk hesaplanamaz ve sinyali, değişken uzaylarda, farklı yönler boyunca yansıtarak çok boyutlu zarflar üretilir, daha sonra lokal ortalamayı elde etmek için bu yansımaların ortalaması alınır. Çok değişkenli sinyalin girişini yansıtmak için kullanılan yön vektörleri kümesi için, Düşük Tutarsızlık Hammersly dizileri (*ing-Low Discrepancy Hammersley Sequences*) yüksek boyutlu küreler üzerinde yarı uniform noktalar edilebilmesi amacıyla kullanılmıştır (Rehman ve Mandic, 2010).

Bununla birlikte, n boyutlu boyutlu uzayda belirlenen bir sinyalin projeksiyonunu gerçekleştirmek için uygun bir yön vektörleri düzenlemesi de dikkat gerektirmektedir. Bir n -boyutlu uzayda çok sayıda yön boyunca lokal ortalama tahmini, tüm zarfların integralinin bir hesabı olarak görülebilir ve hesaplamanın hassaslığı, özellikle sınırlı bir miktar için, yön vektörlerinin tutarlı olarak seçilmesine bağlıdır. N -boyutlu uzaylardaki yön vektörleri, ilgili birim küreler üzerindeki noktalar olarak aynı şekilde sembolize edilebildiğinden, yön vektörlerinin uygun bir düzenlemesinin seçilmesi konusu, n küre üzerinde tekdüze bir örnekleme şemasının bulunması olarak ele alınabilir. N küre üzerinde yön vektörlerinin uygun bir düzenlemesi elde edildiğinde, sinyalin yansımaları o düzenleme boyunca belirlenir. Yansıtılan sinyallerin uç noktaları, sinyalin talep edilen çok boyutlu zarflarını sağlamak için enterpolasyonu hesaplar. **Şekil 3.2:**'de örnekleme yönerge-leri gösterilmektedir.


ÇDGKA'nın ayrıntıları Algoritma'da özetlenmiştir.

Algoritma 2: Çok değişkenli GKA algoritması

- $(n-1)$ küresi üzerinde örnekleme için uygun bir nokta seçilir.
- Bütün k 'lar için (Yön vektörlerinin bütün kümeleri), yasıma kümesi olarak $p^{(Q_k)}(t)_{k=1}^K$ yı verecek şekilde, yön vektörü $x^{(Q_k)}$ boyunca giriş sinyali $v(t)_{t=1}^T$ 'nin $p^{(Q_k)}(t)_{t=1}^T$

ile gösterilen yansıması hesaplanır.

- $p^{(Q_k)}(t)_{k=1}^K$ yansıyan sinyallerin maksimumuna karşılık gelen $t_j^{Q_k}$ zaman sabiti bulunur.
- Çok değişkenli zarf eğrileri $e^{(Q_k)}(t)_{k=1}^K$ elde etmek için $[t_j^{Q_k}, v(t_j^{Q_k})]$ kullanılarak enterpolasyon yapılır.
- K yön vektörleri kümesi için, zarf eğrilerinin ortalaması $m(t) = \frac{1}{K} \sum_{k=1}^K e^{(Q_k)}(t)$ olarak hesaplanır.
- ‘i’ ÖKF nin bir sırası olmak üzere ‘detay’ $c_i(t), c_i(t) = v(t) - m(t)$ kullanılarak çıkartılır. Eğer ‘detay’ $c_i(t)$, çok değişkenli bir ÖKF için durma kriterini sağlarsa, yukarıdaki prosedür $v(t) - c_i(t)$ ye uygulanır, sağlamaz ise $c_i(t)$ ye uygulanır.



Şekil 3.2: Örnekleme Yönergeleri

- a) Örnekleme yönergeleri - Tek tip açısız örneklemeye dayalı iki değişkenli GKA'yi temsil eden projeksiyon seti (Q)
- b) Örnekleme yönergeleri - Projeksiyon seti (Q) - düşük aykırılıklı Hammersley dizisine dayalı çok değişkenli GKA'yi temsil eder.


GKA, her bir EEG kanalına ayrı ayrı çalıştırıldığında, teklik problemi (*ing-uniqueness problem*) olarak adlandırılan EEG sinyalleri ve gürültünün rasgele yapısı nedeni ile farklı EEG kanallarından elde edilen ÖKF lerin farklı sayıda ve farklı istatistiksel özellikte olması durumu ortaya çıkarak, benzer istatistiğe sahip sinyallerden elde edilen farklı ayrıştırmalara göre yansıtılır ve mod karıştırma (*ing-mod mixing*) olayı, tek değişkenli GKA'da farklı ÖKF'ler karşısında benzer frekanslarda ortaya çıkar. GKA'nin çok değişkenli uzantıları, her kanalın tekli GKA ile işlenmesi üzerine çok kanallı sinyalleri daha pratik ve

rahat bir şekilde işleme avantajına sahiptir. ÇDGKA'ında EEG kanallarının ilk ÖKF'leri benzer frekans dalgalanmalarına, bant genişliklerine veya otokorelasyon özelliklerine sahiptir. Ancak, yine de ÇDGKA da bir miktar mod karıştırma hassasiyeti göstermektedir (Rehman ve Mandic, 2010; Rehman *ve diğ.*, 2013).

Mod Karıştırma ve Örtüşme

Temel fonksiyonlar arasında mod karıştırma, esasen farklı modların sinyallerini taşıyan tek bir ÖKF ya da birden fazla ÖKF'de bulunan tek bir mod ile ortaya çıkmaktadır (Rehman ve Mandic, 2011; Wu ve Huang *ve diğ.*, 2009). Bu durum zaman frekans domeninde ÖKF spektrumunun kesişmesine (*ing-overlapping*) ve örtüşmesine (*ing-aliasing*) neden olan sinyal aralıklılığının bir sonucudur. Örtüşmenin sebepleri de ; ekstremum örnekleme, GKA filtrelemesinde önemli bir adım olan Alt-Nyquist örnekleme ve ideal bir alçak geçiren filtreden uzak olan GKA'nin eşdeğer enterpolasyon filtresi (örneğin bir kübik spline), daha fazla örtüşme oluşturmaktadır GKA filtreleme sürecinin önemli bir şekilde sinyal en uç noktaları (ekstremumları) örneklemesine bağlı olduğunu vurgulamak önemlidir ve bu nedenle, bir girdi de yeterli miktarda ekstremumun bulunması GKA'nin başlatılması ve başarılı bir şekilde çalıştırılması için bir ön şarttır. Standart bir GKA, bir dirak darbesi (*ing-dirac pulse*) üzerinde çalışmakta başarısızdır, çünkü anlamlı bir GKA için yeterli ekstremum yoktur. GKA filtresinden eşdeğer bir gürültü yanıtı elde etmek için Flandrin *ve diğ.* (2005), gürültü darbesinin sınırını idealleştirilmiş dirak darbesi olarak düşünüp GKA'yı çalıştırmışlardır. Dirak darbesine gürültü ilavesi, GKA filtreleme sürecini başlatmaya ve onun eşdeğer dürtü tepkisini elde etmeye yardımcı olan sinyal için ek olarak ekstremum getirir. Sinyalin içine gürültü takımı ekleme fikri, Topluluk Görgül Kip Ayrıştırma (TGKA) (*ing-Ensemble Empricial Mode Decompositon*) algortimasının temelini oluşturur (Wu ve Huang *ve diğ.*, 2009). TGKA, verilere çok sayıda bağımsız gürültü ekleyerek çalışır ve sonuçtaki topluluğun her üyesine GKA uygular. Bunu yaparken TGKA beyaz gauss gürültüsüne (BGG) (*ing-White Gasusian Noise*) uygulandığında GKA'nin çift kutuplu filtre bankası özelliğini kullanır. TGKA, mod-karıştırma olmaksızın analize ek olarak, datanın doğasında mevcut daha yerleşmiş modları ortaya çıkarır. Ancak, doğrudan verilere gürültü eklenmesi sonucunda kalıntı gürültünün (*ing-residual noise*) etkilerinin ÖKF'lerde kalması muhtemeldir. Bu kalıntıların genliği (gücü), kalan sinyalin bütünlüğünü riske atarak, takım büyüklüğü (*ing ensemble size*) ortalaması alı-


nan gerçekleştirmelerin sayısına bağlıdır. Bu sorunun üstesinden gelmek için TGKA'de birkaç iyileştirme adımı önerilmiştir. Torres *ve diğ.* (2011) yaklaşımlarında tek bir kalıntıyı hesaplamak için her analiz aşamasında dikkatlice seçilen gürültüler eklemişlerdir. Tamamlayıcı Topluluk Görgül Kip Ayrımı (TTGKA) (*ing-Complete Ensemble Empirical Mode Decomposition*), eklenen gürültünün pozitif ve negatif bölümlerinden elde edilen tamamlayıcı topluluk ÖKF çiftleri vasıtasıyla BGG'den kaynaklanan kalıntıyı ortadan kaldırır (Yeh *ve diğ.*, 2010). Sinyal yerine BGG kullanılması durumunda ÇDGKA'nın filtre bankası özelliği GKA göre oldukça iyi olduğu tespit edilmiştir (Rehman *ve diğ.*, 2013; Wu ve Huang *ve diğ.*, 2009; Flandrin *ve diğ.*, 2005). Ayrıca, ÇDGKA'nın modlarını bir girdi verisinden ortak bir salınım hizalandığı gösterilmiştir. **Şekil 3.3:** ve **Şekil 3.4:**'de GKA ve ÇDGKA'nı bir filtre bankası olarak kullanırken her ÖKF için tanımlanmış anlık frekansların gösteriminde mod hizalama ve mod karışımı çözümleri açık bir şekilde görülmektedir.



Şekil 3.3: GKA'yi bir filtre bankası olarak kullanırken her ÖKF için mod karıştırma sorunu gösterimi

ÇDGKA içindeki mod uyumundan yararlanarak, gürültü destekli ÇDGKA standart GKA'daki

mod karıştırma işlemini azaltmak için kullanılabilir. Nitekim, gürültü kanalları vasıtasıyla girdi verisi üzerine yarı-diyadik filtre bankı yapısını üzerine uygulayarak, farklı ÖKF'lerden gelen spektrumların frekans domeninde daha lokalize olması ve böylece mod karıştırma probleminin azaltılması beklenmektedir.



Şekil 3.4: ÇDGKA'yi bir filtre bankası olarak kullanırken her ÖKF için iyi tanımlanmış anlık frekansların gösterimi

3.1.1.3. Gürültü Destekli Çok Değişkenli Görgül Kip Ayrışımı

Gürültü Destekli Çok Değişkenli Görgül Kip Ayrışımı (GD-ÇDGKA), bir veya daha fazla girişli veri kanalı ve ayrı kanallardaki BGG'nin bitişik bağımsız gerçeklemeleri içeren çok değişkenli bir sinyal oluşturarak çalışır. Veri ve gürültü kanallarını kapsayarak oluşan çok değişkenli sinyal, ÇDGKA metodu kullanılarak işlenir ve orijinal verilere karşılık gelen ÖKF'ler, istenilen dekompozisyonu elde etmek için tekrar oluşturulur (Rehman ve diğ., 2013). Bu şekilde, TGKA'nin aksine, GD-ÇDGKA içindeki fiziksel olarak ayrı giriş ve gürültü alt uzayları, doğrudan gürültü artefaktlarını önler. Çok değişkenli bir ÖKF için eleme işlemi, bütün yansıtılmış sinyaller standart GKA'de kabul edilen herhangi bir durma kriterini yerine getirdiğinde durdurulabilir. ÇDGKA algoritması, çok boyutlu sin-

yale BGG eklenerek uygulandığında, GKA ile karşılaştırıldığında aynı frekans aralığı boyunca farklı kanallara karşılık gelen ÖKF lerde büyük ölçüde geliştirilmiş sıralanma göstererek, her bir kanal üzerinde çift kutuplu filtre seti (*ing-dyadic filter bank*) görevi görmektedir. ÇDGKA'nın bu özelliğini kullanarak, Rehman ve Mandic mod karıştırma problemini daha da iyileştirmek için GD-ÇDGKA yöntemini önermişlerdir. Bu durum, çok değişkenli bağımsız BGG içeren bir alt uzay dahil edilip boyut arttırılarak sağlanır ve elde edilen kompozit sinyal ÇDGKA kullanılarak işlenir. Bu şekilde, gürültü farklı bir alt uzayda kalacağı ve filtre bankası yapısını yükseltmekte kullanılarak, faydalı veri kanalları ile asla karıştırılmaz ve böylece mod karıştırma sorununu azaltılır ve datalara özgü frekans bantlarının daha iyi tanımı sağlanır. Yalnızca orijinal giriş sinyaline karşılık gelen ÖKF'ler, gürültüye bağlı ÖKF altuzayı çıkarılarak muhafaza edilir. Gürültü altuzayı nedeniyle, ÖKF'lerin hizalanması, çift kutuplu filtre seti yapısına uyar ve aynı ayrıştırma seviyesinde aynı bilgiye sahip olarak, böylece biyomedikal sinyallerden dar bantlı olup duran olmayan analizler için önemli bir araç sunup, orijinal giriş sinyali ile alakalı ÖKF'lerin hizalanmasını sağlar. TGKA ve GD-ÇDGKA arasındaki farklara bakılmaksızın, her iki yöntemin arkasındaki ana gerekçe, standart GKA'nın iyileştirilmiş performansı için sinyale BGG ekleyerek, (ÇD)GKA'nın çift kutuplu filtre bankı yapısının kullanılmasını sağlamaktadır. GD-ÇDGKA yönteminin ayrıntıları Algortima 3'de verilmiştir.

Algoritma 3: Gürültü destekli ÇDGKA


- Giriş ile aynı uzunlukta (b kanal), bir ilintisiz beyaz gauss gürültüsü zaman serisi oluşturun.
- Basamak 1 de elde edilen gürültü kanallarını (b kanal) , giriş çok değişkenli sinyali (a kanal) ekleyip, (a+b) kanallık bir sinyal elde edilir.
- Algoritma 2 de özetlenen ÇDGKA algoritması kullanılarak ortaya çıkan (a+b) kanallık çok değişkenli sinyal işlenir.
- Sonuçtan elde edilen (a+b) değişkenli ÖKF den, gürültüye karşılık gelen b kanal çıkartılır, orijinal sinyale karşılık gelen a kanal ÖKF'ler kümesi geriye kalır.

GD-ÇDGKA algoritmasının davranışı, eklenen gürültü kanallarının güç seviyesine göre değişir. Algoritma 3, sonsuz küçük küçük gürültü genlikleri için standart GKA 'ye ben-

zer şekilde performans gösterir. Gürültünün gücünün artırılması, girdi verileri üzerindeki yarı-diyadik filtre bankı yapısını daha da güçlendirecektir ancak aşırı gürültü seviyeleri, (ÇD)GKA tabanlı algoritmaların veri bağımlı kabiliyetini riske atar. Temel bir kural, girdinin varyansının % 2-10' unda gürültünün varyansını (güç) seçmektir. Gücün bu aralığın üstündeki gürültü, çıkışta gereksiz bir mod karıştırma sorunu ile sonuçlanabilir.

3.1.1.4. Görgül Dalgacık Dönüşümü

Görgül Dalgacık Dönüşümü (GDD) prosedürü, sinyalin spektrumunu bölümlendiren ve ampirik dalgacıklar geliştiren ve sinyalin her bir bölümünü işlemek için yürüten iki kritik aşamadan oluşur. Spektrumun yerel maksimumu, sinyalin parçalara ayrılması için ilk olarak hesaplanır ve daha sonra azalan düzende düzenlenmesi yapılır. En yüksek lokal maksimum bir pik dizisi oluşturmak için düzenlenmiştir. Daha sonra iki ardışık maxima arasındaki en düşük lokal minima bulunur ve tüm parçaların sınırları olarak tespit edilir. $0 \sim \Pi$ aralığında sıkıştırılmış spectrum N bitişik parçalara ayrılmıştır. Bütün parçaların sınırları ω_n (burada $\omega_0 = 0$ ve $\omega_N = \Pi$) ile gösterilir. Yani her parça, $\Lambda_n = [\omega_n - 1, \omega_n]$ olarak tanımlanmıştır. Özetle, $\bigcup_{n=1}^N \Lambda_n = [0, \Pi]$ olduğu gösterilmiştir. Genişliği $2\tau_n$ olan geçiş fazı aşağıda eşitlik 3.5 ve 3.6'da tanımlanmıştır. GDD işleminin akış şeması **Şekil 3.5:**'de gösterilmiştir (Gilles ve diğ., 2013).



Şekil 3.5: GDD yönteminin akış şeması

$$\Phi_n(\omega) = \begin{cases} 1 & \text{eğer } |\omega| \leq \omega_n - \tau_n \\ \cos\left[\frac{\Pi}{2} v\left(\frac{1}{2\tau_n}(|\omega| - \omega_n + \tau_n)\right)\right] & \text{eğer } \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ 0 & \text{diğer durumlar} \end{cases} \quad (3.5)$$

$$\Psi_n(\omega) = \begin{cases} 1 & \text{eğer } \omega_n + \tau_n \leq |\omega| \leq \omega_{n+1} - \tau_{n+1} \\ \cos\left[\frac{\Pi}{2} v\left(\frac{1}{2\tau_{n+1}}(|\omega| - \omega_{n+1} + \tau_{n+1})\right)\right] & \text{eğer } \omega_n + \tau_{n+1} \leq |\omega| \leq \omega_{n+1} + \tau_{n+1} \\ \sin\left[\frac{\Pi}{2} v\left(\frac{1}{2\tau_n}(|\omega| - \omega_n + \tau_n)\right)\right] & \text{eğer } \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ 0 & \text{diğer durumlar} \end{cases} \quad (3.6)$$

Uygun bir seçilmiş parametre τ_n GDD'nin iyi bir kapsama sahip olmasını sağlar, $v(x)$ Meyer dalgacının yardımcı işlevidir. Standart örneği aşağıda açıklanmıştır:

$$W_f^{\varepsilon}(0, t) = \langle \phi_1 \rangle = \int f(\tau) \overline{\phi_1(\tau - t)} d\tau \quad (3.7)$$

Detay katsayıları sinyalin iç çarpımıdır. (*ing-inner product*) ve bu yüzden ampirik dalgacıklar:

$$W_f^{\varepsilon}(n, t) = \langle \Psi_1 \rangle = \int f(\tau) \overline{\Psi_1(\tau - t)} d\tau \quad (3.8)$$

Daha sonra sinyalden ayrılmış ampirik modlar şu şekilde sunulur:

$$f_0(t) = W_f^{\varepsilon}(0, t) * \phi_1(t) \quad (3.9)$$

$$f_k(t) = W_f^e(n, t) * \Psi_1(t) \quad (3.10)$$

3.1.2. YENİDEN ATAMA YÖNTEMLERİ

Yeniden atama yöntemleri (YAY), geleneksel zaman-frekans algoritmalarının zaman-frekans gösterimini netleştirmeye çalışır. Genellikle iki şekilde kullanımı vardır. İlk olarak, zaman-frekans dağılımlarının okunabilirliğini arttırmayı (araştırma amaçlı sinyal analizi) amaçlanan bir işlem-sonrası (*ing-post-processing*) tekniği olarak görülebilir. İkincisi ise, karar şemalarının bir kısmı (sinyal işleme) olabilmesi amacı ile, faydalı zaman-frekans bilgisini kodlamanın bir şekli olarak kullanılabilir. Yeniden atama yöntemi özellikle, klasik zaman frekans yöntemindeki dezavantajları iyileştirmeye odaklanır. Örnek olarak, genlik yayılması KZFD dahil klasik lineer zaman-frekans yöntemlerinin dezavantajıdır ve genellikle zaman frekans gösterimini üretirken faz bilgisini gözardı etmekten kaynaklanır. Bu nedenle, KZFD'nün faz bilgisi kullanımını açık veya kapalı bir şekilde dahil ederek zaman frekans eksenini okunabilirliğini geliştirmeye yönelik çalışmalar yapılmıştır. Faz bilgisi yerine uygun analiz pencereleriyle KZFD'nun kombinasyonunu kullanan YAY olarak alternatif bir yaklaşım geliştirilmiştir. YAY, zamansal lokalizasyonu koruyarak, enerji dağılımının merkezine yerel enerjiyi atayıp, zaman frekans gösterimini netleştiren işlem-sonrası bir teknik olup ve çok değişkenli sinyallere iyi adapte edilebilir özelliktedir (Auger ve diğ., 2013). Klasik Zaman-frekans gösterimlerinde gözlemlenen lokalizasyon ve parazit dengelemesinin üstesinden gelebilir.

3.1.2.1. Senkrosıkıştırma Dönüşümü

Senkrosıkıştırma dönüşümü (SSD), durağan olmayan sinyallerin kompakt bir zaman-frekans temsili oluşturacak şekilde sürekli dalgacık dönüşümüne uygulanan bir işlem sonrası tekniğidir. SSD başlangıçta ses sinyali ayrışması açısından sunulmuştur. SSD, dalgacıklar olarak bilinen zaman-frekans filtrelerinin ilerlemesi sayesinde, ilgilenilen salınım unsurlarını tanıyan bir projeksiyon tabanlı algoritma olmasına rağmen, SSD zamanla değişen salınıma sahip olan bir sinyali bileşenlerine ayrıştırmayı amaçlamaktadır (Daubechies ve diğ., 2011). GKA benzeri bir yaklaşım olan SSD metodu, SSD ve yeniden atama yönteminin bir karışımı olmasının yanında, literatürde S-Dönüşümü (Hu-

ang ve diğ., 2016), KZFD (Oberlin ve diğ., 2014), Multitaper Dönüşümü (Daubechies ve diğ., 2016) kullanılarak da farklı yöntemler ile çalışmalar yapılmıştır. (Daubechies ve diğ., 2011) tarafından sunulan SSD'nin amacı sinyalleri bileşenlerine ayırmak (zamanla değişen salınım özellikleri) ve KZFD, SDD veya benzer zaman-frekans yaklaşımlarının (Huang ve diğ., 2016; Daubechies ve diğ., 2016) enerjilerini yeniden atamaktır. Böylece, katsayıların sonraki enerjileri, modüle edilmiş salınımların anlık frekans eğrileri etrafında yoğunlaşır. Zaman-frekans gösterimindeki frekans yeniden atama adımı, zaman-frekans uzayı için sinyal bileşenlerinde önemli bir lokalizasyon sağlar. SSD algoritmasının akış şeması aşağıdaki **Şekil 3.6:**'deki gibi sunulur:

Sinyaller zaman frekansı uyumlu bileşenlerin aşağıdaki gibi genişletilmesi olarak hesaplanır:

$$s(t) = \sum_{k=1}^{K=1} A_k(t) \cos(Q_k(t)) + \eta(t) \quad (3.11)$$


Bir sinyalin Sürekli Dalgacık Dönüşümü $s(t)$;

$$W_s(a, b) = \int a^{-1/2} \psi^*\left(\frac{t-b}{a}\right) s(t) dt \quad (3.12)$$

Burada ψ^* ana dalgacıklarının karmaşık konjügesidir ve b , " a " ile ölçeklendirilen ana dalgacıklarına yapılan zaman kaymasıdır. SDD, $s(t)$ sinyalinin, orijinal ana dalgacıkların biçimlerinin ve çözülen çok sayıda dalgacık ile çapraz korelasyonudur. $W_s(a, b)$ işaretleri, anlık frekansları çıkarmak için kullanılan bir kompakt zaman frekansı temsilini sunan katsayılarıdır. Buradaki amaç SDD'de oluşan lekelenme etkisini azaltmaktır. Bu lekelenme temelde " a " ölçeğinde mevcuttur, çünkü sabit zaman kayması " b " için eğer zaman eksenini boyunca lekelenme göz ardı edilirse, o zaman anlık frekans $w_s(a, b)$ SDD'nin türevi olarak hesaplanabilir. " w "(a, b) $\neq 0$ için " b " ile ilgili herhangi bir noktada (a, b).

$$w_s(a, b) = \frac{-j}{2\pi W_s(a, b)} \frac{\partial W_s(a, b)}{\partial b} \quad (3.13)$$

Zaman frekans temsilindeki son basamak, bilgiyi zaman ölçeği alanından zaman frekans alanına göre tasarlamaktır. Her bir nokta $(b, a), (b, w_s(a, b))$ 'ye değiştirilir ve bu işlem, Senkrosıkıştırma olarak bilinir. " a " ve " b " nin ayrık değerler olmalarından dolayı, öl-



Şekil 3.6: Senkrosıkıştırma Dönüşümü (SSD) Algoritmasının Akış Şeması

çeklendirme adımı, $\Delta a_k = a_{(k-1)} - a_k$, $W_s(a, b)$ 'nin hesaplanabildiği herhangi bir a_k için bulunur. Benzer şekilde, zaman ölçeği alanından zaman frekans alanına $(b, a) \rightarrow (b, w_s(a, b))$ tasarlanırken, SSD katsayısı $T_s(a, b)$, sadece, $\Delta\omega = \omega_l - \omega_{l-1}$ ile $[\omega_l - \Delta\omega/2, \omega_l + \Delta\omega/2]$ frekans aralığı ile ω_l merkezlerde çözümlenir. Buna göre senkrosıkıştırma katsayısı Eşitlik 3.14 de verilmiştir.

$$T(\omega_l, b) = \sum_{a_k | \omega_s(a_k, b) - \omega_l | \Delta\omega/2} W(a_k, b) a^{-3/2} \Delta a_k \quad (3.14)$$

Yukarıdaki koşul, $s(t)$ sinyaline ait zaman frekansı sunumunun sadece frekans alanı boyunca senkronize edildiğini göstermektedir. SSD, SDD katsayılarını, zaman frekansı alanı üzerinden, anlık frekansların daha sonra çıkarıldığı kompakt bir gösterim elde etmek üzere yeniden atar.

3.1.2.2. *Senkrosıkıştırma Dönüşümü Kullanarak Çok Değişkenli Zaman Frekans Analizi*

Son yıllarda, çok kanallı verilerin zaman frekans analizine olan talep çoklu kanal bağımlılıklarının doğrudan kullanan çok değişkenli veriye bağımlı algoritmaların önerilmesiyle artış göstermiştir. Bu amaçla, literatürde önerilen bir zaman-frekans bölümlleme algortimasının çok değişkenli uzantısını kullanarak, senkrosıkıştırma dönüşümünün çok değişkenli uzantısı önerilmiştir. Önerilen algoritma, çok değişkenli anlık frekans kavramından faydalanan çok kanallı sinyallerin bir ortak/ çok değişkenli zaman frekans temsili oluşturmak için kullanılıp, çok değişkenli zaman-frekans algoritmasının performansı duygu durum analizinde EEG sinyalleri üzerinde değerlendirilmiştir (Ahrabian , 2014).

Son yıllarda, tek değişkenli modüleli osilasyon kavramı çok kanallı sinyallerin ortak osilasyon yapısını modellemek amacıyla çok değişkenli uygulamalara doğru kaymıştır. Hem genlik hem de fazın bir fonksiyonu olan bir sinyali ele aldığımızda, $a(t)$ ve $\Phi(t)$ sırasıyla sinyalin anlık genlik ve fazını göstermek üzere, sinyal aşağıdaki gibi modellenir:

$$x(t) = a(t)\cos\Phi(t) \quad (3.15)$$

Bununla birlikte, zamanla değişen sinyale özelliğindeki bir çok sinyalin zamanla değişen anlık genlik ve fazlara sahip olduğu varsayılarak daha iyi modellenebildiği belirtilmelidir. Bu amaçla, analitik sinyal olarak bilinen $x_+(t)$ 'nin kompleks bir gösterimini elde etmek için sinyal $x(t)$ 'ye Hilbert Dönüşümü uygulanır. Buna göre;

$$x_+(t) = a(t)e^{j\Phi(t)} = x(t) + i\hat{h}x(t) \quad (3.16)$$

Burada, $\hat{h}(t)$ Hilbert Dönüşümü operatörü, ve $i = \sqrt{-1}$ dir. Analitik sinyal $x_+(t)$ 'nin gösterimini çok değişkenli bir sinyal için genişlemek amacı ile her zaman anında t vektörü,

çok değişkenli analitik bir sinyal vermek üzere yapılandırılmıştır. Buna göre;

$$x_+(t) = \begin{vmatrix} a_1(t)e^{j\Phi_1(t)} \\ a_2(t)e^{j\Phi_2(t)} \\ a_3(t)e^{j\Phi_3(t)} \\ . \\ . \\ . \\ a_{N_c}(t)e^{j\Phi_{N_c}(t)} \end{vmatrix} \quad (3.17)$$

Burada, $a_{N_c}(t)$ ve $\Phi_{N_c}(t)$ her bir kanal için anlık genlik ve fazı temsil etmektedir. Çok değişkenli bir sinyal için ise tüm kanalların anlık frekanslarının güç ağırlıklı ortalaması olarak tanımlanan ortak anlık frekans;

$$\omega_x(t) = \frac{\Im(x_+^H(t) \frac{d}{dt} x_+(t))}{||x_+(t)||^2} = \frac{\sum_{n_c=1}^{N_c} a_{n_c}^2(t) \Phi_{n_c}^I(t)}{\sum_{n_c=1}^{N_c} a_{n_c}^2(t)} \quad (3.18)$$

Burada, "ℑ" kompleks sinyalin imajiner parçasını " $\Phi_{n_c}^B(t)$ " ise her kanalın anlık frekansını göstermektedir.

Ortak /Çok Değişkenli anlık frekans, çok değişkenli sinyallerin birleşik salınımlı hareketini yakalarken, ortak anlık bant genişliği $v_x(t)$, her kanaldaki çok değişkenli salınımların sapmalarını ortak anlık frekanstan yakalar. Böylece $v_x(t)$;

$$v_x(t) = \frac{||\frac{d}{dt} x_+(t) - i\omega_x(t)x_+(t)||}{||x_+(t)||} \quad (3.19)$$

Bu nedenle, ortak anlık band genişliği, çok değişkenli analitik sinyalin değişim hızına göre, anlık anlık frekans tahmininin normalleştirilmiş hatasını temsil eder. Buna göre, 4.1 eşitliğini 4.3 eşitliğine eklersek, anlık bandgenişliğinin karesi ifadesi ile sonuçlanır.

$$v_x(t)^2 = \frac{\sum_{n_c=1}^{N_c} a_{n_c}^I(t) + \sum_{n_c=1}^{N_c} a_{n_c}^2(t) (\Phi_{n_c}^I(t) - \omega_x(t))^2}{\sum_{n_c=1}^{N_c} a_{n_c}^2(t)} \quad (3.20)$$

Ortak analitik spektrumun global momentleri ortak ani frekans ve bant genişliği cinsinden

ifade edilir. Birinci ve ikinci global momentlerde ortak ortalama frekans ve ortak küresel ikinci merkezi momentler (çok değişkenli bant genişliği karesi) adı verilir. Sonuç olarak, ortak analitik spektrum göz önüne alındığında;

$$S_x(\omega) = \frac{1}{E_x} \|X_+(\omega)\|^2 \quad (3.21)$$

Burada, " $X_+(\omega)$ " " $x_+(t)$ " nin Fourier Dönüşümüdür. E_x ise Fourier katsayılarının toplam enerjisidir. Buna göre;

$$E_x = \frac{1}{2\Pi} \int_0^{\infty} \|X_+(\omega)\|^2 \quad (3.22)$$

Bu, ortak analitik spektrumun ilk anı olarak ifade edilen ortak global ortalama frekansı şu şekilde ifade etmeyi mümkün kılar:

$$\bar{\omega}_x = \frac{1}{2\Pi} \int_0^{\infty} \omega S_x(\omega) d\omega \quad (3.23)$$

Ortak global ikinci merkezi moment (çok değişkenli bant genişliği kare), ortak küresel ortalama frekanstan ortak analitik spektrumun spektral sapmasını ölçer ve aşağıdaki gibi sunulur:

$$\bar{\sigma}_2^x = \frac{1}{2\Pi} \int_0^{\infty} (\omega - \bar{\omega}_x)^2 S_x(\omega) d\omega \quad (3.24)$$

Buna göre, analitik spektrumun global momentleri, ortak anlık frekans ve bant genişliği momentleri ile aşağıdaki gibi ilişkili olabilir.

$$\bar{\omega}_x^2 = \frac{1}{E_x} \int_{-\infty}^{\infty} \|x_+(t)\|^2 \omega_x t dt \quad (3.25)$$

$$\bar{\sigma}_2^x = \frac{1}{E_x} \int_{-\infty}^{\infty} \|x_+(t)\|^2 \sigma_2^x(t) dt, \quad (3.26)$$

Burada, $\sigma_2^x(t)$ ortak anlık ikinci merkezi momenttir. Buna göre;


$$\sigma_2^x(t) = v_x^2(t) + (\omega_x(t) - \bar{\omega}_x)^2 \quad (3.27)$$

Çok Değişkenli Senkrosıkıştırma Dönüşümü

Senkrosıkıştırma yönteminin çok değişkenli sinyal analiz için genişletilmesi amacıyla, her bir kanal için modüle edilmiş salınımlı komponentler biliniyorsa, moduleli salınımlarının frekansları yeterince birbirine yakın olması koşulu ile, ortak anlık frekans hesaplanabilir. Bu bakış açısı ile, K frekans bandı $\{w_k\}_{k=1,\dots,K}$ içine zaman frekans gösteriminin ilk bölümü bulunur ve bu bölüm verilen çok değişkenli sinyalden bir dizi eşleşen tek değişkenli sinyalin belirlenmesini sağlar. Bu frekans bandı taramasındaki anlık ve genlik frekanslar daha sonra belirlenebilir ve sonuç olarak GKA algoritmasındaki ÖKF'lere benzer olarak genlik ve frekans moduleli sinyaller elde edilir (Ahrabian *ve diğ.*, 2015; Ahrabian , 2014).

Zaman-frekans gösteriminde bölümlendirme

Bölümlemedeki temel amaç, çok değişkenli band genişliğine dayalı çok değişkenli tek bileşenli sinyalleri belirlemektir. Zaman frekans düzleminde, frekans aralığı, $l = 0, \dots, L$ frekans band seviyesine karşılık gelen (genellikle $L=5$ alınır) yerde, frekans band indeksi $m = 1, \dots, 2^{l-1}$ alınarak $w_{l,m} = [m, 2^{(l+1)}, (m+1)/2^{(l+1)}]$ için eşit genlikte frekans bandına bölünür. Frekans bandının Seviye l ve indeks m olduğu durumda çok değişkenli bandgenişliği $B_{l,m}$ Şekil 3.7:'deki gibi hesaplanır. Burada " m " frekans band indeksi ve " l " frekans band seviyesine karşılık gelir.



Şekil 3.7: $B_{l,m}$ olarak verilen çok değişkenli bant genişliğine sahip bölünmüş frekans alanı.

Seviye l ve indeks m de verilen bir frekans bandı için, çok değişkenli band genişliği $B_{l,m}$ şeklindeki gibi hesaplanır. $w_{l,m}$ verilen bir frekans bandı içinde, çok değişkenli band genişliği iki frekans altbandı $w_{l+1,2m}$ ve $w_{l+1,2m+1}$ olarak aşağıdaki gibi ayrılır:

- Eğer frekans bandı $w_{l,m}$ çok değişkenli, tek bileşenli sinyal içeriyorsa , o zaman,

$$B_{l,m} = B_{l+1,2m} + B_{l+1,2m+1}$$
- Eğer her bir frekans altbandı ayrı çok değişkenli tek bileşenli ise, o zaman, $B_{l,m} >$

$$B_{l+1,2m} + B_{l+1,2m+1}$$

Sonuç olarak, verilen frekans bandı $w_{l,m}$ için çok değişkenli band genişliği $T_n(w, b)$ tarafından verilen her bir kanal için SSD katsayılı N kanallı $x(t)$ çok değişkenli sinyali, SSD katsayısının tersinin Fourier transformu alınarak bulunur.

$$\Phi_{l,m} = [F\{\mathfrak{R}_{\Psi}^{-1} \sum_{\omega \in \omega_{l,m} T_n(\omega, b)}\}]_{n=1, \dots, N} \quad (3.28)$$

Burada $\{.\}$ Fourier dönüşümü operatörü, R_{Ψ} normalizasyon sabiti, ve $\Phi_{(l,m)}(w) \in \mathbb{R}^N$ sütun vektörüdür. Çok değişkenli bandgenişliği , Fourier katsayılarının toplam enerjisi ve ortak analitik spektrum (Ahrabian ve diğ., 2015) kullanılarak bulunur. Adaptif frekans ölçeklerinin temel mantığı; başlangıç çok değişkenli bandgenişliği $l = 0$ seviyesinde, bütün sinyal için hesaplanırsa, bandgenişliği aşağıdaki koşula dayalı bölünür, buna göre;

$$B_{l,m} > \frac{B_{l+1,2m}\Lambda_{l+1,2m+1} + B_{l+1,2m+1}\Lambda_{l+1,2m}}{\Lambda_{l+1,2m+1} + \Lambda_{l+1,2m}} \quad (3.29)$$

$$\Lambda_{l+1,2m} = \sum_{b=1}^T (A_{l+1,2m}^{coklu}(b))^2 \quad (3.30)$$

$$\Lambda_{l+1,2m+1} = \sum_{b=1}^T (A_{l+1,2m+1}^{coklu}(b))^2 \quad (3.31)$$

Burada, $(A_{l+1,2m}^{coklu}(b))^2$ ve $(A_{l+1,2m+1}^{coklu}(b))^2$ ilgili frekans altbandları için çok değişkenli anlık genliklere karşılık gelir. (Olhede ve Walden, 2004)'da, eşitliğin sağ tarafı frekans altbantlarının toplam enerjisini, ihmal edilebilir sinyal içerikli altbantlar dikkate alınmayacak şekilde, tam böler. Adaptif frekans bantlarının son seti, K salınımlı ölçek sayısı ve $w_1 > w_2 > w_3 > \dots > w_K$ olmak üzere $\{w_k\}_{k=1, \dots, K}$ olarak verilir.

3.1.2.3. Çok değişkenli zaman-frekans gösterimi:

Herbir kanal $T_n(w, b)$ için karşılık gelen SSD katsayıları ile çok değişkenli sinyal $x(t)$ için, (SSD katsayıları $T_n(w, b)$, sabit R_Ψ normalizasyon katsayısı ile normalize edilir), (Olhede ve Walden, 2004)'da önerilen yöntemin çok değişkenli uzantısı kullanılarak, verilen bir salınım ölçeği kümesi $\{w_k\}_{k=1, \dots, K}$ elde edilir, her bir kanal bandı k için anlık frekans $\Omega_k^n(b)$ aşağıdaki gibi verilir:

$$\Omega_k^n(b) = \frac{\sum_{w \in w_k} |T_n(w, b)|^2 w}{\sum_{w \in w_k} |T_n(w, b)|^2} \quad (3.32)$$

Ve her bir frekans bandı için anlık genlik $A_k^n(b)$;

$$A_k^n(b) = \sqrt{\sum_{w \in w_k} |T_n(w, b)|^2} \quad (3.33)$$

Aşağıdaki koşul her frekans bandında, hesaplanan anlık frekanslar için de geçerlidir. $\Omega_k^n(b) > \Omega_{k1}^n(b)$ daha açık bir şekilde, zaman içinde her noktada anlık frekanslar iyi bir şekilde ayrılır. İkinci adımda, ortak anlık frekansı kullanarak N kanal boyunca anlık frekansı, verilen bir frekans bandı k için, birleştirerek çok değişkenli anlık frekansı tahmin etmektir. Sonuç olarak, çok değişkenli anlık frekans bandı $\Omega_k^{\text{çoklu}}(b)$ aşağıdaki gibi verilir:

$$\Omega_k^{\text{çoklu}}(b) = \frac{\sum_{n=1}^N (A_k^n(b))^2 \Omega_k^n(b)}{\sum_{n=1}^N (A_k^n(b))^2} \quad (3.34)$$

Her bir kanal için anlık genlik $A_k^{\text{çoklu}}(b)$;

$$A_k^{\text{çoklu}}(b) = \sqrt{\sum_{n=1}^N (A_k^n(b))^2} \quad \text{olur.} \quad (3.35)$$

Bu durumda her bir frekans bandı için ortak anlık frekans ve genlik bulunabilir. Her bir salınım ölçümü k için, çok değişkenli zaman frekans katsayısı $T_k^{\text{çoklu}}(w, b)$;

$$T_k^{\text{çoklu}}(w, b) = A_k^{\text{çoklu}}(b) \delta(w - \Omega_k^{\text{çoklu}}(b)) \quad (3.36)$$

Burada, $\delta(\cdot)$ dirac delta fonksiyonu ve her bir salınımlı ölçek için çok değişkenli zaman frekans katsayısı:

$$T^{\zeta oklu}(w, b) = T_k^{\zeta oklu}(w, b)|_{k=1, \dots, K} \quad (3.37)$$

bulunur.

Ancak, anlık frekans hesaplamaları boyunca faz bilgisi kaybolduğu için orijinal çok değişkenli sinyal $x(t)$ 'nin yeniden inşa edilemeyeceği not edilmelidir.

Algoritma 4: Çok Değişkenli Senkrosıkıştırma Algoritması:

- Verilen N kanallı çok değişkenli sinyal $x(t)$ için $T_n(w, b)$ katsayıları elde etmek amacıyla, SSD kanala göre uygulanır.
- Zaman frekans gösterimi için frekans eksenini boyunca bir dizi bölüm belirlenir, her bir frekans bölümü için anlık frekans $\Omega_k^n(b)$ ve anlık genlik $A_k^n(b)$ sırasıyla hesaplanır.

$$\Omega_k^n(b) = \frac{\sum_{w \in w_k} |T_n(w, b)|^2 w}{\sum_{w \in w_k} |T_n(w, b)|^2} \quad (3.38)$$

$$A_k^n(b) = \sqrt{\sum_{w \in w_k} |T_n(w, b)|^2} \quad (3.39)$$

- Sırasıyla çok değişkenli frekans $\Omega_k^{\zeta oklu}(b)$ ve çok değişkenli genlik $A_k^{\zeta oklu}(b)$ hesaplanır.

$$\Omega_k^{\zeta oklu}(b) = \frac{\sum_{n=1}^N (A_k^n(b))^2 \Omega_k^n(b)}{\sum_{n=1}^N (A_k^n(b))^2} \quad (3.40)$$

$$A_k^{\zeta oklu}(b) = \sqrt{\sum_{n=1}^N (A_k^n(b))^2} \quad (3.41)$$


- Çok Değişkenli Senkrosıkıştırma Katsayısı $T^{çoklu}(w, b)$ hesaplanır.

3.2. SINIFLANDIRMA

EEG öznitelik vektörü, bir duygusal durumdan ne sonuç çıkarılacağına gözlenmesini sağlar. Genel olarak, bir sınıflandırıcı mümkün duygusal durumların biri içinde öznitelik vektörünü çözmek için kullanılır. Çok sayıda sınıflandırma yöntemi, Mahalanobis mesafe tabanlı yöntem (*ing-Mahalanobis Distance*), K-en yakın komşu (k-NN), Destek Vektör Makinesi (DVM) (*ing-Support Vector Machine*), Diskriminant Analizi dahil olmak üzere duygu durum tahmininde kullanılmıştır.

Daha önce açıklandığı gibi, duygu durumunu tahmin eden çoğu sayısal modeller, ayırık durum uzayı üzerine odaklanır ve sonlu sayıda duygu durumlarının biri üzerine EEG özniteliklerini sınıflandırır. Bu yaklaşım, verilen uyarının hangi duyguyu tetiklediğinin statik olarak belirlenmesi durumuna genellikle iyi sonuçlar verir. Ancak, duygu durumunun sürekli takibinin önemli rol oynadığı çevrimiçi duygu tahmin sisteminin gelişmesi için, mevcut yaklaşım duygu durumunun zamansal dinamikleri dikkate alınmadığı için yetersiz kalabilir. Genellikle, gözlenen EEG sinyalinin duygusal duruma doğrudan giriş çıkış haritalaması oluşturulur. Ancak, sınıflandırma doğruluğunun iyileşmesi amacıyla makul bir çözüm sağlamasına rağmen, duygu durumunun dinamiği kadar duygu durumunun önceki bilgisinden faydalanmaz. Bu eksiklikler, duygunun sinirsel mekanizması üzerinde yararlı analizler elde edilmesini zorlaştırmaktadır. Ek olarak bir model içinde, özellikle zamanla sürekli olarak duygusal durumunu izlemek için duygu durumunun dinamiklerinin önceki bilgisinin eklenmesi genellikle arzu edilir. Ancak mevcut veritabanları genellikle duygu oluşumu üzerine odaklanmıştır.

Öte yandan, makine öğrenme algoritmaları, insanlığa yetenek kazandırır ve bu sayede makineler kendi deneyimlerinden yeni bilgiler edinebilirler. Bu yetenek öğrenme olarak adlandırılır. Algoritmalar, daha fazla örnekle tahmin performanslarını geliştirebilirler. Makine öğrenimi algoritmaları günlük yaşamında özellikle tümör tespiti gibi tıbbi tanı, yüz tanıma gibi güvenlik amaçlarıyla, hesaplamalı finans, hareket algılama gibi görüntü işleme, tahmini bakım için otomotiv, havacılık, üretim, doğal dil işleme gibi alanlarda yaygın olarak kullanılmaktadır. Makina öğrenme çeşitleri **Şekil 3.8:**'de gösterilmektedir.



Şekil 3.8: Makina Öğrenme çeşitleri

Danışmanlı makine öğrenimi algoritması, sınıflandırma modeli öğrenme ve oluşturma amacıyla sınıf bilinen verileri girdi ve çıktı olarak kullanır. Daha sonra model bilinmeyen verileri tahmin etmek için kullanılır. Danışmanlı öğrenme, sınıflandırma ve regresyon tekniklerini üretmek için kullanılan yordayıcı modeli kullanmıştır (Shipp *ve diğ.*, 2002). Sınıflandırma teknikleri veri noktalarının sınıflarını varsayar. Örnek olarak, bir e-postanın spam olup olmadığını, EEG verileri kullanarak nörofizyolojik vakaları saptadıklarını tespit ederler. Danışmansız öğrenme, etiket yanıtı olmadan kapsanan modeller veya içsel özellikler ortaya çıkarır ve sadece girdi değerlerini içerir. Genellikle gen dizisi analizi, pazar araştırmaları için kullanılır (Hofmann *ve diğ.*, 2001)


3.2.1. Destek Vektör Makinesi

DVM algoritmaları Boser *ve diğ.* (1992) tarafından danışmanlı makina öğrenme algoritmaları olarak ikili şekilde sunulmuştur (Vapnik ve Vapnik, 1998). DVM'nin esas avantajı, sınıflandırma problemini optimizasyon problemine dönüştürerek çözmektir. Bu sayede hesaplama süreçlerinin sayısı azaltılacak ve diğer tekniklere göre daha hızlı bir çözüm elde edilebilecektir (Osowski *ve diğ.*, 2004). DVM, doğrusal iki sınıf sınıflandırıcıların bir üyesidir. Veri kümelerindeki nesnelerin sınıflandırma işlemi, temel olarak -1 (ilk sınıf) veya 1 (diğer sınıf) olarak nesnelerin etiketlenmesine dayanır. Etiketleme süreci, araştırmanın belirtilmesine göre değişmektedir (Friedman *ve diğ.*, 2001). DVM'nin diğer bir önemli işlevi de farklı olarak etiketlenmiş veri noktalarını ayırt edebilen en uygun bir hiperdüzlem (doğrusal karar sınırı) oluşturmak ve destek vektörleri arasındaki mesafeyi maksimize etmektir (Bishop *ve diğ.*, 2006; Ben-hur ve Weston, 2010). DVM'nin matema-

tiksel açıklaması aşağıdaki gibi özetlenebilir; her giriş noktası " x_i " olarak gösterilebilir ve etiketler " y_i " olarak ifade edilebilir, " w " hiper düzlemin normalini ve ağırlık vektörünü, ek olarak " b " ise eğilim ve sabit değeri temsil eder.

$$f(x) = wx + b \quad (3.42)$$

İki sınıf ve iki boyutlu sınıflandırma için, lineer DVM modelinin geometrik çizimi **Şekil 3.9:**'da gösterilmiştir.




Şekil 3.9: DVM'nin geometrik çizimi

İki paralel çizgi sınır düzlemi olarak adlandırılır. Sınır düzlemlerinin ortasından geçen ve her iki düzlemi de eşit olarak ayıran koyu renk yazılmış düzlem bir hiper düzlem olarak ifade edilmektedir (Burges, 1998; Soman, 2009). DVM doğrusal olmayan uyarlanabilir verileri doğrusal bir karar sınırının bulunabileceği daha yüksek boyutlarda oluşturmak için polinom, gauss gibi çekirdek fonksiyonları kullanır.

Petrantonakis ve Hadjileontiadis (2010) çalışmalarında yüksek boyutlu öznelik uzayını yansıtan polinom ve çekirdek fonksiyonu kullanılan DVM sınıflandırıcı kullanmışlardır ve DVM kullanarak farklı duygu sınıfları sınıflandırılmıştır (Petrantonakis ve Hadjileontiadis, 2010). Channel ve diğ. (2009) çalışmalarında kısa süreli duyguları, karar yüzeyi ile bu yüzeye en yakın nokta arasındaki mesafeyi maksimuma çıkaran ve ayrıca eğitim setindeki hatayı en aza indiren maksimum kenar sınıflandırıcılarına sahip olan DVM kullanarak kategorize etmiştir (Channel ve diğ., 2009). Ayrıca öznelikleri analiz etmek ve duyguları sınıflandırmak için doğrusal ve radyal temel fonksiyonları kullanılmıştır.

3.2.2. Topluluk Sınıflandırıcı




Şekil 3.10: Topluluk Sınıflandırıcı Akış Şeması

Topluluk modelleri, daha istikrarlı oldukları ve daha önemlisi tekil sınıflandırıcı daha iyi oldukları düşünüldüğü için pek çok alanda yaygın olarak kullanılmaktadır (Lessman ve diğ., 2015). Model biyasını ve varyansını azalttığı da bilinmektedir (Myoung ve diğ., 2006; Tsai ve Hsiao, 2011). Topluluk sınıflandırıcılar, birden fazla temel modelin tahminlerini toplar. Bir çok ampirik ve teorik kanıtlar model kombinasyonunun tahmin edilen doğruluğu artırdığını göstermiştir (Finlay, 2011; Paleologo, 2010). Topluluk öğrenicileri, temel modelleri bağımsız veya bağımlı bir şekilde oluştur. Mevcut toplulukların hatalarından kaçınmak için tekrar eğitilmiş temel modeller eklenir (Paleologo, 1996). **Şekil 3.10:**'da Topluluk Sınıflandırıcı Akış Şeması sunulmaktadır.

3.2.3. En Yakın Komşu Sınıflandırıcı

Sınıflandırma için kullanılabilecek en basit karar prosedürlerinden biri en yakın komşu kuralıdır. En yakın komşusunun kategorisine göre bir örnek sınıflandırır. En yakın komşu



Şekil 3.11: En yakın komşu sınıflandırıcı grafik çizimi

sınıflayıcılar, test tanımlama gruplarını, ona benzeyen eğitim tanımlama grupları ile karşılaştırmak suretiyle öğrenmeye dayanır. Bir tanımlama grubuna aşına olmadığında, o zaman k-en yakın komşu sınıflandırıcı, bilinmeyen tanımlama grubuna en yakın olan k eğitim verileri için örnek boşluğu araştırır. Bu eğitim tanımlama grupları, bilinmeyen tanımlama gruplarının "en yakın komşular" ıdır. Yakınlık, Öklid mesafesi kullanılarak tanımlanmıştır. En yakın komşu sınıflandırıcı grafik çizimi **Şekil 3.11:**'de gösterilmiştir. **Şekil 3.11:**'de de görüldüğü gibi farklı tanımlama grupları en yakın komşu sınıflandırıcı kullanılarak sınıflandırılmıştır (Sreeshakthy ve diğ., 2016).

İki nokta ya da tanımlama grubu arasındaki Öklid uzaklığı

$$X_1 = (x_{11}, x_{12}, \dots, x_{1n}) \text{ ve } X_2 = (x_{21}, x_{22}, \dots, x_{2n})$$


olmak üzere;

$$Uzaklik(X_1, X_2) = \sqrt{\sum (X_{1i} - X_{2i})^2} \quad (3.43)$$

dir.

3.2.4. Karar Ağacı

Karar ağaçları, kolay anlaşılır bilgi modelleri sundukları için popüler bir makine öğrenme sınıflandırma metodudur (Mitchell, 1997). Ayırım genellikle, ayrık, kategorik değişken-



Şekil 3.12: Bir karar ağacının şematik temsili

lerden ziyade sürekli kullanan yöntemler arasında yapılır (Bell, 1999). Sınıflandırma, "kök" ile "yaprak" düğümlerindeki tabandan bireyleri sınıflandırarak örnek verilere dayanan girdi alanını bölen bir ağaç yapısı kullanılarak gerçekleştirilir (Mitchell, 1997; Bell, 1999; Duda *ve diğ.*, 2000). Kökten başlayarak (örneğin, farklı popülasyonlardan gelen bireylerin bir karışımı), ağaçtaki her düğüm tek bir değişken (veya özellik) hakkında bir test sorusu içerir. Karar ağacındaki kritik adım, her bir düğümde hangi özelliğin test edileceğini belirtmektir. Bu karar, ilk olarak her bir değişkenin entropisi olarak tanımlanan entropi ile hesaplanır.

$$S = \sum_{i=1}^c -p_i \log_2 p_i \quad (3.44)$$

burada, belirli bir öznitelik için belirli bir durumu paylaşan kişilerin oranını temsil eden p ve durum sayısını olasılık metodu 0, 1 veya 2 ön işlemesi gözönüne alındığında (öznitelik,

bireyde temsil edilmediyse 0, belirli bir lokusta heterozigot ise 1 ve homozigot ise 2) temsil eden c parametreleridir. Bilgi kazanımı, bölünmeden önce ve sonra bireylerin alt kümeleri içindeki entropi azalması ile ölçülür. Böylelikle, her bir ayırmada, tüm özellikler bir ayırımla sonuçlanan en ayırt edici özelliği seçmek için değerlendirilir. Bir özellik A'nın bilgi kazanımı $G(S,A)$, entropi katılarak;

$$G(S,A) = S - \sum_{v \in [0,1,2]} \frac{S_v}{S} S_v \quad (3.45)$$

S_v , v değerine sahip A özelliği için S'nin alt kümesini temsil eder (Mitchell, 1997). **Şekil 3.12:** 'de bir karar ağacının şematik temsili gösterilmektedir

Ağaçtaki her düğüm, gruplar içinde entropi azalması açısından nicelleştirilen, maksimum bilgi kazancıyla sonuçlanan öznetelik değerleri temelinde bireyleri tekrar böler.


3.3. ÇAPRAZ DOĞRULAMA YÖNTEMLERİ

Çapraz Doğrulama Yöntemleri (ÇDY), veri seti eğitim verileri ve test verileri olarak belirleyen ve kategorize eden birkaç protokol oluşturur (Mosier, 1951) ve eğitim ve test verilerinin objektif olarak seçilmesini sağlar ve böylece sınıflandırma performansını artırır (Browne, 2000). Veri setindeki değerler, 3 yöntemle test veya eğitim verileri olarak etiketlenir.

3.3.1. Dışarda Tutma ÇDY

Dışarda Tutma yönteminde veri seti eğitim ve test olmak üzere iki parçaya ayrılır. Test setinde kullanılan veri, eğitim setinin dışındaki verilerden oluşup, sınıflandırma modeli oluşturulduktan sonra eğitim verilerini kullanarak öğrenme gerçekleşebilir. Test veri seti ile de öğrenmenin ne kadar gerçekleştiği kontrol edilerek, model performansı değerlendirilmektedir. Varsayımın sonuçları, gerçek etiketler ve tahmini değer ile karşılaştırılır ve sonuç olarak sınıflandırıcı performansı bu şekilde belirlenir. Yöntemin yüksek bir varyansa sahip olması nedeniyle, performans sonuçları bölümün nasıl yapıldığına bağlıdır. Dışarda Tutma yöntemi **Şekil 3.13:**'de gösterilmiştir. Bu yöntemin dezavantajları da mevcuttur. Eğer gözlem sayısı az olur ise veri kümesindeki test ve eğitim verisi ayrımı yete-

rince uygun yapılamaz. Ayrıca, eğitim ve test verileri bir defaya mahsus ayrılır ise, veri setindeki verilerin tamamı öğrenmede kullanılamaz.




Şekil 3.13: Dışarda Bırakma ÇDY

3.3.2. K-Katmanlı ÇDY


K-Katmanlı ÇDY, Dışarda Tutma yöntemindeki eksiklikleri gidermek için önerilmiş bir yöntemdir. Dışarda tutma yönteminde veri kümesi iki eşit parçaya bölünür ve eğitim verileri veya test verileri olarak etiketlenir. Fakat K-katmanlı ÇDY'ni uygulamak için, veri alt kümesinin K-parçasına bölünmüş olmalıdır. Öğrenme süreci K-kez yinelemeye neden olur ve iterasyonun her birinde altkümelerin biri test için ve k-1 altküme eğitim için kullanılır. Altkümelerin rastgele seçiliyor olması bir avantajdır. Yöntemin diğer bir avantajı ise, tüm değerler hem eğitim hem de test olarak kullanılabilir. Dolayısıyla, sonuçlar verilerin nasıl bölüneceğinden etkilenmez. Seçilen alt kümelerden birbirine bitişik olması sonuçları artırabilir. K-kat ÇDY işlemi **Şekil 3.14:**'de gösterilmiştir.

3.3.3. Birini Dışarda Bırak ÇDY

Birini Dışarda Bırak ÇDY, K-Katmanlı ÇDY'nin özel ve yenilikçi bir türüdür. K-katmanlı ÇDY ile aynı şekilde gerçekleştirilir, ancak k her zaman 1'e eşit olacaktır. Bu şekilde, yöntem, alt örneklerin komşularının performans puanları üzerindeki etkilerini ve tahmin edicinin varyans fazlalığından kaynaklanan problemi aşabilir. Veri kümesindeki her değer test değeri olarak kullanıldığından, tahmin sonuçları daha sağlam olacaktır. Birini Dışarda Bırak ÇDY **Şekil 3.15:**'de gösterilmektedir (Gutierrez, 2006)



Şekil 3.14: K-Katmanlı ÇDY



Şekil 3.15: Birini Dışarda Bırak ÇDY

3.4. GRAM-SCHMIDT YÖNTEMİ İLE ORTOGONALLEŞTİRME

GKA, aşağıdaki özellikleri karşıladığı bilinen doğrusal olmayan çok ölçekli veri bağımlı bir ayrışma olduğunu gösterir:

- Genel olarak ikili filtre bankası yapısı olarak hareket eder.
- Yarı-ortogonal bir ayrışmadır, dolayısıyla modlar nispeten ortogonaldır (Huang ve Kunoth, 2013; Cherian *ve diğ.*, 2014; Oberlin *ve diğ.*, 2012).

Böylece, ilgili ÖKF'ler GKA işleminde elde edildikten sonra, sadece ortogonal modlarla ilgilenen bir yöntemin işlemi kolaylaştırabileceği açıktır. Bu şekilde, edinilmiş ÖKF'ler, ortogonal bileşenlerin miktarını tahmin etmek için Gram-Schmidt Ortogonalleştirme yöntemine tabi tutulurlar (Cherian *ve diğ.*, 2014). (Lou ve Huang, 2015; Huang *ve diğ.*, 2018) sayısal örnekler ile tüm ÖKF'lerin karşılıklı olarak ortogonal olmadığını incelemişlerdir.

V'nin doğrusal olarak bağımsız bir alt kümesi olarak $\mathcal{U}_1, \mathcal{U}_2, \dots, \mathcal{U}_n$ temelli sonlu boyutlu bir iç çarpım uzayı olsun. Vektör sistemi $\mathcal{U}_1, \mathcal{U}_2, \dots, \mathcal{U}_n$ 'deki herhangi iki vektörün birbirine dik olduğu tespit edilir ise, bu sisteme "ortogonal vektör sistemi" denir. Diğer bir deyişle, $1 \leq i, j \leq n$ $i \neq j$ olmak üzere, $\mathcal{U}_1, \mathcal{U}_2, \dots, \mathcal{U}_n$ ortogonal vektör sistemini oluşturur. Ek olarak, ortogonal vektör sistemi $\mathcal{U}_1, \mathcal{U}_2, \dots, \mathcal{U}_n$ için;

$$e_1 = \frac{\mathcal{U}_1}{\|\mathcal{U}_1\|}, \quad e_2 = \frac{\mathcal{U}_2}{\|\mathcal{U}_2\|}, \quad \dots \quad e_n = \frac{\mathcal{U}_n}{\|\mathcal{U}_n\|}, \quad (3.46)$$

olmak üzere, $e_1, e_2, \dots, e_n$ ortonormal vektör sistemini oluşturur. Başka bir ifade ile, $1 \leq i, j \leq n$ için, $\langle e_i, e_j \rangle = \delta_{ij}$ ise $e_1, e_2, \dots, e_n$ ortonormal vektör sistemidir.

$$\delta_{ij} = \begin{cases} 1, i = j \\ 0, i \neq j \end{cases} \quad \text{olup, Kronecker Deltası olarak bilir.}$$

Gram Schmidt Ortogonalleştirme metodunda amaç, bir iç çarpım uzayında lineer bağımsız bir vektör sisteminden önce ilk basamak olarak bir ortogonal vektör sistemi sonrasında da ortonormal bir vektör sistemi elde etmektir. V, n boyutlu iç çarpım uzayı olmak üzere, $r \leq n$ olan $v_1, v_2, \dots, v_n \in V$ için $v_1, v_2, \dots, v_n \in V$ lineer bağımsız bir vektör sistemi düşünülür ise, daha sonraki basamakta Gram-Schmidt Ortogonalleştirme işlemi ile, yeni vektörler olan $v_1, v_2, \dots, v_n$ oluşturmak için $\mathcal{U}_1, \mathcal{U}_2, \dots, \mathcal{U}_n$ vektörlerinden faydalınır. Oluşturulan ortogonal vektör sistemindeki her vektör kendi normuna bölünerek ortonormal vektör sistemi hazırlanır. $1 \leq i \leq r$ olmak üzere, $e_i = \frac{\mathcal{U}_i}{\|\mathcal{U}_i\|}$, vektörlerinden oluşan

ortonormal vektör sistemi bulunur.

$$\mathcal{U}_r = \mathbf{v}_r - \sum_{j=1}^{r-1} \frac{\langle \mathbf{v}_r, \mathcal{U}_j \rangle}{\langle \mathcal{U}_j, \mathcal{U}_j \rangle} \mathcal{U}_j \quad (3.47)$$

3.5. TEKİL DEĞER ANALİZİ


Durağan olmayan ve çok bileşenli bir sinyali analiz etmek için, zaman-frekans temelli tekniklerin diğer tekniklerden üstün olduğu gösterilmiştir (Cohen, 1995). Bir sinyalin zaman-frekans temsilindeki gömülü örnekler matrisin tekil değer ve vektörlerini kullanarak karakterize edilebilir. Tekil değer ayrıştırma yöntemi, sinyal işleme ve istatistiksel veri analizinde önemli bir araç olmuştur. X sinyalinin zaman frekans dağılımını gösteren $M \times N$ 'lik X matrisinin bir tekil değer ayrışımı aşağıdaki formülle ifade edilebilir.

$$X = \mathcal{U} \Sigma V^T \quad (3.48)$$

Burada, $\mathcal{U} (M \times M)$ ve $V (N \times N)$ ortonormal matrislerdir. Σ ise, $\sigma_{i,j} > 0$ ve $i \neq j$ olmak kaydıyla, $\sigma_{i,j} = 0$ bileşenli tekil değerlerin diagonal matrisidir. Ek olarak, $\sigma_{1,1} \geq \sigma_{2,2} \geq \dots \geq 0$ gibi benzersiz olmayan $\mathcal{U}$ ve V matrislerinin var olduğu gösterilebilir. $\mathcal{U}$ ve V matrislerinin sütunları sırasıyla sağ ve sol tekil vektörler olarak adlandırılır. $\mathcal{U}$ ve V 'nin önemli bir özelliği karşılıklı ortagonal olmalarıdır (Nakos ve Joyner, 1998). Tekil değerler matrisin bileşimindeki bireysel tekil vektörleri temsil ederler. Diğer bir ifade ile, matristeki gömülü örnekler için daha geniş tekil değerlere karşılık gelen tekil vektörler diğer tekil vektörlerden daha önemli bilgiler içerir. Tekil değer analizi kullanarak zaman frekans ekseninde bir örneği spesifikliğini bulmak için, daha geniş tekil değerlere karşılık gelen bazı sağ ve sol tekil vektörlerin kullanılması gerekmektedir. Bunun nedeni, sağ ve sol tekil vektörlerin sırasıyla sinyalin frekans ve zaman domeni temsili ile ilişkili olmasıdır (Groutage ve Bennink, 2000)

3.6. ÇOKLU ÇÖZÜNÜRLÜK ANALİZİ

Ayrık dalgacık dönüşümü prosedüründe, sinyal ayrıştırılmalarını iki filtre ile (düşük frekans ve diğer yüksek frekans olmak üzere) yaklaşım katsayılarına (A) ve detay katsayıla-



Şekil 3.16: Dalgacık ayrışmasının filtre bankası uygulaması

rına (D) ayırır. Yaklaşık katsayısı daha fazla yaklaşım ve detay katsayılarına ayrılmıştır; Ancak, detaylar daha fazla bölüme maruz kalmamaktadır. Bu prosedür yinelemeli olarak tamamlanmakta, çeşitli seviyelerde veya ölçeklerde yaklaşım katsayıları ve detay katsayıları düzenlemesi oluşturmaktadır. Üç seviyeli dalgacık ayrışması için dalgacık dönüşümünün filtre bankası uygulaması **Şekil 3.16:**'da gösterilmektedir. Dalgacık dönüşümüyle altındaki temel fikir Çoklu Çözünürlük Analizi (ÇÇA) olarak bilinen yöntemi motive eden, ölçek ve dönüşümün ilgili farklı seviyeleridir.

ÇÇA, Mallat (1989) tarafından önerilmiştir (Mallat, 1989). Sinyallerin incelenmesine yönelik bu yöntem, bir bilgi sinyali için çok seviyeli bir temsilden oluşur. Her bir sonraki seviye boyunca, yaklaşımlar yaklaşıklık ve detay katsayılarına ayrılır. Çoğunlukla, ÇÇA ölçekleme fonksiyonunun, sürekli fonksiyon $f(t)$ için parçalı yaklaşımda dikkate değer bir role sahip olduğunu ve ölçekleme endeksine bağlı olduğunu öne sürmektedir. ÇÇA'nın ana dalgacık fonksiyonunun seçimine bağlı olduğunu söylemek gerekir. Ana dalgacık ve ölçekleme fonksiyonunun seçimi incelemeye bağlı olarak değişir. Bu nedenle, talep edilen sonuçlara sahip olan tüm uygulamalar için ana dalgacık ve ölçekleme fonksiyonunun belirlenmesi o incelemeye bağlı olarak değişmiştir. ÇÇA analizi veri sıkıştırma, biyomedikal sinyal analizi, özellik çıkarma, gürültü giderme vb gibi farklı sorunların üstesinden gelmek için büyük ölçüde tercih edilmektedir. Bu çalışmada, dört farklı dalgacık fonksiyonu -db8, db4, sym8 ve coif5- çoklu çözünürlük analizi, EEG sinyallerini beş farklı frekans bandında (delta, teta, alfa, beta ve gama) ayırmak için kullanılmıştır. Bu dalgacık fonksiyonları, en iyi zaman-frekans gösterim özellikleri nedeniyle seçilmiştir. Ayrıca, bu dalgacıkların dalga şekilleri, EEG sinyalinde ayırt edilecek dalga formları gibidir. **Tablo 3.1:**'de, örnekleme frekansı $f_s = 128$ Hz ile çeşitli dekompozisyon seviyelerine ilişkin bant genişliğini ve frekanslarını göstermektedir.


Tablo 3.1: EEG sinyallerinin 128Hz'lik örnekleme frekansına sahip farklı frekans bantlarına ayrılması.

Frekans Aralığı	Ayrışma Seviyesi	Frekans Bandları	Frekans Bandgenişliği
0-4 Hz	A5	Teta	4 Hz
4-8 Hz	D5	Delta	4 Hz
8-16 Hz	D4	Alfa	8 Hz
16-32 Hz	D3	Beta	16 Hz
32-64 Hz	D2	Gama	32 Hz


4. BULGULAR

4.1. EEG SİNYALLERİ YOLUYLA DUYGU DURUM SINIFLANDIRIMADA ÇOK DEĞİŞKENLİ SENKRO SIKIŞTIRMA YÖNTEMİ KULLANIMI

Bu çalışmada, çok değişkenli senkrosıkıştırma yöntemi kullanılarak Bölüm 2.4.2.1. de açıklandığı gibi ve **Şekil 2.5:**'de de gösterildiği gibi iki boyutu Circumfleks model ve Bölüm 2.4.2.2. de açıklandığı gibi ve **Şekil 2.10:** 'de gösterildiği gibi üç boyutlu model farklı sınıflandırıcılar kullanılarak değerlendirilmiştir. **Şekil 2.10:** modelindeki değerler bu çalışmada değerlik-aktivasyon ve baskınlık etiketletlerine tekabül etmektedir. Buna göre, DEAP veri setinde 32 kişinin 40 video kaydı kullanılarak Bölüm 2.2.'de toparlanan kanal seçimi literatur bilgisi ve referans çalışmasına(Mert ve Akan, 2018) dayanarak, Bölüm 2.6.'da ifade edildiği gibi 26 kanallı veri girişi oluşturulmuştur. Sağ frontal ağırlıklı lobun (Fp2, AF4, F4, F8, FC2, FC6, T8, C4), sol ön ağırlıklı lob (Fp1, AF3, F3, F7, FC1, FC5, T7, C3), sağ ve sol frontal-ağırlıklı lob farklarından oluşan sanal kanallar ve 2 merkezi kanal (Fz, Cz) olmak üzere 26 giriş çok değişkenli senkrosıkıştırma algoritmasına **Şekil 4.1:**'deki gibi giriş vektörü olarak verilmiştir. Algoritmanın sonucu olarak çok değişkenli senkrosıkıştırma katsayıları elde edilmiştir ve her video kaydı için $(26 * 2017 * 4032)$ üç boyutlu matrisler oluşmuştur. Bu sonuçlar, boyut indirgemesi için TDA algoritmasına girdi olarak verildiğinde, her video için tek boyutlu bir matris elde edilmiştir $(52442 * 1)$. Burada elde edilen diziler kompleks sayılardan oluştuğundan mutlak değerleri alınarak gerçek sayılar elde edilmiştir. Çalışmada kullanılan 32 kişinin verileri için $1280 * 52442$ 'luk bir girdi verileri oluşturulmuş (her video alt alta sıralanarak) ve giriş matrisi olarak verilmiştir. Buna karşılık, her bir etiket için (değerli, aktivasyon-baskınlık) karşılığında, 1'den 9'a değişen değerlerin, 5'inci skalada < 5 'e göre yüksek veya düşük değerlere sahip olduğu kararı ile son etiket değerleri 0 veya 1 olarak ayarlanır (Ozel ve diğ., 2017c). Son basamakta ise, $(1280 * 1)$ değerlik ve aktivasyon etiketine göre iki çıkış verileriyle lojik matematiğin "ve" operatörü çalıştırılıp, hem değerlik hem de aktivasyon etiketi 1'e eşitse, pozitif değerlik yüksek aktivasyon "PDYA" atanmıştır. Değerlik 0'a eşit olduğunda ve aktivasyon 1'e eşitse, negatif değerlik yüksek aktivasyon "NDYA" ve aynı şekilde pozitif değerlik düşük aktivasyon "PDDA", negatif değerlik düşük aktivasyon



"NDDA" olarak duygu durum grupları iki boyutlu Circumfleks modeli için oluşturulur. **Şekil 4.2:**'de oluşturduğumuz iki boyutlu duygu uzayı bölümlemesi görülmektedir.




Şekil 4.2: İki boyutlu duygu uzayı bölümlemesi

Ek olarak, bu etiketler kullanılarak duygular duygu durum uzayında dört farklı bölüme bölündükten sonra baskınlık etiketinin katkısı da göz önüne alınarak yeni duygu durum bölümleri yapılır. Daha açık bir ifade ile, "PDYA" etiketi göz önüne alındığında, baskınlık etiketi "1" ise, duygu bölümü "PDYAYB" olarak belirlenir, öte yandan baskınlık etiketi "0" ise, "PDYADB" olarak belirlenir. "NDYA" söz konusu olduğunda, baskınlık etiketinin içeriğine göre, "NDYAYB" ve "NDYADB" duygu bölümü oluşturulur. Diğer duygu durum bölümleri de baskınlık etiketinin sonucuna göre değerlendirilerek yeni duygu bölümleri oluşturulur. Ve son çıktılarımız "PDYAYB", "PDYADB", "NDYAYB", "NDYADB", "PDDAYB", "PDDADB", "NDDAYB", "NDDADB" olmak üzere sekiz duygusal durum bölümüne değerlendirilir. Üç boyutlu duygu durum uzayı bölümleri **Şekil 4.3:**'de görülmektedir.

Seçilen sınıflandırıcılar, MATLAB Classification Learner Tool paketindeki performansı $data = [çıktı \text{ (etiket verileri } (1280 \times 1) \text{ girişi (işlenmiş EEG sinyali } (1280 \times 52442))]$ olarak değerlendirilmiştir. Elde edilen sonuçlar **Tablo 4.1:** ve **Tablo 4.2:** de sunulmuştur. Sonuçlar % olarak verilmiştir.

Tablo 4.1: ÇDSSD kullanarak 2D değerlik- aktivasyon kombine alanı için dört duygusal ifade

<i>Sınıflandırma Yöntemleri</i>	PDYA	NDYA	PDDA	NDDA
KARAR AGACI				
Complex Tree	60.5	69.5	67.5	69.1
Medium Tree	69.1	76.3	73.4	74.5
Simple Tree	69.8	78.6	76.8	77.7
DESTEK VEKTÖR MAKİNESİ				
Linear	68.4	78.7	76.7	78.0
Quadratic	61.1	62.5	41.6	46.6
Cubic	43.7	55.9	61.4	44.8
Fine Gaussian	70.7	79.1	77.1	78.2
Medium Gaussian	70.8	79.1	77.1	78.2
Coarse Gaussian	70.8	79.1	77.1	78.2
EN YAKIN KOMŞU SINIFLANDIRICI				
Fine	58.0	68.4	63.8	66.4
Medium	69.8	78.5	76.6	77.3
Coarse	70.7	79.1	77.1	78.2
Cosine	68.8	78.4	76.4	78.1
Cubic	70.2	78.0	76.2	77.4
Weighted	65.2	74.9	72.3	73.9
TOPLULUK SINIFLANDIRICI				
Boosted Trees	70.9	79.1	77.1	78.2
Bagged Trees	66.5	75.5	74.1	75.1
Supspace Discriminant	62.8	69.1	68.1	67.5
Subspace k-NN	61.1	69.1	66.4	70.5
RUSBoosted Trees	70.2	45.8	37.8	38.2



Şekil 4.3: Üç boyutlu duygu uzayı bölümlenmesi

Tablo 4.2: ÇDSSD kullanarak 3D değerlik- aktivasyon-baskınlık kombine etki alanı için sekiz duygusal ifade


<i>Sınıflandırma Yöntemleri</i>	PDYAYB	PDYADB	PDDADB	PDDAYB	NDDADB	NDYADB	NDYAYB	NDDAYB
KARAR AGACI								
Complex Tree	63.7	84.2	77.4	81.3	77.3	85.7	74.1	88.2
Medium Tree	71.2	86.9	84.5	87.3	83.0	89.9	83.5	91.5
Simple Tree	74.0	88.6	86.5	89.6	84.7	91.6	84.8	92.7
DESTEK VEKTÖR MAKİNESİ								
Linear	65.9	88.1	86.3	89.8	85.4	91.6	84.5	93.0
Quadratic	68.4	44.5	76.8	30.7	66.6	74.5	51.0	70.9
Cubic	45.2	61.8	45.9	51.2	27.4	16.8	43.4	12.0
Fine Gaussian	73.4	88.8	86.5	90.2	85.3	92.1	85.1	93.3
Medium Gaussian	73.9	88.8	86.5	90.2	85.3	92.1	85.1	93.3
Coarse Gaussian	73.7	88.8	86.5	90.2	85.3	91.1	85.1	93.3
EN YAKIN KOMŞU SINIFLANDIRICI								
Fine	61.3	84.6	76.8	81.3	75.9	86.9	76.0	87.9
Medium	71.5	88.8	86.4	90.2	85.2	92.1	84.8	93.3
Coarse	74.0	88.8	86.5	90.2	85.3	92.1	85.1	93.3
Cosine	72.0	88.8	86.5	90.2	85.2	92.1	85.1	93.3
Cubic	71.4	88.8	86.3	90.2	85.2	92.1	84.9	93.3
Weighted	68.2	88.2	84.1	89.0	83.9	91.1	82.3	92.9
TOPLULUK SINIFLANDIRICI								
Boosted Trees	74.1	88.8	86.5	90.2	85.3	92.1	85.1	93.3
Bagged Trees	68.3	88.2	85.2	89.6	84.5	91.5	83.8	93.0
Supspace Discriminant	67.7	85.3	78.8	84.2	77.3	87.2	77.3	88.5
Subspace k-NN	64.1	86.0	79.8	84.7	79.8	87.7	78.0	90.6
RUSBoosted Trees	73.3	72.9	29.2	33.9	37.5	37.5	60.9	33.2

Buna göre, çalışmada yüksek-düşük değerlik, aktivasyon, baskınlık sınıflandırması için sınıflandırıcı olarak kullanılan paket içerdiğiindeki DVM, KA, EYKS, TS sınıflandırıcıların seçilen kernelleri kullanılmıştır. DVM, Bölüm 3.2.1.'da açıklandığı gibi, sınıflandırma problemini kareli optimizasyon problemine dönüştürür ve uygulanması sürecinde çekirdek fonksiyonu seçimi ve parametre optimizasyonu önemli rol oynamaktadır. Matlab Classification Learner Tool'da tahmin süresi lineer DVM için orta, diğer kerneller için yavaştır. Yorumlanabilirliği lineer DVM için kolay diğer kerneller için zordur. Hafıza kullanımı lineer DVM için ortadır, diğerleri için çoklu sınıflarda orta, ikililerde geniştir. KA da Bölüm 3.2.4., yukarıdan aşağıya, tekrarlı bir şekilde böl ve kazan metoduna göre inşa edilirler. Matlab Classification Learner Tool'da tahmin süresi hızlıdır. Yorumlanabilirliği kolaydır. Hafıza kullanımı azdır. EYKS ise Bölüm 3.2.3.'de ayrıntılı olarak anlatıldığı üzere, bu sinyallerin sınıflandırılmasında bir çok çalışmada kullanılan eğitim-siz ve temel bir sınıflandırma yöntemi olan Hassas k-NN kullanılmıştır. Veriye en yakın k tane örneğin sınıfına bakılarak sınıflandırılmaya karar verilir. Matlab Classification Learner Tool'da tahmin süresi kübik için yavaş diğerleri için ortadır. Yorumlanabilirliği zordur. Hafıza kullanımı ortadır TS'nda Bölüm 3.2.2.'da yer verilmiş olup, ilki topluluk içindeki temel sınıflandırıcıların başarıları, ikincisi ise temel öğrencilerin kararlarının birbirlerinden farklılığı olmak üzere iki temel kritere göre başarı sağlanır. Matlab Classification Learner Tool'da tahmin süresi algortimanın seçimine göre hızlıdan ortaya değişir. Yorumlanabilirliği zordur. Hafıza kullanımı algortima seçimine göre az küçükten büyüğe doğru genişler.

Sunulan çalışmada, duygu durum analizi için oluşturulan DEAP veri kümesi kullanılarak, EEG işaretlerinden değerlik, aktivasyon ve baskınlık duygu durumlarının hem iki boyutlu hem üç boyutlu sınıflandırması yapılmıştır. EEG işaretleri kullanılarak yapılan çalışmalarda, uyaranların sınıflandırma performansı üzerindeki etkileri karşılaştırılmıştır. **Tablo 4.1:**'de sırasıyla değerlik ve aktivasyon boyutlarına ait düşünülen dört sınıf her sınıf PDYA, PDDA, NDYA, NDDA için sonuçlar verilmiştir. Buna göre en iyi sonuçlar, DVM'de "fine gaussian", "coarse gaussian", "medium gaussian" kernellerinde elde edilmiştir. Diğer iyi sonuçlarda, EYKS kullanıldığında, "coarse" ve "cubic" kernellerde elde edilmiştir. Sonuçlar incelendiğinde, **Tablo 4.1:**'de verilen değerlik ve aktivasyon boyutunda (Ozel ve diğ., 2018d), iki boyut olarak düşölüp elde edilen dört grup farklı sınıflandırıcılarda elde edilen sonuçlar arasında tatmin edici sonuçlar elde edilmiştir. Üç boyutlu olarak düşünülen diğer çalışmada ise önerilen yöntem ile sekiz farklı duygu durumu oluş-

turulup, **Tablo 4.2:**'de sunulan sonuçlar karşılaştırıldığında, en iyi sonuç aynı şekilde iki boyut düşünülerek elde edilen sonuçlara benzer olarak DVM'de ve EYKS'nda benzer kernellerde elde edilmiştir. Ancak genel sonuçlar karşılaştırıldığında üç boyutluda elde edilen sonuçlar iki boyutlu sonuçlardan daha iyi olduğu görülmektedir.

Çalışmada farklı kanallara ayrı ayrı senkro sıkıştırma dönüşümü uygulanarak ve üç boyut sonrası duygu kümeleri bulunarak devam edilmiştir. Buna göre ilk çalışmadaki DEAP veri setinde kullanılan veri sayısı aynı kalıp kanallara ayrı ayrı SSD uygulanarak sınıflandırma sonuçları değerlendirilmiştir. Ek olarak üç boyutlu 8 farklı duygu durum sınıflandırmasından sonra her sınıfın duygu durumu kümesinde ne kadar etkili olduğu araştırılmıştır. Buna göre kanallara ayrı ayrı SSD uygulandığında yöntem ve sonuçlarımızı aşağıdaki **Tablo 4.3:**'de sırayla sunulmuştur. Sonuçlar yüzde (%) olarak sunulmuştur.



Şekil 4.4: DEAP Veri Setinde 3DSSD ve kanallara ayrı ayrı SSD uygulanmasının temsili gösterimi

- a) DEAP veri kümesinde SSD'yi ayrı kullanarak her bir kanal için 32 denek 40 video için iki boyutlu matris gösterimi
- b) DEAP veri kümelerinde 3DSSD kullanan 32 denekten 40 video için üç boyutlu matris gösterimi

Tablo 4.3: 26 girişli EEG kanalımızı ayrı ayrı incelemek için her bir kanal için SSD kullanan 3D değerlik- aktivasyon-baskınlık kombine alanı için sekiz duygusal ifade

<i>Sınıflandırma Yöntemleri</i>	PDYAYU	PDYADU	PDDADU	PDDAYU	NDDADU	NDYADU	NDYAYU	NDDAYU
KARAR AGACI								
Complex Tree	69.6	85.1	82.7	84.7	76.6	86.3	77.0	88.2
Medium Tree	73.2	86.1	85.6	87.8	81.6	89.1	82.6	89.9
Simple Tree	70.8	87.8	86.7	89.3	84.4	90.8	84.2	92.3
DESTEK VEKTÖR MAKİNESİ								
Linear	72.6	88.8	86.5	90.2	85.3	92.1	85.1	93.3
Quadratic	74.1	88.5	84.7	87.3	81.8	90.9	80.9	90.5
Cubic	70.0	87.0	82.3	86.6	79.8	89.4	79.3	89.8
Fine Gaussian	75.7	89.8	86.5	90.2	85.2	92.1	85.1	93.3
Medium Gaussian	71.3	89.8	86.5	90.2	85.3	92.1	85.1	93.3
Coarse Gaussian	70.5	89.8	86.5	90.2	85.3	92.1	85.1	93.3
EN YAKIN KOMŞU SINIFLANDIRICI								
Fine	67.6	86.7	82.4	81.9	77.5	85.9	77.3	85.2
Medium	74.5	88.8	86.6	90.2	85.2	92.1	84.1	93.3
Coarse	72.7	88.8	86.5	90.2	85.3	92.1	85.1	93.3
Cosine	74.2	88.8	86.3	90.2	85.3	92.1	84.4	93.3
Cubic	74.6	88.3	86.2	90.2	85.3	92.0	84.5	93.3
Weighted	73.4	88.4	85.8	88.2	82.3	90.9	83.4	92.0
TOPLULUK SINIFLANDIRICI								
Boosted Trees	70.5	88.8	86.5	90.2	85.2	92.1	85.1	93.3
Bagged Trees	72.9	87.9	85.4	87.7	82.0	90.7	81.5	92.0
Supspace Discriminant	73.1	86.2	84.0	85.9	80.5	87.9	81.0	89.6
Subspace k-NN	70.9	88.4	82.0	85.7	79.5	88.7	80.3	89.5
RUSBoosted Trees	55.8	62.3	72.7	81.1	55.9	60.5	50.8	65.6

İlk olarak, kanallar arasında çok kanallı bağımlılığı daha dikkatli gösterebilmek için, SSD yöntemini **Şekil 4.4:** 'de solda ayrı ayrı gösterilen 26 kanala sağda kanalların bütününe uygulandı. **Şekil 4.4:**'de görülebileceği gibi, iki gösterim ile özetlenirse; a) Her kanal için 32 kişilik 40 video için 2D matris gösterimi ve b) Tüm kanallar için 32 kişilik 40 video için 3D matris gösterimi temsilen gösterilmeye çalışılmıştır. Buna göre; ÇDSSD yöntemi kullanılarak, bir $26 \times 2017 \times 4032$ hücre olarak hesaplanacak şekilde kanal katkıları ile birlikte sağlanıyorken, SSD'yi kanallara ayrı olarak kullanırken, her kanal için 2017×4032 boyutlu matris elde edildi Ancak kanallara ayrı ayrı uygulandığında, bu tüm kanalların katkısını kavramak için 40 video izleyen 32 katılımcı için ilk kanalından son kanalına kadar birleştirmelidir. Bunlar, boyut küçültme için TDA algoritmasına girdi olarak verildiğinde, bir kanal da her video gösterimi için bir 2017×1 matrisi elde edilir. Bu nedenle, her bir hücrenin TDA'den sonra 2017×1 matris içerdiği 32×40 'lık bir hücreye sahip olunur. Bu noktada, bu hücrelerdeki matrislerin karmaşık sayılardan oluştuğunu hatırlamak önemlidir; bu sebeple sayıları kullanabilmek için bu kompleks değerli sayıların mutlak değerler hesaplanmıştır. Ardından, tüm kanalları birleştirdiğimizde tüm ilk kanallar birleştirildikten sonra ikinci kanallar gibi adımlar sonrası bir 40×1678144 matrisi elde edilir. Sınıflandırma aşaması için, bu matrisi 1280×52442 'ye çevirildi. (Bu, 40×1678144 matrisinin $40 \times (32 \times 52442)$ olarak yazılabilmesinden kaynaklanmaktadır, bu nedenle, MATLAB'da "reshape" işlevini kullanarak, bahsedilen matrisi yukarıda 1280×52442 'ye çevirildi). Bu yeniden şekillendirmede, çalışmamızda senkronize dönüşümün ayrı ayrı kanallara uygulanarak sınıflandırmasında 1280×52442 'lik bir matristen yararlanıldığını, diğer taraftan, ÇDSSD uygulanmasında sınıflandırma aşaması için 1280×52442 'luk bir matristen yararlanıldığını ifade edebilir. Belirtildiği gibi, veri uzunlukları neredeyse aynıdır. Bu, yaklaşık olarak benzer veri içeriğindeki veri katkısını görebileceğimiz anlamına gelmektedir.

Bu çalışmada, sınıflandırma sürecinde veri içeriğimizin performansını göstermek için SSD ve ÇDSSD yöntemlerini kullanılmıştır. Öncelikle, **Tablo 4.1:**'de ÇDSSD kullanarak 2D değerlik-aktivasyon kombine alanı için dört duygusal ifade olarak sunulmuştur. En başarılı sınıflandırmalar, **Tablo 4.1:**'de görülebileceği gibi, Gaussian DVM tiplerinde Coarse EYKS kullanılarak gerçekleştirilmiştir. Öte yandan, aynı süreç, ÇDSSD **Tablo 4.2:**'de kullanılarak 3D değerlik-aktivasyon-baskınlık kombine alanı için sekiz duygusal ifadeyle ve her bir kanala ayrı ayrı SSD kullanan 3D değerlik-aktivasyon-baskınlık kombine alanı için sekiz duygusal ifadeyle değerlendirilmiştir. Buna göre, EYKS'da Medium K-NN ve DVM'daki Gaussian DVM tiplerine sahip sınıflandırıcılar yine diğer sınıf-

landiricılara kıyasla en yüksek deęerdir. Bu noktada, veri ierięimizin, DVM'deki Kbik DVM ve **Tablo 4.2:**' deki TS, RUSBoosted Aęaları sınıflandırıcılar iin uygun olmadığı grlmřtr. Ancak, SSD'yi kanal bařına ayrı olarak gerekleřtirdięimiz **řekil 4.4:**'de, byle bir problemle karřılařılmamıřtır.

4.1.0.1. Deęerlendirme


Burada alıřmamız, hem SSD hem kanallara hem de ok deęiřkenli SSD'nin tm kanallara ayrı ayrı kullanılması aısından nemlidir. Sonularımıza gelince, her iki yntemin sonularının beklenileni karřılandığına altı izilmelidir. Ancak, DSSD algoritmaların aıklamasına gre, kanallar arasındaki ortak anlık frekans ve bant geniřlięinden kaynaklanan ok kanallı baęımlılıęın katkısının da grlmesi beklenmekteydi. SSD yntemi kanallara ayrı ayrı uygulandıęında, oklu kanal baęımlılıęını gz nnde bulundurmaması yonunden eksiklikleri olsa da, bu yntemi klasik zaman frekansı yntemiyle karřılařtırdığımızda, daha iyi zaman-frekans gsterimi saęlama aısından avantaja sahip olduęu aıktır. ok deęiřkenli SSD uzantısı da ok kanallı sinyalleri deęerlendirmek aısından nemli bir adımdır. Ancak burada ok kanallı katkının ok daha fazla grlmesi aısından eksikliklerinin iyileřtirilmesi gerektięi sonucuna varılmıřtır. Bu arada, tm kanallar iin yapılan DSSD iřlemi, bir kanala SSD yntemi uygulanması ile karřılařtırıldıęında daha yavařtır. Ancak, SSD'nin bir kanala ayrı ayrı uygulandıęı ve tm kanal katkılarını kullanarak birleřtirildięi srete zaman alıcı bir iřlemdir. alıřmamızın dięer  boyutlu alıřmalara katkısı sz konusu olduęunda, ok deęiřkenli bir yntem kullanmamız ve sınıflandırma algoritmalarımızı geniř tutmamız aısından alıřmamızın katkıları olacaktır. Ek olarak, mantıksal matematik kullanan sekiz farklı duygusal durum iin aktivasyon, deęerlik ve baskınlık boyutlarının birleřtirilmesi, alıřmamızda sınıflandırma srecini daha kolay hale getirmiřtir.

4.2. DUYGU DURUM ANALİZİ İÇİN EEG SİNYALLERİ KULLANILARAK GÜRÜLTÜ DESTEKLİ ÇOK DEĞİŞKENLİ GÖRGÜL KİP AYRIŞTIRMA YÖNTEMİ

Önerilen duygu durumu analizi modelinde, GD-ÇDGKA 'nın mod karıştırma sorununu çözen çift kutuplu filtre bankı yapısından faydalanılarak, çok değişkenli-band sınırlı ÖKF'ler elde edilmiştir. Aynı zamanda elde edilen ÖKF lerin zaman frekans dağılımı öznitelik vektörü olarak kullanılır. **Şekil 4.5:** 'de gösterildiği üzere, 32 kanalın tamamını kullanmak yerine, ilk çalışmamızda da olduğu gibi efektif sonuç almak için 8 kanal sol frontal lobta, 8 kanal sol frontal lobta, 2 kanal merkez kanallarında ve son olarak kullanılan sağ ve sol frontal lobların farkı olarak 8 sanal kanal kullanılmıştır. Sonuçlar ÇDGKA ile karşılaştırmak açısından ayrı ayrı sunulmuştur.


İlk olarak, ÇDGKA yönteminin çift kutuplu filtre yapısındaki başarısını göstermek için **Şekil 4.6:** deki ÇDGKA'yi bir filtre bankası olarak kullanırken, kullanılan 26 kanalda her ÖKF için iyi tanımlanmış anlık frekansların gösterimi ve mod karıştırma durumu sunulmuştur. Buna göre ÇDGKA çift kutuplu filte bankı yapısı kullanırken başarılıdır ancak daha tatmin edici sonuçlar elde edilebilir durumdadır. Aynı şekilde, ÖKF'lerine açılan EEG sinyalinde salınımlar ÖKF 5 den başlayarak azaldığı, ÖKF 9 da hemen hemen hiç salınım kalmadığı görülmektedir. **Şekil 4.7:**'deki görselde ÇDGKA kullanarak EEG sinyalinin ÖKF'lerine açılımı sunulmuştur. (Kullanılan EEG sinyali DEAP seti, 10. kişi 20. video dinletisidir. Toplamda sonuçtaki 15 ÖKF'den anlamlı görünen ilk 9 'u görselde sunulmuştur).

İkinci olarak önerilen duygu durum modelinde kullanılan GD-ÇDKA için çift kutuplu filtre yapısındaki başarısını göstermek için, **Şekil 4.8:**'de GD-ÇDGKA'yi bir filtre bankası olarak kullanırken, kullanılan 26 kanalda her ÖKF için iyi tanımlanmış anlık frekansların gösterimi ve mod karıştırma durumu sunulmuştur (Ozel ve diğ., 2017b). Buna göre, GD-ÇDGKA yöntemindeki çift kutuplu filtre bankı yapısı, ÇDGKA diyadik filte bankı yapısından daha başarılı olduğu aşıkardır. Özellikle, ÖKF 5'den sonra mod karıştırma olayının azaldığı ve mod- hizalama durumunun ve salınımların arttığı görülmektedir. **Şekil 4.9:**'deki görselde, GD-ÇDGKA kullanarak EEG sinyalinin ÖKF'lerine açılımı sunulmuştur. GD-ÇDGKA içindeki gürültü alt uzayında, 0.2-0.5 dB arasında değişen Sinyal Gürültü Oranı (SGO) (*ing-Signal Noise Ratiao (SNR)*)'ye karşılık gelen iki



Şekil 4.5: Önerilen GD-ÇDGKA tabanlı duygu durumu modeli


gürültü kanalı, $l = 2$ ve $N = 8000$ bağımsız gürültü takımı kullanımıştır. Bölüm 3.1.1.2. de anlatıldığı üzere, (GD) ÇDGKA 'de kullanılan yönlerin sayısı (*ing number of directions*) $V = 128$ dir ve (GD) ÇDGKA 'da kullanılan durdurma ölçütünün parametreleri $[\sigma_1 = 0.05, \sigma_2 = 0.5, \alpha = 0.05]$ dir. Ancak gürültü kanallarının sayısı üzerinde herhangi bir sınır yoktur. Karşılaştırma açısından $V = 64$ ve $V = 32$ alınarak elde edilen simülasyon sonuçları **Şekil 4.11:**, **Şekil 4.12:** ve **Şekil 4.13:**'de sunulmuştur. (**Şekil 4.10:** dan sonra kullanılan simülasyonlar 12.kişi 10. video dinletisi verisine aittir. Farklı kişi için de



Şekil 4.6: ÇDGKA'yi bir filtre bankası olarak kullanırken, kullanılan 26 kanalda her ÖKF için iyi tanımlanmış anlık frekansların gösterimi ve mod karıştırma durumu

sonuçları değerlendirmek için eklenmiştir).


ÇDGKA kullanıldığında, **Şekil 4.6:**'de, özellikle ÖKF 5 ve ÖKF 6 den başlayarak, görsel uyarıya karşılık gelen modda daha fazla mod hizalama sorunu bulunduğu ve dahası, farklı kanallardan gelen ÖKF 5, ÖKF 6, ÖKF 7, ÖKF 8 ve ÖKF 9 açılımları örtüşmekte ve daha fazla mod karıştırma ile sonuçlandığı görülmektedir. Öte yandan, GD-ÇDGKA'nın aynı veri setine uygulanması, **Şekil 4.8:** ve **Şekil 4.9:**de gösterildiği gibi, her biri tek bir zamansal modu içeren frekansa hizalanan ÖKF'ler ile sonuçlanmıştır. Daha önce Bölüm 3.1.1.2. ve 3.1.1.3. da belirtildiği gibi, GD-ÇDGKA'nın başarılı bir şekilde çalışması için "1 "gürültü kanalları için uygun genliklerin seçilmesi bir ön şarttır. Daha düşük gürültü seviyeleri kullanmak, standart GKA'de gözlemlenene benzer bir eğilim olan görsel uyarıya karşılık gelen modun gücünü azaltma eğilimindedir. Standart GKA'nin sonsuz küçük girdi gürültü seviyeleri için GD-ÇDGKA özel bir durumu olarak düşünülebileceği görülmektedir. Daha yüksek gürültü amplitüdlere için, görsel uyarıya karşılık gelen modda mod karıştırma görülür. Bu durum, aşırı giriş gürültü gücü nedeniyle GD-ÇDGKA'nın veri te-



Şekil 4.7: ÇDGKA kullanarak EEG sinyalinin ÖKF'lerine açılımı

melli doğasının kaybedilmesine sebep olabilir. GD-ÇDGKA 'den elde edilen ÖKF'lerin daha sıklıkta lokalize olduklarını ve ÖKF frekans dağılımları arasında daha büyük bir ayırım olması, denemeler arasında çıkarılan EEG bileşenleri modelinde daha iyi bir tutarlılık olduğunu ve bu bileşenlerin daha iyi ayrıldığını göstermektedir. Filtre bankı yapısı ve ÖKF açılımları incelendiğinde, filtre bankı yapısındaki farklılıklar ÖKF 5 den başlayarak sezilmektedir. Ancak, aradaki farkın daha iyi anlaşılması için, GD-ÇDGKA ve ÇDGKA kullanılarak elde edilen ÖKF açılımlarının farkları alındığında aslında farkın ilk ÖKF den başladığı, GD-ÇDGKA mod hizalamanın yanı sıra, sinyalin doğasında bulunan diğer salınımları da açığa çıkardığı **Şekil 4.10:** de görülmektedir. Buna göre, GD-ÇDGKA yönteminin duygu durum sınıflandırma çalışmalarında ÇDGKA dan daha iyi sonuçlar vereceği öngörülmektedir.


Sonuçlara bakarak, sınıflandırmada GD-ÇDGKA ve ÇDGKA algoritmasında $V=128$ alınmasının mod karıştırma açısından daha iyi sonuçlar verdiği görülmektedir. $V=32$ yada $V=64$ yön sayıları ile yapılan simülasyon sonuçları mod karıştırmaya daha meyillidir. Ek



Şekil 4.8: GD-ÇDGKA'yi bir filtre bankası olarak kullanırken, kullanılan 26 kanalda her ÖKF için iyi tanımlanmış anlık frekansların gösterimi ve mod karıştırma durumu çözümü

olarak, fark kanalları olarak kullandığımız, çalışmada kullanılan sağ ve sol frontal lob kanal farkları çıkarılarak simülasyon sonuçlarına bakıldığında, kanal fazlalığının önemli bir mod karıştırma olayına yol açmadığı hem ÇDGKA Şekil 4.15:'de algoritma simülasyon sonucunda, hem GD-ÇDGKA Şekil 4.14:'de algortima simülasyon sonucunda görülmektedir. Şekil 4.13:'deki simülasyon sonucuyla Şekil 4.8:' deki simülasyon sonucunda farklı kişiler kullanılmasına rağmen ÖKF'lerde mod karıştırma işleminin ÖKF 5'den başlayarak fark edildiğine diğer bir örnektir.

Bu çalışmada, duygu durumu sınıflandırmada, yüksek-düşük değerlik, aktivasyon, baskınlık sınıflandırması için sınıflandırıcı olarak Matlab Classification Learner Tool'u içerdiği DVM, KA, EYKS ve TS sınıflandırıcıları kullanılmıştır. Kullanılan sınıflandırıcılardaki seçilen yöntemler ise Fine Gaussian, Complex Tree, Weighted k-NN ve Subspace k-NN dir. Sonuçlar Tablo 4.4:'de sunulmuştur (Ozel ve diğ., 2018a). Sonuçlar yüzde (%) olarak verilmiştir.




Şekil 4.9: GD-ÇDGKA kullanarak EEG sinyalinin ÖKF'lerine açılımı

Tablo 4.4: GD-ÇDGKA ve ÇDGKA algortima sonucu elde edilen ÖKF lerin özneliliklerinin DVM, KA, EYKS, TS kullanarak sınıflandırılması.

Yüksek-Düşük	Değerlik	Aktivasyon	Baskınlık	Yöntem
DVM	60.9	55.5	63.5	CDGKA
DVM	63.1	56.4	66.2	GD-CDGKA
KA	66.3	65.0	69.7	CDGKA
KA	68.4	67.2	71.9	GD-CDGKA
EYKS	67.3	71.6	72.1	CDGKA
EYKS	70.0	73.8	74.2	GD-CDGKA
TS	66.4	69.6	70.0	CDGKA
TS	68.1	72.3	72.5	GD-CDGKA

ÇDGKA tabanlı duygu durum analizi çalışmaları göz önüne alındığında, GD-ÇDGKA yöntemi ile açığa çıkarılan ÇDGKA'nin yöntemi kullanımı sırasındaki gömülü salınımların ortaya çıkarılarak kullanımı için önemlidir. Buna göre, bu çalışmada k-NN Sınıflandırıcısını kullanan yüksek / düşük değerlik, aktivasyon ve baskınlık (ortalama % 72.6)




Şekil 4.10: GD-ÇDGKA ve ÇDGKA kullanarak EEG sinyalinin ÖKF'lerine açılımlarının farkları


boyutunda sırasıyla % 70.0, % 73.8 ve % 74.2 en iyi sonuçları elde edildi.

Guitton (2010) çalışmasında, ÇDGKA ile birlikte kullanılan Eşzamanlı Kümeleme Analizi (EKA) (ing- Synchrony Cluster Analysis (SCA)), Frekans Akımları Analizi (FAA) (ing- Frequency Flows Analysis (FFA)) ve spectrogram sonuçlarında ÖKF'ler üzerinde hesaplanan EKA kullanılarak yapılan en yüksek doğruluk oranı DVM sınıflandırıcı ile % 73.0 tür (Guitton, 2010). Mert ve Akan ise, Hjorth parametrelerini, entropi, güç, GSY, korelasyon ve asimetri güç farkı, güç oranları, relative entropi, korelasyon yöntemleri ile ÇDGKA 'den elde edilen ÖKF'lerin özniteliklerini zenginleştirerek, YSA sınıflandırıcı ile en iyi %75.00 7.48, YSA doğruluk oranlarını elde etmiştir (Mert ve Akan, 2018). Sunulan yöntem çalışmanın ÇDGKA süreci sırasında gömülü osilasyonları kullandığı ve sınıflandırmada OKF zaman-frekans dağılımına odaklanırken, gösterirken, Mert ve Akan'ın, ÇDGKA yöntemiyle elde edilen ÖKF'lerden elde edilen yeni öznitelikleri bir araya getirerek faydalanmaları açısından farklıdır.

Gerçek duygu durumu EEG verisini işlerken GD-ÇDGKA tarafından sağlanan iyileş-




Şekil 4.11: GD-ÇDGKA'yi bir filtre bankası olarak kullanırken, kullanılan 26 kanalda her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu çözümü ($V=64$)




Şekil 4.12: GD-ÇDGKA'yi bir filtre bankası olarak kullanırken, kullanılan 26 kanalda her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu çözümü ($V=32$)


tirmelerin, çıktındaki artık gürültünün azalması, eklenen gürültüye duyarlılığın azalması ve gelişmiş frekans lokalizasyonu açısından, ÇDGKA'na göre uygulanabilir bir alterna-




Şekil 4.13: GD-ÇDGKA'yi bir filtre bankası olarak kullanırken, kullanılan 26 kanalda her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu çözümü ($V=128$)



Şekil 4.14: Fark kanalları kullanılmadan (ilk 18 kanal kullanılarak) , GD-ÇDGKA'yi bir filtre bankası olarak kullanırken, her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu çözümü



Şekil 4.15: Fark kanalları kullanılmadan (ilk 18 kanal kullanılarak) , ÇDGKA'yi bir filtre bankası olarak kullanırken, her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu




Şekil 4.16: ÇDGKA'yi bir filtre bankası olarak kullanırken, her ÖKF için iyi tanımlanmış anlık frekansların göstermi ve mod karıştırma durumu (V=128)

tif ve avantaj oluşturduğunu gösterilmiştir. Hem TGKA hem de GD-ÇDGKA de dahil olmak üzere gürültü destekli yöntemlerin, çift kutuplu filtre bankası ayrışmasının sinyaller için yararlı olacağı aşikardır. Ancak, istenilen sinyalde birden çok diyalik alt bantda bulunuyorsa, analiz için gürültüye dayalı yöntemleri seçmek, istenen sinyali birden fazla ÖKF'ye yayabilir ve böylece istenmeyen mod karıştırma sonucunu doğurabilir. Bu gibi durumlarda, giriş sinyalinde bir diyalik filtre bankı yapısının uygulanması, GKA tabanlı algoritmaların kendine has veri uyarlamalı yeteneğini azaltabilir. Dolayısı ile giriş verisine uygun varyansa sahip gürültü seçmek son derece önemlidir. Analizlerimiz, GD-ÇDGKA için en uygun gürültü seviyelerinin, giriş veri gücünün (varyans) % 2-10 aralığında olduğunu göstermektedir. Ayrıca, GD-ÇDGKA'nın standart ÇDGKA yaklaşımından daha iyi performans göstermediği veya daha kötü performans göstermediği verilerle de karşılaşılmıştır, bu durumun özeti olarak kullandığımız 10. kişi 20. video dinletisi verisi **Şekil 4.6:**, **Şekil 4.7:**, **Şekil 4.8:**, **Şekil 4.9:**, **Şekil 4.10:** ve 12. kişi 10. video dinletisi **Şekil 4.11:**, **Şekil 4.12:**, **Şekil 4.13:**, **Şekil 4.14:**, **Şekil 4.15:**, **Şekil 4.16:** verisi simülasyonların da olduğu gibi belirgin farklardan ziyade ÖKF hizalamalarına ve mod karışmalarına dikkat edilerek çıkan sonuçlardan kaynaklanan durumlara benzemektedir. Yine de bu belirsizlik gibi görünen durumlar olmasına rağmen, sınıflandırma sonuçlarında GD-ÇDKA algortması ÇDGKA algoritmasına göre daha iyi sonuç vermiştir. Ek olarak, sınıflandırmanın algoritmasının yapısından dolayı her farklı seferde çalıştırdığımızda, özellikle aktivasyon ve baskınlık değerleri için- birbirine çok uzak olmasa da- farklı sonuçlar elde edilmiştir. ÇDGKA'da varsayılan yön vektörü anlamlı ÖKF ler çıkaracak şekilde 64 olarak seçilmiştir. Yön vektörü sinyallerin boyutlamasından belirgin derecede daha büyük olmalıdır. **Şekil 4.11:**, **Şekil 4.12:**, **Şekil 4.13:**, **Şekil 4.14:**, **Şekil 4.15:**, **Şekil 4.16:**' de görülen simülasyon sonuçlarında yön vektörünün 128 olarak seçilmesinin daha anlamlı ÖKF sonuçları elde edilmesine katkı sağladığı görülmektedir. Ancak, Bölüm 3.1.1.2.'de de ifade edildiği gibi yön vektörünün büyük seçilmesi istenilen bir ayrışma sağlayacağını garanti etmeyeceği için yön vektörü seçiminde dikkatli olunmalıdır. Hem yön vektörü 128 seçilerek hem de GD-ÇDGKA kullanarak optimum sonuçlar elde edilmiştir. Yön sayısının büyük seçilmesinin dezavantajı ise, yön sayısı arttıkça sinyali dekompoze etmek için harcanan süre de artmaktadır. Özet olarak, EEG verileri gibi çoğu gerçek sinyaller, nadiren saf salınımlar veya dönüşler sergiler ve dolayısıyla duygu durumu sınıflandırmada EEG verileri ve GD-ÇDGKA algoritması ile iyi derece de eşleşmektedir.

4.2.0.1. Değerlendirme

GD-ÇDGKA kullanarak, duygu durum analizinde çok değişkenli GKA kullanmanın faydası gösterilmiştir. Yöntemin esnek olduğu ve analiz sonucunda fiziksel olarak anlamlı bileşenlerinin üretildiği ve bu sayede eklenen gürültünün gücünün algoritmanın çalışmasını kontrol ettiği EEG sinyalleri analiz sonucu elde edilen ÖKF açılımlarında da görülmektedir. GD-ÇDGKA'nın mod-sıralaması ve filtre bankası özelliği örneklerle gösterilmiştir. Frekans lokalizasyonu, gürültü girişim ve mod karıştırma açısından, standart ÇDGKA yöntemiyle karşılaştırıldığında GD-ÇDGKA yönteminin kullanışlılığını göstermek için performans değerlendirmeleri sağlanmıştır. Ancak, yöntemin dezavantajı ÇDGKA'ye göre EEG verilerinin bütün kanallarının varyansını bulup, % 2-10 arasında değişen varyans gürültüsü ekleme işleminin son derece kontrollü yapılması gerektiği ve vakit aldığıdır. Birçok uygulamada çok değişkenli sinyal işleme yaklaşımının tercih edilen bir yöntem olduğu belirtilmelidir. Bu açıdan, EEG verileri doğal olarak çok değişkenlidir ve farklı kanalları arasında önemli bir bağ oluştururlar. Bu tür veri setlerinden fiziksel olarak anlamlı bir sonuç almak için, gözlemlenen tüm değişkenlerin benzer ölçeklerde ÖKF bileşenleri ile aynı sayıda ayrıştırılması istenir. Bu gibi durumlarda, GD-ÇDGKA uygulaması, tek değişkenli GKA ve TGKA yöntemlerine göre kanal bazında büyük avantajlar sağlar. ÇDGKA karşılaştırıldığında GD-ÇDGKA yöntemi daha iyi sonuçlar vermektedir ancak GD-ÇDGKA tercih edilmesi kullanıcının yöntem üzerinde hakimiyeti ve yeterli zamana sahip olması ile doğru orantılıdır. Sonuç olarak, çok değişkenli verilerin analizi için, duygu durum sınıflandırma alanında ÇDGKA üzerinde GD-ÇDGKA metodunun avantajları, standart GKA'nın temel sorunları - frekans lokalizasyonu, gürültü girişim ve mod karıştırma- kullanılarak gösterilmiştir. Ayrıca, EEG analizinde GD-ÇDGKA kullanarak bu yöntemin durağan olmayan ve çok kanallı yapısı, sabit baz fonksiyonunu kullanan yöntemlerle ilgili belirsizliği aşma becerisini açıklayabilmekteki başarısı gösterilmiştir. Çalışmanın devamı açısından, GKA filtrelemesinde, ideal bir alçak geçiren filtreden uzak olan GKA'nın eşdeğer enterpolasyon filtresi (örneğin bir kübik spline), daha fazla örtüşme oluşturması sorunu vardır ve daha uygun GKA filtreleri çalışılabilir. Ek olarak, daha fazla ÖKF den faydalanmak için ÖKF lerdeki mod karışımlarını azaltarak, ÖKF salınımlarını belirginleştirerek yeni fikirler geliştirilebilir.

4.3. ÇDGKA-ÇÇA VE ÇDGKA-SSD DOMENİNDE ÇOK KANALLI EEG SİNYALLERİNDEN DUYGU DURUM ANALİZİ



Şekil 4.17: ÇDGKA-(ÇÇA&SSD) domenlerinde önerilen duygu durum analizi

Önerilen duygu tanıma yöntemi genel olarak iki temel adımdan -özellik çıkarma ve sınıflandırma - dan oluşmakla birlikte, temel amaç Alfa, Beta, Teta, Delta, Gama beyin sinyallerinin duygu durum sınıflandırmasına katkısını görmektir. Yöntemin aşamalarının blok diyagramı **Şekil 4.17:**'de gösterilmektedir. ÇDGKA algoritmasının veriye bağımlı ve filtre bankası yapısı nedeniyle ÖKF'ler birbirinden farklıdır. Bu şekilde, her bir ÖKF'nin bant genişliği farklıdır en yüksek frekansa sahip ilk ÖKF'den en düşük frekansa sahip son ÖKF'ye kadar elde edilen tüm salınımlar, ÇDGKA'nın filtre bankası özelliği ile elde edilir. Bu çalışmanın temel dayanağı, algoritmanın ÇDGKA'nın sonucu olan ÖKF'lerin farklı frekans aralıklarında salınımlara sahip olması ve bilinen beyin sinyalleri ile daha spesifik bilgilere ulaşılabileceği öngörüsüdür. Diğer taraftan, ÇÇA'da farklı dalgacıkların da EEG sinyalleri üzerinde farklı etkileri vardır.

Ek olarak, önerilen yöntemdeki çok kanallı EEG sinyalleri için, sinyaldeki sinyallerin sürekli değişimlerinin katkısı, farklı özniteliklerin kullanılmasıyla, en önemli ilk dört ÖKF'nin ÇÇA'leri hesaplanarak değerlendirilmiştir. ÇDGKA-ÇÇA işleminde, ÇDGKA'nın her bir katılımcıya oynanan 40 farklı videoda kaydedilen EEG sinyallerine ulaştıktan sonra alınan ÖKF'lere ÇÇA uygulayarak Alfa, Beta, Delta, Gama ve Teta alt bantları olarak frekans bantlarına bölünür. Elde edilen her bir alt bant matrisi, 40 adet 1x4 hücre içerir. Elde edilen bu hücre dizileri, birinci ÖKF'den sonraki ÖKF'ye kadar olan, sırasıyla, seçilen dalgacık fonksiyonu (db8 (Daubechies 8 wavelet), db4 (Daubechies 4 wavelet), coif5 (Coiflet 5 wavelet), sym8 (Symlet 8 wavelet) nedeniyle detay katsayılarını içerir. Özet olarak, bu hücrelerin her biri Alfa, Beta, Delta, Gama, Teta alt bantları için farklı diziler içerir. Bu diziler boyut indirgeme metodu uygulanmamıştır çünkü boyutları sınıflandırılmak için yeterince veri içermektedir. Önerilen duygu tanıma yöntemi, Bölüm 2.1. da nörobilimsel bulgularla çalışılmış Alfa, Beta, Delta, Teta ve Gama beyin dalgaları için literatürde yapılan çalışmalar referansı ile sinyal işleme odaklı yeni bir yaklaşım geliştirme potansiyeline sahiptir. Buna göre çalışmanın amacı nörobilimsel bulgulardan farklı olarak CDGKA tabanlı yeni bir yaklaşım sunarak duygu durum analizi yapmak ve de OKF dan elde edilen senkrosıkıştırma katsayısı ile elde edilen öznitelik vektörünü ile duygu durum sınıflandırması gerçekleştirmektir. Genel olarak bu çalışmada da iki temel adımdan -özellik çıkarma ve sınıflandırma - dan oluşur. Önerilen yöntemin aşamalarının blok diyagramı **Şekil 4.17:**'de gösterilmektedir.

Tablo 4.5: Alfa beyin dalgacığında Db4 fonksiyonu kullanılarak yüksek / düşük aktivasyon değeri, baskınlık boyutları için doğruluk oranları.

Db4	Aktivasyon	Değerlik	Baskınlık
Alfa	54.9	52.0	55.8
	57.4	56.5	54.9
	57.2	61.6	54.7
	64.6	54.1	73.5
Ortalama	59.1	54.1	54.9

Tablo 4.6: Beta beyin dalgacığında Db4 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değeri, baskınlık boyutları için doğruluk oranları.

Db4	Aktivasyon	Değerlik	Baskınlık
Beta	57.7	56.0	54.5
	60.1	61.6	59.2
	61.9	58.7	57.1
	63.2	51.6	73.4
Ortalama	57.5	53.9	54.9

4.3.0.1. Değerlendirme

Önerilen yöntemimizde ilk basamakta, ilk dört ÖKF için salınımın Alfa, Beta, Delta, Gama, Teta frekans bantlarını veren ÇDGKA-ÇÇA tabanlı bir süreçten faydalanıldı. Bu işlemin sonucunda, Matlab Classification Learner Tool'da k-NN sınıflandırıcı kullanılarak sınıflandırma işleminde (yüksek / düşük) aktivasyon, değeri, baskınlık düzeyleri için doğruluk oranlarını incelenmiştir. Buna göre, Alfa, Beta, Delta, Gama, Teta beyin dalgaları ve db4, db8, sym8 ve coif5 dalgacık fonksiyonları ile elde edilen yüksek / düşük aktivasyon, değeri, baskınlık boyutları için doğruluk oranları **Tablo 4.5:** - **Tablo 4.24:** arası sunulmuştur. Sonuçlar % olarak sunulmuştur.

Buna göre, hemen hemen tüm dalgacık fonksiyonu için en önemli sonuçlar Gama bantlarında elde edilmiştir. Bununla birlikte, Alfa aralığında en yüksek doğruluk oranları sym8 ve coif5 fonksiyonlarında elde edilmiştir. Benzer şekilde, Beta, Delta, Teta frekans bantları için sınıflandırma oranları, sym8 ve coif5 fonksiyonlarında db4 ve db8 fonksiyonlarından nispeten daha iyi olduğu görülmektedir. Öte yandan, çalışmamızda değeri kat-

Tablo 4.7: Teta beyin dalgacığında Db4 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Db4	Aktivasyon	Değerlik	Baskınlık
Teta	54.2	52.3	52.8
	54.0	57.7	53.6
	56.9	59.2	59.6
	52.9	54.2	64.6
Ortalama	55.2	53.9	54.7

Tablo 4.8: Gama beyin dalgacığında Db4 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Db4	Aktivasyon	Değerlik	Baskınlık
Gama	70.0	58.4	65.8
	68.4	67.2	67.7
	52.7	67.1	64.2
	70.6	54.6	75.6
Ortalama	71.3	63.7	68.6

Tablo 4.9: Delta beyin dalgacığında Db4 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Db4	Aktivasyon	Değerlik	Baskınlık
Delta	52.8	55.2	53.4
	54.1	54.5	51.0
	52.0	57.4	57.3
	54.8	53.1	64.8
Ortalama	54.4	54.4	54.3

Tablo 4.10: Alfa beyin dalgacığında Db8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Db8	Aktivasyon	Değerlik	Baskınlık
Alfa	60.9	51.0	56.3
	60.6	61.1	56.1
	61.9	59.4	61.5
	62.9	56.1	71.1
Ortalama	59.9	56.7	56.7

Tablo 4.11: Beta beyin dalgacığında Db8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Db8	Aktivasyon	Değerlik	Baskınlık
Beta	65.9	53.7	55.8
	59.2	64.3	60.5
	64.0	58.0	63.6
	61.0	56.3	69.1
Ortalama	61.9	57.0	59.0

Tablo 4.12: Teta beyin dalgacığında Db8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Db8	Aktivasyon	Değerlik	Baskınlık
Teta	59.0	51.1	51.5
	59.3	56.5	52.6
	54.8	58.7	59.8
	56.0	53.0	63.9
Ortalama	57.2	54.0	56.5

Tablo 4.13: Gama beyin dalgacığında Db8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Db8	Aktivasyon	Değerlik	Baskınlık
Gama	71.2	57.9	64.8
	64.6	57.4	67.3
	74.8	67.3	65.3
	69.8	64.2	75.7
Ortalama	71.2	63.7	67.7

Tablo 4.14: Delta beyin dalgacığında Db8fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Db8	Aktivasyon	Değerlik	Baskınlık
Delta	54.8	51.1	50.2
	67.6	54.4	67.5
	54.9	61.4	59.8
	57.0	53.9	66.6
Ortalama	54.8	54.7	54.4

Tablo 4.15: Alfa beyin dalgacığında Sym8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Sym8	Aktivasyon	Değerlik	Baskınlık
Alfa	62.6	53.0	56.1
	61.3	57.0	57.4
	63.7	61.2	59.5
	62.7	56.0	72.3
Ortalama	62.5	56.1	58.0

Tablo 4.16: Beta beyin dalgacığında Sym8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Sym8	Aktivasyon	Değerlik	Baskınlık
Beta	63.0	52.2	57.3
	59.9	62.5	59.6
	67.5	60.2	61.3
	59.7	54.7	70.8
Ortalama	62.0	58.6	60.0

Tablo 4.17: Teta beyin dalgacığında Sym8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Sym8	Aktivasyon	Değerlik	Baskınlık
Teta	57.4	49.5	54.9
	55.5	58.0	54.6
	60.5	60.0	62.5
	55.2	51.9	63.7
Ortalama	56.6	54.0	56.1

Tablo 4.18: Gama beyin dalgacığında Sym8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Sym8	Aktivasyon	Değerlik	Baskınlık
Gama	70.4	57.7	64.0
	68.4	67.3	67.8
	74.2	63.0	64.4
	70.6	63.4	73.0
Ortalama	71.2	62.8	67.6

Tablo 4.19: Delta beyin dalgacığında Sym8 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Sym8	Aktivasyon	Değerlik	Baskınlık
Delta	57.1	49.3	49.9
	56.0	60.9	50.7
	63.9	58.5	57.9
	55.4	54.5	74.5
Ortalama	55.8	53.9	53.0

Tablo 4.20: Alfa beyin dalgacığında Coif5 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Coif5	Aktivasyon	Değerlik	Baskınlık
Alfa	61.6	53.6	57.0
	63.0	62.5	57.0
	59.5	61.2	62.3
	63.4	54.7	70.1
Ortalama	60.4	57.5	58.2

Tablo 4.21: Beta beyin dalgacığında Coif5 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Coif5	Aktivasyon	Değerlik	Baskınlık
Beta	61.3	51.6	57.3
	62.5	61.3	59.3
	61.8	60.4	60.2
	59.7	55.5	68.2
Ortalama	61.1	57.2	59.1

Tablo 4.22: Teta beyin dalgacığında Coif5 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Coif5	Aktivasyon	Değerlik	Baskınlık
Teta	57.3	50.1	53.0
	56.3	67.2	53.2
	73.3	61.0	63.4
	54.9	53.0	65.5
Ortalama	61.1	57.2	59.1

Tablo 4.23: Gama beyin dalgacığında Coif5 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Coif5	Aktivasyon	Değerlik	Baskınlık
Gama	70.7	57.5	65.5
	69.0	67.7	65.6
	74.8	67.7	64.4
	70.0	62.5	75.4
Ortalama	71.2	64.0	67.5

Tablo 4.24: Delta beyin dalgacığında Coif5 fonksiyonu kullanılarak yüksek / düşük aktivasyon, değerlik, baskınlık boyutları için doğruluk oranları.

Coif5	Aktivasyon	Değerlik	Baskınlık
Delta	61.4	52.3	51.0
	59.2	2.5	52.3
	53.4	58.9	59.3
	54.9	55.0	64.6
Ortalama	55.1	54.5	54.7

sayısı doğruluk oranı genel olarak daha düşük olmakla birlikte, en tatmin edilen değerler yine Gama frekans aralığına aittir. Özet olarak, bizim çalışmamız, özellikle sonraki dördüncü ÖKF ile Alfa, Beta, Teta, Gama ve Delta frekans bandı için baskınlık düzeyi sınıflandırması için en iyi sonucu vermiştir. Dolayısı ile bu çalışma da iki dikkat çekici sonuç elde edilmiştir. İlk olarak, ÖKF’lerde 3. veya 4. ÖKF duygu durum sınıflandırma sonuçları diğer ÖKF’lere ve ilk dört ÖKF ortalamasına göre daha iyi sonuç vermektedir. Bu durum da, Bölüm 2.3.1. de bahsedilen ve (Cho *ve diğ.*, 2014) çalışmasında sunulan gücü ve harmonikliği yüksek ÖKF’lerinin seçiminin doğruluğuna işaret etmektedir. Ayrıca, son yıllarda Gama dalgacığı ile ilgili spesifik çalışmalar yapılmaktadır (Zhuang *ve diğ.*, 2018; Li ve Lu, 2009; Ozel *ve diğ.*, 2018c). Buna göre bu çalışma Gama bandı sonuçlarının daha yüksek olduğunu göstererek, Gama beyin dalgası için daha spesifik çalışmalara ihtiyaç olduğunu göstermektedir.


Bu çalışmada önerilen diğer yöntemde ise (Ozel *ve diğ.*, 2018e), DEAP veritabanındaki ilk 5 kişiye izletilen ilk 5 video ile diğer çalışmalarımızda kullanılan aynı kanal düzeni kullanılarak 26 girişlik kanal düzeni ÇDGKA algoritmasına verilmiştir. Algoritma sonucu elde edilen ÖKF’lerden ana sinyal ile korelasyonu en yüksek ÖKF sinyali seçilip SSD al-

Tablo 4.25: Aktivasyon- Değerlik ve Baskınlık Parametreleri ile CDGKA-SSD yönteminde sınıflandırma oranları.

Doğruluk Oranı	Aktivasyon	Değerlik	Baskınlık
Karar Ağacı	72.0	36.0	44.0
Destek Vektör Makinesi	76.0	68.0	68.0
En Yakın Komşu Sınıflandırıcı	76.0	60.0	68.0
Topluluk Sınıflandırıcı	71.0	60.0	56.0

goritması uygulanmıştır. Sonrasında elde edilen senkrosıkıştırma katsayılar sınıflandırma sürecinde kullanılmıştır.

Çalışmada EEG sinyallerinden duygu durum analizi gerçekleştirebilmek amacı ile ÇDGKA ve SSD yöntemleri bir arada kullanılarak yeni bir model önerilmiştir. Sınıflandırma sonuçları çevrim dışı, kullanıcı bağımsız olmak üzere DEAP veritabanı kullanılarak değerlendirilmiştir. % olarak sunulan **Tablo 4.25:**'de elde edilen değerlere göre en iyi sınıflandırma sonuçları uyarılma düzleminde elde edilmiş olup, en iyi sınıflandırıcı sonuçları destek vektör makinesi ve en yakın komşu sınıflandırıcıda elde edilmiştir. Buna göre karar ağacı sınıflandırıcısının değerlik ve baskınlık sınıflandırıcı sonuçları tatmin edici bulunmamıştır. Sınıflandırma sonuçları uyarılma boyutu için %75 civarı değişirken, baskınlık ve değerlik boyutlarında bu değer %65 dolaylarındadır. İlerleyen çalışmalarda SSD algoritmasından özgül kip türleri (ÖKT)'lere elde edilerek sınıflandırma sonucu değerlendirilecektir.



Şekil 4.18: Adaptif ortogonal sinyal ayrıştırma temelli duygu durum analizi için önerilen yöntemin şeması

4.4. ADAPTİF ORTOGONAL SİNYAL AYRIŞTIRMA TEMELLİ DUYGU DURUM ANALİZİ

Bu çalışmada, araştırmada yararlanılan DEAP veri setindeki 16 denekten oluşan 40 video dinletisinin EEG sinyalleri dikkate alınarak, her bir katılımcı için 16 kanallı veri (16x40x8064) kullanılmıştır. Dinletilen her video için 8064 veri örneği seçilmiştir. Burada kullanılan 16 kanal, sol lobdaki (Fp1, AF3, F3, F7, FC1, FC5, T7, C3), sağ lob (Fp2, AF4, F4, F8, FC2, FC6, T8, C4) kanallardır. Bu kanalları içeren veriler, **Şekil 4.18:**'de gösterildiği gibi, ÇDGKA algoritmasına bir girdi olarak verilmiştir. Böylece, sonuç olarak edinilen veri seti, her bir müzik videosu için yaklaşık 16x15x8064 boyutuna sahiptir. Yani, her katılımcı için aynı boyutta 40 adet veri elde edilmiştir. Bu noktada, orta sayı, ÖKF'lerin miktarını gösterir. Çalışmadaki, ÖKF sayılarımız 13 ile 17 arasında değişmektedir. Bununla birlikte, farklı video inceleme deneylerinde ortalama ÖKF sayısı 15'tir ve **Şekil 4.18:**'de, görsel algı için temsil edilen ortalama ÖKF sayısı 15 olarak belirlenmiştir.

Diğer taraftan, Bölüm 2.1. de ifade edildiği gibi, GKA tarafından ayrıştırılan ÖKF'ler ortogonal olmadığı veya yarı ortogonal olması sınırlaması tartışılmıştır ve ÖKF'lerin ortogonal bileşenlerini Gram-Schmidt Ortogonalleştirme yöntemi ile seçmek bu çalışmada bir çözüm olarak önerilmiştir. Bu nedenle, bu çalışmada da ÇDGKA ile elde edilen tüm ÖKF'ler, ÖKF'lerde ortogonal bileşenlerin sayısını hesaplamak için Gram-Schmidt Ortogonalleştirme Yöntemi'ne tabi tutulur. Hesaplanan bileşenler, GDD'yi çalıştıracak modlarının miktarını sunar. Bu nedenle, tüm bazların GDD prosesinde süper ortogonal olması koşuluyla, bir sinyal ayrıştırması gerçekleştirilir. Özetle, ortogonal bir ÇDGKA sunmak için, ÇDGKA algoritmasını, ÇDGKA için sonuçların getirdiği ÖKF'ler ile önemli öz-nitelikleri ortogonallestiren Gram-Schmidt optimizasyon yöntemiyle birleştirilmektedir. Daha sonra, yöntemin optimize edilmiş ortogonal ÖKF'leri, sınıflandırma işlemi için bir matematik temeli içinde bir ürün elde etmek amacıyla GDD algoritmasına verilir. Ayrıca, kanal seçiminin karmaşıklığını ve duygu durum analizinde kanal katkısının her birini çözmek için bu önerilen yöntemle ayrı olarak kullanılan kanallar da incelenecektir. Kanal seçimi için tartışılacak çalışmalar **Tablo 2.1:** ve **Tablo 2.2:** de gösterilmiştir.

4.4.0.1. Değerlendirme

Önerilen çalışmada amaç (Ozel ve diğ., 2018b), duygusal modellemede seçilen kanal katkılarını ortaya çıkarıp yeni bir hibrid öz-nitelik çıkarma metodu önermektir. Öz-nitelik yön-

Tablo 4.26: Karar Ağacı Sınıflandırıcısı kullanarak Duygu Durum sınıflandırma doğruluk oranları.

Yüksek/Düşük	Aktivasyon	Değerlik	Baskınlık
Fp1	63.4	53.3	58.4
AF3	68.0	55.6	59.8
F3	69.4	55.6	60.0
F7	71.4	59.2	60.0
FC5	70.0	59.5	59.7
FC1	72.3	60.3	58.8
C3	68.8	56.1	59.5
T7	65.5	55.3	58.9
Fp2	65.3	52.7	60.3
AF4	71.6	56.1	58.0
F4	67.3	53.9	59.5
F8	68.6	55.2	61.9
FC6	68.3	53.3	61.4
FC2	68.4	55.5	61.6
C4	71.3	60.3	64.5
T8	68.4	59.4	60.8

temimizin gerekçelerini özetlenerek, kanalları ayrı ayrı değerlendirmenin öngörülen katkıları Bölüm 2.2. ve **Tablo 2.1:** ve **Tablo 2.2:** de sunulmuştur. Buna göre, Bölüm 2.2. de ifade edildiği gibi EEG Kanal azaltma işlemi için öznelitik seçim yöntemlerini kullanan önceki çalışmalar genel olarak aynı kanal gruplarını içermemektedir. Bu nedenle, bu çalışmada seçilen nöro-bilimsel bilgi tabanlı kanallar, yeni bir öznelitik çıkarma işlemi sunarak ayrı ayrı değerlendirilecektir. **Tablo 4.26:** ve **Tablo 4.27:**'de yüzde % olarak sunulan doğruluk oranına ilişkin sonuçlar göz önüne alındığında, uyarılma, değerlik ve baskınlık etiketleri için yüksek / düşük sınıflandırma performansları hesaplanmıştır. Sonuçlara göre, KA sınıflandırıcısında en yüksek sınıflandırma sonucu FC1, AF4 ve F7 kanalları yüksek düşük aktivasyon etiketi için % 72.3, % 71.6, %71.4, FC1, C4, FC5 kanalları yüksek değerlikli etiket için % 60.3, % 60.3, % 59.5 ve C4, F8, FC2 kanalları yüksek düşük baskınlık etiketi için, % 64.5, % 61.9, % 61.6'dır. Benzer şekilde, Topluluk sınıflandırıcı sınıflandırıcısı FC1, C4, T8 kanalları yüksek-düşük aktivasyon etiketi için % 72.7, % 72.7, % 71.3, F7, C4, T8 kanalları yüksek-düşük değer etiket için % 62.0, % 61.1, % 58.0 ve C4, FC2, FC1 kanalları yüksek düşük baskınlık etiketi için % 64.7, % 63.3, % 63.3'tür.

Duygu durumu analizi son zamanlarda önemli gelişme sağlamıştır. Daha önceki çalış-

Tablo 4.27: Topluluk Sınıflandırıcı Sınıflandırıcısı kullanarak Duygu Durum sınıflandırma doğruluk oranları.

Yüksek-Düşük	Aktivasyon	Değerlik	Baskınlık
Fp1	64.1	52.3	58.6
AF3	68.9	53.3	58.0
F3	69.7	56.3	61.1
F7	70.9	62.0	59.4
FC5	66.6	54.7	57.7
FC1	72.7	57.8	63.3
C3	70.3	53.6	58.9
T7	66.7	52.0	60.5
Fp2	67.0	54.5	58.3
AF4	71.7	56.7	60.8
F4	68.1	54.8	60.8
F8	68.1	55.0	60.3
FC6	68.3	54.1	61.3
FC2	68.1	54.4	63.3
C4	72.7	61.1	64.7
T8	71.3	58.0	61.9

malarda, çok değişkenli geleneksel olmayan zaman-frekans yöntemlerine temel seviyede odaklanmışlardır. Şimdiye kadar ÇDGKA yöntemi ile EEG'den duygu tanıma özelliğinin çıkarılması için bir kaç inceleme sunulmuştur. Sunulan BU çalışmanın başlıca katkıları aşağıda özetlenmiştir:

İlk olarak, öznitelik çıkarma işleminden önce, farklı çalışmalarda bile farklı öznitelik seçim yöntemlerinin kullanıldığını, farklı kanalların seçiminin söz konusu olduğu incelenen çalışmalarla fark edilmiştir. Daha açmak gerekirse, (Bos, 2006; Al-Nafjan *ve diğ.*, 2017) çalışmalarında AF3, F3, F4, FPz kanallarının Alfa ve Beta güç performanslarını farklı formüllerle birleştiren en iyi aktivasyon ve değerlik sınıflandırma oranları incelenip ve önerilmişlerdir. Ayrıca Alarcoa ve Fonseca, yaptıkları çalışmada duygu tanıma tercihinde en çok kullanılan kanalların F4 (% 82.9), F3 (% 77.14), T7 (% 65.7), FP1 (% 65.7), FP2 (% 60) T8 (% 60), F7 (% 60), F8 (% 60), O1 (% 54.3), P7 (% 54.3), P8 (% 51.4), O2 (% 51.4), FC5 (% 40), FC6 (% 40), C4 (% 40), C3 (% 34.3), AF3 (% 34.3), AF4 (% 34.3), P3 (% 28.6), P4 (% 25.7) olduğunu belirtmektedir (Alarcao ve Fonseca, 2017). Ayrıca, Bölüm 2.2. de ifade edildiği gibi kanal seçiminin nümerik olarak yapıldığı çalışmalar, duygu tanıma için aynı kanal seçimini göstermediğini fark edilmiştir. Bu karmaşıklığı çözmek için, kanal seçimi için herhangi bir öznitelik seçim yöntemi eklemekten bir stan-

dart veri kümesi kullanarak inceleme yapmak gereklidir. Bu şekilde, kullanılan herhangi bir kanalın sınıflandırılma aşamasında gerçek katkısını ayırt etmek mümkündür. Bu çalışmada, nöro-bilimsel bilgiye (Fp1, AF3, F3, F7, FC1, FC5, T7, C3, AF4, F4, F8, FC2, FC6, T8, C4) bağlı olarak seçilen on altı kanaldan yararlanılarak sınıflandırma aşaması gözlemlenmiştir. En çok göze çarpan sınıflandırma performansı, kullanılan her iki sınıflandırma yönteminde aktivasyon etiketi için sırasıyla FC1, AF4 ve F7 kanallarına aittir. Yine de tüm etiket sonuçları göz önünde bulundurulduğunda C4 kanalı, diğer sonuçlarla karşılaştırıldığında en iyi sonuçları sağlar. Buna göre, TS tarafından kullanılan sonuçlar, KA Sınıflandırıcısından daha başarılı görünmektedir. Ek olarak, en yüksek sınıflandırma sonuçları aktivasyon etiketine aittir. Yine de, aynı veri kümesi üzerinde farklı öznelik çıkarma yöntemlerini ve farklı öznelik seçim algoritmalarını inceleyerek kanal katkısını anlamak için çok daha fazla çalışma gereklidir. Bu çalışmada, farklı öznelik çıkarma işlemi, (Jenke *ve diğ.*, 2014)' tarafından da belirtildiği gibi farklı kanallarda farklı sonuçlar verebileceği tahmin edilmektedir.

İkincisi, çok değişkenli algoritmaların kullanımından yararlanarak daha iyi sonuçlar sunmak belirlenen amaçlar arasındadır. Son yıllarda, GKA eksikliklerini ortadan kaldırmak için çeşitli çalışmalar yapılmakla birlikte ve bunlardan biri olan ortogonalite problemi. Literatürde, farklı ortogonalleştirme çalışmaları ile kombine GKA sunulmasına rağmen, herhangi bir ortogonalleştirme yöntemi ile birlikte ÇDGKA mevcut değildir. Bu şekilde, ÇDGKA ile ayrıştırılmış EEG sinyalleri, bu çalışmada çok değişkenli bir algortmada olabilecek bir eksikliği geliştirerek bir optimizasyon yöntemi ile bağlanmıştır. Bu nedenle, Ortogonal Çok Değişkenli Görgül Kip Ayrışımı olarak isimlendirilebilecek Gram-Schmidt Ortogonalleştirme Yöntemi'ne dayanan yeni bir metot önerilmiştir ve (Gilles *ve diğ.*, 2013) tarafından 2013 yılında önerilen yeni bir yöntem olan ve gelecekte zaman-frekans algoritmalarına kıyasla birçok avantajı olan GDD yöntemi öncesi ortogonal ÖKF'ler elde edilmiştir. Sonuç olarak, Ortogonal Çok Değişkenli Görgül Kip Ayrıştırma yöntemimiz Görgül Dalgacık Dönüşümü ile bir araya getirilmiştir. Tüm sinyallerin ortogonal olmasıyla GDD işleminde daha iyi ayrışmaya katkıda bulunulmuştur. Duyguların durum analizi için DEAP veri setinde EEG sinyali üzerinde incelemeler yapılmış ve yüksek / düşük etiketleme, aktivasyon ve değerlik etiketleri için tatmin edici sonuçlar elde edilmiştir. Bu nedenle, yöntem dikkat çekici seviyededir.

Üçüncüsü, bizim çalışmamızda, nörobilimsel bilgiye bağlı olarak seçilen on altı elektro-

dun sınıflandırma sonuçları, aktivasyon, değerlik seviyesine ek olarak, baskınlık düzeyi açısından da incelenmiştir. Bu nedenle, katkısı olan kanal sayısını seçerek baskınlık, aktivasyon ve değerlik seviyelerini bulmak, bu konuda yapılacak seviye kullanımına odaklanan başka çalışmalara katkıda bulunacaktır.

5. TARTIŞMA VE SONUÇ

Çok değişkenli sinyaller için kanallar arasındaki bağımlılıkları analiz etmek, birçok bilim ve mühendislik disiplini için son derece önemlidir. Bu tezde, duygu durum analizi için yeniden atama ve veri bağımlı zaman-frekans yöntemlerinin temelinde çok değişkenli verilerin analizi ve filtrelenmesi için modellerin geliştirildiği çalışmalar gerçekleştirilmiştir. Bu tezin motivasyonu, EEG gibi çok kanallı veri kaydının alınabildiği teknolojiler için çok kanallı fiziksel süreçlerin kayıtlarının mümkün olduğu sensör teknolojisindeki son gelişmelerle birlikte, özellikle çok kanallı zaman frekansı algoritmaları ve çok değişkenli sinyal işleme teknikleri ile birlikte kullanımının duygu durum modellemeye katkısını görmektir.

Çok değişkenli zaman-frekans analizindeki son gelişmeler, modüle edilmiş çok değişkenli osilasyon modelinin ve çok değişkenli görgül modelin geliştirilmesine neden olmuştur. ÇDGKA, çok değişkenli sinyallerin kanallar arası bağımlılıklarının daha etkin bir şekilde kullanıldığı gösterip, kanal boyunca benzer zaman-frekans karakteristiklerine sahip bir dizi modülasyonu salınımı tanımlamak için çok boyutlu uzayda çok kanallı sinyalleri doğrudan işler. Öte yandan, çalışmamızda kullandığımız modüle edilmiş çok değişkenli salınım modeli temelli ÇDSSD, çok değişkenli sinyallerin kompakt bir şekilde temsil edilmesiyle sonuçlanmasının yanında, çoklu kanal bağımlılıklarını dikkate alarak çok değişkenli sinyalin niteliklerini yakalayan tek bir osilasyon yapısı olarak karakterize eder. Esasında, ÇDSSD algoritması ÇDGKA algoritmasından esinlenerek, çok değişkenli veriler içerisindeki veri kanallarında ortak olan bir dizi modülasyonlu salınımı tanımlamak için zaman-frekans alanını bölümlere ayırmak suretiyle, senkrosıkıştırma dönüşümünün çok değişkenli bir uzantısını önerip sonrasında çok değişkenli veriler için ortak olan modüle edilmiş çok değişkenli salınımların tanımlandığı çok değişkenli bir zaman-frekans gösterimini oluşturmak için kullanılmıştır. Ek olarak, GKA' nın çok değişkenli uzantıları çok kanallı sinyallerin işlenmesinde büyük ölçüde önemli iken, bu algoritmanın sonucu ortaya çıkan ÖKF fonksiyonlarının daha işlevsel hale getirilmesi de işlem kapasitesini geliştirmek için önem taşımaktadır. Bu amaçla literatürde hibrid model sınıfında toplayabileceğimiz yeni modeller önerilmektedir. Bu bilgiler ışığında, bu tez çalışmasında dört

farklı çalışma gerçekleştirilmiştir.

- EEG Sinyalleri Yoluyla Duygu Durum Sınıflandırmada Çok Değişkenli Senkro Sıkıştırma Yöntemi Kullanımı: İlk çalışmada çok kanallı EEG sinyalleri ile duygu durum analizi için, ortak anlık frekans ve bant genişliği kavramlarından faydalanan ve çok kanallı sinyallerin ortak osilasyon yapısını modellemek için önerilen ÇDSSD'yi kullanarak zaman-frekans analizini gerçekleştirmenin yeni bir yöntemi sunulmaktadır. Çok değişkenli SSD algoritmasının fizibilitesi ve performansı, tek değişkenli versiyonunu ile karşılaştırarak, DEAP veri tabanından elde edilen EEG sinyalleri üzerinde gösterilmiştir. Duygu durumu sınıflandırma basamağında, aktivasyon-değerlik ve baskınlık boyutlarını birleştirerek sekiz duygu durum etiketi kullanılmıştır. Sınıflandırıcı olarak kullanılan DVM, EYKS, TS ve KA farklı kerneller ile ÇDSSD ve tek değişkenli versiyonu kullanılarak, tüm duygu durum etiketleri arasında en yüksek tahmin doğruluğu % 93'dür.
- Duygu Durum Analizi için EEG Sinyalleri Kullanılarak Gürültü Destekli Çok Değişkenli Görgül Kip Ayrıştırma Yöntemi: İkinci çalışmamızda, ÇDGKA algoritmasındaki çift kutuplu filtre özelliği iyileştirilerek, duygu durum sınıflandırmasına katkı sağlanmaya çalışılmıştır. Buna göre, ÇDGKA bir çok avantajına rağmen, tek değişkenli veriler için tasarlanmış olması, mod karıştırmaya eğilimli olması ve GKA işleminin başlayabilmesi için yerel ekstremum sayısının yeterli olması gibi dezavantajlara sahiptir. Bu dezavantajları minimuma indirebilmek için, bu çalışmamızda duygusal durum sınıflandırmasında çok değişkenli GKA ve gürültü destekli çok değişkenli GKA versiyonunu kullanmaktadır. Buna göre EYKS kullanılarak en iyi yüksek/düşük aktivasyon-değerlik ve baskınlık sonuçları sırasıyla %73.8, %70.0, %74.2'dir.
- ÇDGKA-ÇÇA ve ÇDGKA-SSD Domeninde Çok Kanallı EEG Sinyallerinden Duygu Durum Analizi: Diğer bir çalışmamızda ise, ÇDGKA kullanılarak elde edilen ÖKF'lere ADD tabanlı ÇÇA ve SSD uygulanarak elde edilen Alfa, Beta, Teta, Delta, Gama dalgacık katsayıları ve senkrosıkıştırma katsayıları kullanılarak sınıflandırma sürecinin yürütüldüğü bir duygu tanıma modeli sunulmuştur. Bu nedenle DEAP veri tabanındaki EEG verileri, aktivasyon, değerlik ve baskınlık boyutları için düşük / yüksek olarak kategorize edilmiş ve sınıflandırma aşamasında k-NN farklı sınıflan-

dırıcı kullanılmıştır. Diğer etiketlerden ayrı olarak en iyi oranlarda baskınlık etiketi sırasıyla Gama bandı için % 74.8,% 67.7,% 75.7 olarak gerçekleşmiştir.

- Adaptif Ortogonal Sinyal Ayırıştırma Temelli Duygu Durum Analizi: Son çalışmamızda ise, aynı şekilde ÇDGKA temelli bir duygu tanıma modeli sunulmuştur. Ancak bu kez ÇDGKA algoritması sonucu elde edilen ÖKF'lerin yarı ortogonal olduğu bilgisinden faydalanarak, elde edilen ÖKF lere Gram-Schmidt Orthogonalization yöntemi uygulanıp, ortogonal ÖKF'ler elde edilmiş ve sonrası ortogonal bileşenlerin miktarı, GDD algoritmasına giriş olarak verilip öznitelik vektörü çoğaltılmıştır. Öte yandan, duygusal durum analizi göz önüne alındığında kanal seçimi de önemli bir problemdir çünkü beynin tüm bölümlerinin duygu tanıma işlevi yoktur. Özellikle, frontal lob üzerine kanallar duygusal durum analizi çalışmalarında kullanılır. Bununla birlikte, kanal düzeninde tercih edilirken, hepsi, bir kaç veya sadece bir tanesini tercih ettikleri kanal düzenlemesinde kullanılan çalışmalar da vardır. Ayrıca öznitelik seçme algoritmaları ile de kanallar seçilerek değerlendirilmiştir. Bu çalışmada, seçilen kanallarında sınıflandırmaya katkısı göz önünde bulundurularak, TS ve KA sınıflandırıcıları kullanılarak % 72.7, % 62.0 ve % 64.7 sınıflandırma performanslarıyla yüksek-düşük aktivasyon, değerlik ve baskınlık olarak sınıflandırılmıştır.

Sonuçlarımız, literatürdeki hibrid modeller ve çok değişkenli hibrid modeller ve 3 boyutlu duygu durum analizi çalışmaları ile karşılaştırılması amacı ile % olarak sunulan **Tablo 5.1:**, **Tablo 5.2:**, **Tablo 5.3:** elde edilmiştir. Buna göre bu tez çalışmasında önerilen yöntemler daha önce mevcut önerilere göre genelde daha başarılı sınıflandırma sonuçları vermiştir.

Tablo 5.1: Duygu Durum Analizinde Hibrid Modeller.

Yazar	Veri Kümesi	Duygu Durumu	Doğruluk oranı	Yöntem	Sınıflandırıcı
(Petrantonakis ve Hadjileontiadis, 2010)	POFA	Mutluluk Şaşkınlık Korku Öfke Tiksinme Üzüntü	77.8, QDA (Kanallar ayrı ayrı) 85.17, DVM (Kanallar bütün)	GKA & GA (HAF) & (YSG)	EYKS QDA MM DVM
(Zhang ve diğ., 2016)	DEAP	PDYA PDDA NDYA NDDA	94.98 (İkili Sınıflandırma) 93.20 (Çoklu Sınıflandırma)	GKA & Örnek Entropi (İlk Dört OKF)	DVM
(Zhuang ve diğ., 2018)	Şahsi Veri Kümesi	Pozitif & Negatif Mutluluk Şaşkınlık Korku Öfke Tiksinme Üzüntü	87.36 (Pozitif & Negatif) 54.52 (Altı Ayrık Duygu)	GKA (İlk OKF) log(OKF)	SVM

Tablo 5.2: Duygu Durum Analizinde Çok Değişkenli Hibrid Modeleler.

Yazar	Veri Kümesi	Duygu Durumu	Doğruluk oranı	Yöntem	Sınıflandırıcı
(Xu, 2012)	IAPS	Pozitif olarak heyecanlı Negatif olarak heyecanlı Nötr	EYKS(81.39;LDA (59.18)	CDGKA-istatistiksel CDGKA-NBP CDGKA-YSG CDGKA-Dalgacık	EYKS LDA
(Mert ve Akan, 2018)	DEAP	Yüksek-Düşük Değerlik Yüksek-Düşük Aktivasyon Yüksek-Düşük Değerlik Yüksek-Düşük Aktivasyon	67 ± 9.60, EYKS 51.01 ± 15.69, EYKS 72.87 ± 4.68, YSA 75.00 ± 7.48, YSA	CDGKA-tabanlı öznitelikler, ICA	EYKS YSA
(Guitton, 2010)	Şahsi Veri Kümesi	Mutlu Rahat Nötr Korku	CDGKA-(EKA-FAA) & DVM 72.2-83.3 77.8-66.7 72.2-83.3 66.7-55.6	CDGKA-tabanlı öznitelikler	DVM, EYKS LDA

Tablo 5.3: Duygu Durum Analizinde 3 Boyutlu Duygu Durum Sınıflandırma Sonuçları.

Yazar	Veri Kümesi	Duygu Durumu	Doğruluk oranı	Yöntem	Sınıflandırıcı
(Liu ve Sourina, 2013)	IADS & DEAP	Yüksek/Düşük Aktivasyon & Yüksek/Düşük Baskınlık & 4 seviye Değerlik Boyutu Birleşimi	23.2,9-seviye 21.84,8-seviye 31.16,7-seviye 50.91-6 seviye 53.57,5 seviye 62.07,4-seviye 86.76,3-seviye 100, 2-seviye	İstatistiksel Öznitelikler & Fraktal Boyut Tabanlı Öznitelikler	DVM
(Verma ve Tiwary ve diğ., 2017)	DEAP	Değerlik Aktivasyon Baskınlık	67.5, Değerlik 69.6, Aktivasyon 65.1, Baskınlık	ÇÇA-tabanlı çoklu modelite (EEG & Video) öznitelikleri	ÇKA EYKS DVM
(Walter ve diğ., 2013)	Şahsi Veri Kümesi (IAPS)	PDDAYB NDYADB	70.1(bireysel)	istatistiksel öznitelikler, EMG Peak-searching Yöntemi,KVP istatistiksel öznitelikler, DİY	YSA
(Guendil ve diğ., 2017)	DEAP	Değerlik Aktivasyon Baskınlık & (İki Seviye)	73.43 (D) 72.65(A) 69.3 (B)	Dalgacık Tabanlı Öznitelik	SÖM

Buna göre, **Tablo 5.1:** ve **Tablo 5.2:**'yi kendi arasında karşılaştırdığımızda, **Tablo 5.1:** sonuçlarının **Tablo 5.2:** sonuçlarından daha iyi performans gösterdiği görülmektedir. Ancak, Bölüm 3.1.1.1. ve Bölüm 3.1.1.2. da ifade edildiği gibi yöntemin analitik olmaması gerekçesi ve Bölüm 3.1.1.2. da açıklanan CDGKA yönteminin çok değişkenli sinyal yapısı için daha uygun olması gerekçesi ile **Tablo 5.2:** sonuçları daha güvenilirdir. Bunların dışında bu tez de çok değişkenli hibrid model olarak önerilen duygu durum analizi çalışmaları da genel olarak literatürdeki hibrid model kavramına farklı bir bakış açısı getirip, duygu durum sınıflandırması basamağında yaklaşık %5 civarı artış ile katkı sağlamıştır.

Ek olarak, tezin diğer önemli katkısı 3 boyutlu duygu durum analizi uygulaması ile olmuştur. Bugüne kadar, 3 boyutlu duygu durum uzayı kavramı ile sınıflandırma gerçekleştiren çalışmalar **Tablo 5.3:** de verilmiştir. **Tablo 5.3:**de de görüldüğü gibi, bu tez çalışmasında Bölüm 4.1. de elde edilen sonuçlara göre önerdiğimiz öznitelik çıkarma ve duygu durum uzayı bölümlenmesi yöntemi hem doğruluk oranları hem de duygu durum uzayı sınıflandırması kavramında daha iyi performans göstermiştir.

Bunların dışında, duygunun ortaya çıkması, temel bulguların tanımı ve ortak deney seti kullanımının gözlemlenmesi bu tezin amaçlarından olması sebebi ile DEAP veri kümesi üzerinde daha fazla inceleme yapılmıştır. Birçok duygu durum analizi çalışmasında farklı deneysel protokol ayarı ile spesifik duygu örnekleri, duygu durum analizi işleminde kullanılmıştır, ancak bir çok durumda, belirsizlik ve temel bulgu tanımında genellikle tartışmalı seçimler vardır. Ortak veri kümesi kullanımı, yeni önerilen öznitelik çıkarma ve sınıflandırma metodu performanslarını karşılaştırma olanağı vermesinin yanında, duygu durumu uzayı bölümlenmesi, kanal seçimi gibi farklı kriterleri de değerlendirme imkanı sunmaktadır. Ancak kullanılan DEAP veri kümesi akademik çalışmalarda kullanılmasına izin verilen, anlaşılır ve istatistiksel analize uygun katılımcı sayısı ve video dinletisine sahip olmasına rağmen, bazı dezavantajlara sahiptir. İlk önemli dezavantaj video dinletisi sırasında videolar birer dakika boyunca dinletilip sadece özdeğerlendirme anketi süresince beklenilmiştir. Ayrıca çalışmada dinletilen müzik videolarının oluşturduğu duyguları karşılaştırabileceğimiz, video dinletimine başlanmadan önceki EEG kayıtları mevcut değildir. Dolayısı ile duygu oluşumu sonrası ve öncesi karşılaştırmalar yapılamamıştır. Ek olarak, DEAP veri kümesinde dinletilen video listesi verilmesine rağmen, videoların hangi duyguyu oluşturmak amacı ile dinletildiği bilgisine bütün videolar için ulaşılamamıştır.

Sonuç olarak, sunduğumuz duygu durum analizi modellerinde bu dezavantajlarında göz önünde bulundurulması gerekir.

Ayrıca, duygu durum analizi çalışmalarında kanal seçimi de tartışmalı bir konudur. Adaptif Ortogonal Sinyal Ayırıştırma Temelli Duygu Durum Analizi çalışmamızda kullanılan kanallar ayrı ayrı değerlendirilerek, duygu durum analizinde kanal seçimi çalışmalarına katkı sağlanmaya çalışılmıştır. Buna göre literatürde çoğunlukla kanallar nörobilimsel verilere dayalı olarak veya öznitelik seçme yöntemleri seçilmektedir ve en iyi ortak kanal grubu çalışmalara göre farklılık göstermektedir. Bu tez çalışmasında da seçilen kanallar her birinin katkısının ayrı ayrı görülmek istenmesi sebebi ile ayrı ayrı uygulanmasına rağmen, ortak bir kanal grubu sonucuna işaret etmemiştir. Dolayısı ile duygu durum analizi için en iyi kanal seçimi kullanılan öznitelik çıkarma yöntemine göre de değişmektedir sonucuna varılmıştır.

Gelecek çalışma önerileri, esasında hem duygu durum analizi modelleme hem de çok değişkenli sinyal işleme yöntemlerini kapsamalıdır. İlk olarak duygu durum sınıflandırma kısmında hem veri kümesi yetersizliği, hem duyguların tam yerinin bilinmemesi, hem de makina öğrenme algoritmaları kullanımı sebebi ile duygunun yeri yerine oluşturduğumuz sekiz farklı duygu grubuna göre sınıflandırma yapılabilmektedir. Daha etkin bir sınıflandırma için daha etkili duygu durum modelleri takip edilip uygulanabilir. Ayrıca daha iyi sınıflandırma algoritmaları daha iyi sonuçlar verebilir. Ek olarak, çok kanallı sensör teknolojileri duygu durum modelleme alanı ile doğrudan ilgilidir. Daha hızlı ancak verimi yüksek öznitelik çıkarma metodları ile gerçek zamanlı duygu durum analizi çalışmaları yapılan çalışmaların günlük hayata uyarlanabilirliğini de artıracaktır. Duygu durum analizi çalışmalarının psikolojik boyutu da olduğu için, duyguların birbiri ile ilişkisini araştıran çalışmalar duyguların birbirinden ayırt edilebilmesine katkı sağlayacaktır.

KAYNAKLAR

- Scherer, K. R. , 2005, What are emotions? and how can they be measured?, *Social Science Information*, 4, 44, 695-729
- Phillips, M. L. , Drevets, W. C. , Rauch, S. L., Lane, R. , 2003, Neurobiology of emotion perception II: implications formajor psychiatric disorders, *Biological Psychiatry*, 5, 54, 515-528
- Phillips, M. L. , Drevets, W. C. , Rauch, S. L., Lane, R. , 2003, Neurobiology of emotion perception I: the neural basis of normal emotion perception, *Biological Psychiatry*, 5, 54, 504-514
- Luneski, A. , Konstantinidis, E. , Bamidis, P. D. , 2010, Affective medicine: a review of affective computing efforts in medical informatics, *Methods of Information in Medicine*, 3, 49, 207-218
- Barret, L. F. , 1998, Discrete emotions or dimensions? the role of valence focus and arousal focus, *Cognition and Emotion*, 4, 12, 579-599
- Mauss, I. B. ,Robinson, M. D. , 2009, Measures of emotion: a review, *Cognition and Emotion*, 2, 23, 209-237
- Frantzidis, C. A. , Bratsas, C. , Papadelis, C. L. , Konstantinidis, E. , Pappas, C. , Bamidis, P. D. , 2010, Toward emotion aware computing: an integrated approach using multichannel neurophysiological recordings and affective visual stimuli, *IEEE Transactions on Information Technology in Biomedicine*, 3, 14, 589-597
- Cacioppo, J. T. , 2004, Feelings and emotions: Roles for electrophysiological markers , *Biol. Psychol.*, 1-2 ,64, 235-243
- Jenke, R. , Peer, A. ,Buss, M. , 2014, Feature Extraction and Selection for Emotion Recognition from EEG, *IEEE Transactions on Affective Computing*, 3 , 5
- Kim, M. -K. , Kim, M. , Oh, E. , Kim, S. -P. , 2013, A review on the computational methods for emotional state estimation from the human EEG, *Comput. Math. Methods Med.*, 2013, 1-13
- Vytal, K. , Hamann, S. , 2010, Neuroimaging support for discrete neural correlates of basic emotions: a voxel-based metaanalysis, *Journal of Cognitive Neuroscience*, 12, 22, 2864-2885
- Panksepp, J. , 2007, Neuro psychoanalysis may enliven the mindbrain sciences, *Cortex*, 8, 43, 1106-1107
- Robinson, M. D. , Clore, G. L. , 2002, “Belief and feeling: evidence for an accessibility model of emotional self-report, *Psychological Bulletin*, 6 , 128, 934-960

- Christie, I. C., Friedman, B. H. , 2004, Autonomic specificity of discrete emotion and dimensions of affective space: a multivariate approach, *International Journal of Psychophysiology*, 2, 51, 143-153
- Hamalainen, M. ,Hari, R. , Ilmoniemi, R. J. , Knuutila, J. , Lounasmaa, O. V. , 1993, Magnetoencephalography—theory, instrumentation, and applications to noninvasive studies of the working human brain, *Reviews of Modern Physics*, 2, 65, 413-497
- Peyk, P. , Schupp, H. T. , Elbert, T. , Junghöfer, M. ,2008, Emotion processing in the visual brain: a MEG analysis, *Brain Topography*, 4, 20, 205-215
- Ray ,A. ,Bowyer, S. M. , 2010, Clinical applications of magnetoencephalography in epilepsy, *Annals of Indian Academy of Neurology*, 1, 13, 14-22
- Davidson, P. R. , Jones, R. D. , Peiris, M. T. , 2007, EEG-based lapse detection with high temporal resolution, *IEEE Transactions on Biomedical Engineering*, 5, 54, 832-839
- Murugappan, M. , Nagarajan, R. , Yaacob, S. , 2010, Classification of human emotion from EEG using Discrete Wavelet Transform *J. Biomed. Sci. Eng.* ,4 ,3, 390-396
- Hausdorff, J. , Lertratanakul, A. , Cudkowicz, M. , Peterson, A. , Kaliton, D. , Goldberger, A. , 2000, Dynamic markers of altered gait rhythm in amyotrophic lateral sclerosis, *J. Appl. Physiol.* , 88, 2045-2053
- Khosrowabadi, R. , Rahman, A. , Classification of EEG correlates on emotion using features from Gaussian mixtures of EEG spectrogram, 2010, *Proc. 3rd Int. Conf. Inf. Commun. Technol. Moslem World*, E102-E107
- Sourina, O. , Liu, Y. , 2011, A Fractal-based algorithm of emotion recognition from EEG using arousal-valence model, *Proceedings of Biosignals*, Rome, 209-214
- Huang, N. E. , Shen, Z. , Long, S. R. , Wu, M. C. , Shih, H. H. , Zheng, Q. , Yen, N. -C. , , Tung, C. C. , Liu, H. H. , 1998, The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis *Proc. R. Soc. A*, 1971, 454 , 903-995
- Rehman, N. , Mandic, D. P. , 2010, Multivariate empirical mode decomposition, *Proc. R. Soc. A*, 2117, 466, 1291-1302
- Rehman, N., Mandic, D.P., 2011, Filter bank property of multivariate empirical mode decomposition, *IEEE Trans. Signal Process.*,5, 59 ,2421-2426
- Daubechies, I. , Lu, J. , Wu, H. -T. , 2011, Synchrosqueezed wavelet transforms: An Empirical Mode Decomposition-like tool, *IEEE Trans. Signal Process.*, 2, 30, 243–261
- Ahrabian, A. , Looney, D., Stankovic, L. , Mandic, D. P. , 2015, Synchrosqueezing-based time-frequency analysis of multivariate data *Signal Processing*, 106, 331-341
- Lilly, J. M. , Olhede, S. C. , 2009, Wavelet ridge estimation of jointly modulated multivariate oscillations *Conference Record of the Forty-Third Asilomar Conference on Signals, Systems and Computers*, 452-456

- Lilly, J. M. , Olhede, S. C. , 2012, Analysis of modulated multivariate oscillations *IEEE Trans. Signal Process.*, 2, 60, 600-612
- Olhede, S. , Walden , A. T. , 2004, The Hilbert spectrum via wavelet projections, *Proc. R. Soc. A*, 460, 955-975
- Mert, A. , 2015, EEG Sinyallerinin Görgül Kip Ayırışım Yöntemi ile Analizi , *İstanbul Üniversitesi, Doktora tezi*
- Chui, C. K. , Mhaskar, H. N. , 2016, Signal decomposition and analysis via extraction of frequencies, *Applied and Computational Harmonic Analysis*, 1, 40, 97-136
- Chui, C. K. , Mhaskar, H. N. , Van Der Walt, M. D. , 2016, Data-driven atomic decomposition via frequency extraction of intrinsic mode functions, *GEM - International Journal on Geomathematics*, 1, 7, 117-146
- Pouryazdian, S. , Beheshti, S. , Krishnan, S. , 2015, Localization of Brain Activities using Multiway Analysis of EEG Tensor Via EMD and Reassigned TF Representation, *The 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBS)*, Milan, İtalya
- Shahnaz, C. , Sultana, S. , Fattah, S. A. , Rafi, R. H. M. , Ahmmed, I. , Zhu, W.-P. , Ahmad, M. O. , 2015, Emotion Recognition Based on EMD Wavelet Analysis of Speech Signals, *IEEE International Conference on Digital Signal Processing (DSP)*, Singapur, Singapur
- Das, A. B. , Bhuiyan, M. I. H. , 2016, Discrimination and classification of focal and non-focal EEG signals using entropy-based features in the EMD-DWT domain, *Biomedical Signal Processing and Control*, 29, 11-21
- Guitton, C. , 2010, Emotions Estimation from EEG Recordings , *Imperial College of Science, Technology & Medicine Department of Electrical& Electronic Engineering*
- Wu, H. -T. , Flandrin, P. , Daubechies, I. , 2011, One or two frequencies? The Synchrosqueezing Answers, *Advances in Adaptive Data Analysis*, 1&2, 3, 29-39
- Huang, Z. -L., Zhang, J. , Zhao, T. -H., Sun, Y. , 2016, Synchrosqueezing S-Transform and Its Application in Seismic Spectral Decomposition, *IEEE Transactions on Geoscience and Remote Sensing*, 54, 817-825
- Daubechies, I. , Wang, Y. G. , Wu, H. -T. , 2016, ConceFT: concentration of frequency and time via a multitapered synchrosqueezed transform, *Philos Trans A Math Phys Eng Sci.* , 2065, 374, 1-19
- Hu, Y. , Tu, X. , Li, F. , Meng, G. , 2018, Joint High-Order Synchrosqueezing Transform and Multi-Taper Empirical Wavelet Transform for Fault Diagnosis of Wind Turbine Planetary Gearbox under Nonstationary Conditions, *Sensors*, 150, 18, 1-18,
- Ghanbari, Z. , Moradi, M. H. , 2016, K-complex Detection Based on Synchrosqueezing Transform, *AUT Journal of Electrical Engineering*, 2, 49, 215-222

- Rutkowski, T. M. , 2014, Multichannel EEG Sonification with Ambisonics Spatial Sound Environment, *Signal and Information Processing Association Annual Summit and Conference (APSIPA)*, Siem Reap, a city of Angkor Wat Cambodia.
- Vasquez-Correa, J. C. , Arias-Vergara, T. , Orozco-Arroyave, J. R. , Vargas-Bonilla, J. F. , Noeth, E. , 2016, Wavelet-Based Time-Frequency Representations for Automatic Recognition of Emotions from Speech, *Proceedings of Speech Communication; 12. ITG Symposium*, Paderborn, Germany
- Kabir, M. M. , Tafreshi, R. , Boivin, D. B. , Haddad, N. , 2015, Enhanced automated sleep spindle detection algorithm based on synchrosqueezing, *Medical & Biological Engineering & Computing*, 7, 53, 635-644
- Bai, Y. , Wang, Y. , Niu, Z. , Li , X. , 2017, Synchrosqueezing Algorithm Application in TMS-EEG Analysis, *Chinese Automation Congress (CAC)*, Jinan, China
- Ali, S. , Ferdou, J. , Hamid, E., Molla, K. I. , 2016, Time-Frequency Coherence of Multichannel EEG Signals: Synchrosqueezing Transform Based Analysis, *International Journal of Computer Science Trends and Technology (IJCTST)*, 3, 4
- Ferdou, J. , Ali, S. , 2017, Time-Frequency Analysis of EEG Signal processing for Artifact Detection, *International Journal of Science and Research (IJSR)*, 4, 6, 2013-2021
- Allen, J. B. , Rabiner, L. R. , 1977, A Unified Approach to Short-Time Fourier Analysis and Synthesis, *Proceedings of the IEEE*, 11, 65, 1558-1564
- Shensa, M. S. , 1992, The Discrete Wavelet Transform: Wedding the A Trous and Mallat Algorithms, *IEEE Transactions on Signal Processing*, 10, 40, 2464-2482
- Daubechiesi, I. , 1990, The wavelet transform, time-frequency localization, *IEEE Transactions on Information Theory*, 5, 36, 961-1005
- Bartelt, H. O. , Brenner, K. -H. , Lohmann, A. W. , 1980, The Wigner Distribution Function and Its Optical production, *Optics Communications*, 1, 32, 32-38
- Yao, J. , Krolak, P. , Steele, C. , 1995, The Generalized Gabor Transform, *IEEE Transactions on Image Processing*, 7, 4, 978-988
- Kalman, R. , 1960, A New Approach to Linear Filtering and Prediction, *Transaction of the ASME—Journal of Basic Engineering*, Seri D, 82, 35-45
- Stockwell, R. G. , Mansinha, L. , Lowe, R. P. , 1996, Localization of the Complex Spectrum, *IEEE Transactions on Signal Processing*, 4, 44, 998-1001
- Gilles, J. , 2013, Empirical Wavelet Transform, *IEEE Transactions on Signal Processing*, 16, 61, 3999-4010
- Lin, Y. -P. , Wang, C. -H. , Jung, T. -P. , Wu, T. -L. , Jeng, S. -H. , Duann, J. -R. , Chen, J. -H. , 2010, EEG-Based Emotion Recognition in Music Listening, *IEEE Transactions on Biomedical Engineering*, 7, 57, 1798-1806

- Ozel, P. , Akan, A. , Yilmaz, B. , 2017a, Multivariate Pseudo Wigner Ville Distribution based Emotion Detection from Electrical Activity of Brain, *10th International Conference on Electrical and Electronics Engineering*, Bursa, Turkey
- Hadjidimitriou, S. K. , Hadjileontiadis, L. ,2012, Towards an EEG-based recognition of music liking using time-frequency analysis, *IEEE Transactions on Biomedical Engineering* , 12, 59, 3498-3510
- Zhuang, N. , Zeng, Y. , Tong, L. , Zhang, C. , Zhang, H. , Yan, B. , 2017, Emotion Recognition from EEG Signals Using Multidimensional Information in EMD Domain, *BioMed Research International*, 2017, 1-9
- Zhuang, N. , Zeng, Y. , Yang, K. , Zhang, C. , Zhang, C. , Tong, L. , 2018, Investigating Patterns for Self-Induced Emotion Recognition from EEG Signals, *Sensors*, 841, 18, 1-22
- Rehman, N. U. , Park, C. , Huang, N. E. , Mandic, D. P. , 2013, Emd via Memd:Multivariate Noise Aided Computation of Standard Emd *Advances in Adaptive Data Analysis*, 2 (2013), 5, 1350007 (25 sayfa)
- Torres, M. E. , Colominas, M. A. , Schlotthauer, G. , Flandrin, P. ,2011, A complete ensemble empirical mode decomposition with adaptive noise, *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing*, Prag.
- Wu, Z. , Huang, N. E. , 2009, Ensemble Empirical Mode Decomposition : A Noise Assisted Data Analysis Method, *Advances in Adaptive Data Analysis*, 1, 1-41.
- Zhu, W. , Zhao, H. , Xiang, D. , Chen, X. , 2013, A Flattest Constrained Envelope Approach for Empirical Mode Decomposition, *PLoS One*, 4, 8, 1-6.
- Singh, P. , Srivastava, P. K. , Patney, R. K. , Joshi, S. D, Saha, K. , 2013, Nonpolynomial Spline Based Empirical Mode Decomposition, *International Conference on Signal Processing and Communication (ICSC)*, Noida, India
- Pao, S. -H. , Young, C. , -N. , Tseng, C. L. , 2010, Smoothing Empirical Mode Decomposition: A Patch to Improve the Decomposed Accuracy, *Advances in Adaptive Data Analysis*, 2, 4, 521-543
- Matei, B. , Meignen, S. , 2010, A new optimization based approach to the empirical mode decomposition, *Annals of the University of Bucharest (mathematical series)*, LXII, 4, 129-139
- Tianlu, M. , Zengli, L. , 2013, Inhibition of Envelope Correction Method to EMD End Effect, *Proceedings of the 2nd International Conference on Computer Science and Electronics Engineering (ICCSEE)*, Paris, Fransa
- Niang, O. , Deléchelle, E. , Lemoine, J. , 2010, A spectral approach for sifting process in Empirical Mode Decomposition, *IEEE Transactions on Signal Processing*, 11, 58, 5612-5623

- Yeh, J. -R. , Shieh, J. -S. , Huang, N. , 2010, Complementary Ensemble Empirical Mode Decomposition: A Novel Noise Enhanced Data Analysis Method, *Advanced Adaptive Data Analysis*, 2(210), 135-136.
- Huang, B. , Kunoth, A. , 2013, An optimization based empirical mode decomposition scheme, *Journal of Computational and Applied Mathematics*, 240, 174-183.
- Cheriyian, L. E. , Janardhanan, P. , 2014, Adaptive Orthogonal Signal Decomposition Based on Empirical Mode Decomposition and Empirical Wavelet Transform, *International Journal of Industrial Electronics and Electrical Engineering*, 5, 2, 49-52
- Oberlin, T. , Meignen, S. , Perrier, V. , 2012, An Alternative Formulation for the Empirical Mode Decomposition, *IEEE Transactions on Signal Processing*, 5, 60, 2236-2246
- Ren, Q. S. , Yi, Q. , Fang, M. Y. , 2007, Fast Implementation of Orthogonal Empirical Mode Decomposition and Its Application into Singular Signal Detection, *IEEE International Conference on Signal Processing and Communications*, Dubai, United Arab Emirates.
- Lou, M. , Huang, T. , 2015, An orthogonal technique for empirical mode decomposition in Hilbert-Huang transform, *MATEC Web OF Conference*, Dübendorf (Zürich), Switzerland
- Lou, M. , Huang, T. -L, 2007, Orthogonal empirical mode decomposition, *Journal of Tongji University*, 3, 35, 293-298.
- Huang, T. -L. , Ren, W. -X. , Lou, M. -L. , 2008, The Orthogonal Hilbert-Huang Transform and Its Application in Earthquake Motion Recordings Analysis, *The 14. th World Conference on Earthquake Engineering*, Beijing, China,
- Huang, T. -L. , Lou, M. -L. , Chen, H. -P. , Wanga, N. -B. , 2018, An orthogonal Hilbert-Huang transform and its application in the spectral representation of earthquake accelerograms, *Soil Dynamics and Earthquake Engineering*, 104, 378-389.
- Hu, Y. , Li, F. , Li, H. -G. , Liu, C. , 2017, An enhanced empirical wavelet transform for noisy and non-stationary signal processing, *Digital Signal Processing*, 60, 220-229
- Jenke, R. , Peer, A. , Buss, M. , 2013, Effect-size-based electrode and feature selection for emotion recognition from EEG, *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Vancouver, BC, Canada.
- Zhang, J. , Chen, M. , Zhao, S. , Hu, S. , Shi, Z. , Cao, Y. , 2016, Relief-Based EEG Sensor Selection Methods for Emotion Recognition, *Sensors*, (10) 26, E1558, 16
- Hatamikia, S. , Nasrabadi, A. M. , 2013, Common Spatial Pattern Method for Channel Reduction in EEG-Based Emotion Recognition, *Modares Journal of Electrical Engineering*, 1, 31-43.
- Ozerdem, M. S. , 2017, Polat, H. , Emotion recognition based on EEG features in movie clips with channel selection, *Brain Informatics*, 4, 4, 241-252.

- Petrantonakis, P. C. , Hadjileontiadis, L. J. , 2010, Emotion Recognition from Brain Signals Using Hybrid Adaptive Filtering and Higher Order Crossings Analysis, *IEEE Transactions on Affective Computing*, 2, 1, 81-97.
- Blaiech, H. ,Neji, M. , Wali, A. , Alimi, A. M. , 2013, Emotion recognition by analysis of EEG signals, *13th International Conference on Hybrid Intelligent Systems (HIS)*, Gammarth, Tunisia.
- 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*, 4, 53
- Parrott, W. G. , 2001, Emotions in Social Psychology: Essential Readings, *Philadelphia, PA: Psychology Press*
- Plutchik, R. , 1980, Emotion: A Psychoevolutionary Synthesis, *New York: Harper and Row*
- Russell, J. A. , 1980, A circumplex Model of Affect, *Journal of Personal and Social Psychology*, 39, 1161-1178.
- Mert, A. , Akan, A. , 2018, Emotion recognition from EEG signals by using multivariate empirical mode decomposition, *Pattern Analysis and Applications*, 1, 21, 81-89
- Liu, Y. , Sourina, O. , Nyuyen, M. K. , 2011, Real Time Eeg Based Emotion Recognition and its Applications, *Transactions on Computational Science XII*, 256-277
- Othman, M. , Wahab, A. , Karim, I. , Dzulkifli, M. A. , Alshaikli, I. F. T. , 2013, EEG emotion recognition based on the dimensional models of emotions, *Procedia - Social and Behavioral Sciences*, 97, 30-37.
- Verma, G. K. , Tiwary, U. S. , 2017, Affect representation and recognition in 3D continuous valence-arousal-dominance space, *Multimedia Tools and Applications*, 2, 76, 2159-2183.
- Petrantonakis, P. C. , Hadjileontiadis, L. , 2012, Adaptive Emotional Information Retrieval From EEG Signals in the Time-Frequency Domain, *IEEE Transactions on Signal Processing*, 5, 60, 2604-2616
- Mehrabian, A. , Russell, J. A. , 1974, An approach to environmental psychology, *Camb-ridge, MA: MIT Press*
- Cambria, E. , Livingstone, A. , Hussain, A. , 2012, The Hourglass of Emotions, *Cognitive Behavioural Systems* , 144-157.
- Bradley, M. M. , Greenwald, M. K. , Petry, M. C. , Lang, P. J, 1992, Remembering Pictures : Pressure Arousal in Memory, *Journal of Experimental Psychology: Learning, Memory & Cognition* , 2, 18, 379-390
- Watson, D. , Tellegan, A. , 1985, Towards a consensual structure of Mood, *Psychological Bulletin*, 2, 98, 219-235.

- Lövheim, H., 2012, A new three-dimensional model for emotions and monoamine neurotransmitters, *Medical Hypotheses*, 78, 341-348.
- Eerola, T. , Vuoskoski, J. K. , 2010, A comparison of the discrete and dimensional models of emotion in music, *Psychology of Music*, 1-32
- Bruna, O. , Avetisyan, H. , Holub, J. , 2016, Emotion models for textual emotion classification, *Journal of Physics: Conference Series*, 772.
- Kumar, J. , kumar, J. , 2016, Affective modelling of users in HCI using EEG, *Procedia Computer Science*, 84, 107-114.
- Alarcao, S. M. , Fonseca, M. J. , 2017, Emotions Recognition Using EEG Signals: A Survey, *IEEE Transactions on Affective Computing*, PP, 1-1, 1-20.
- Soroush, M. Z. , Maghooli, K. , Setarehdan, S. K. , Nasrabadi, A. M. , 2017, A review on EEG Signals Based Emotion Recognition, *Int Clin Neurosci J*, 4, 4, 118-129.
- Katsigiannis, S. , Ramzan, N. , 2018, DREAMER: A Database for Emotion Recognition Through EEG and ECG Signals From Wireless Low-cost Off-the-Shelf Devices, *IEEE Journal of Biomedical Informatics*, 1, 22, 98-107
- Zheng, W. -L., Lu, B. -L., 2015, Investigating Critical Frequency Bands and Channels for EEG-based Emotion Recognition with Deep Neural Networks, *IEEE Transactions on Autonomous Mental Development*, 3, 162-175
- Conneau, A. -C. , Hajlaoui, A. , Chetouani, M. , Essid, S. , 2017, EMOEEG: a New Multimodal Dataset for Dynamic EEG-based Emotion Recognition with Audiovisual Elicitation, *25th European Signal Processing Conference (EUSIPCO)*, Kos island, Greece.
- Miranda-Correa, J. A. , Abadi, M. K. , Sebe, N. , Patras, I. , 2017, AMIGOS: A Dataset for Affect, Personality and Mood Research on Individuals and Groups, *IEEE Transactions on Affective Computing*
- Subramanian, R. , Wache, J. , Abadi , M. K. , Vieriu, R. L. , Winkler, S. , Sebe, N. , 2016, ASCERTAIN: Emotion and Personality Recognition using Commercial Sensors, *IEEE Transactions on Affective Computing*, 2, 9, 147-160.
- Healey, J. A. , Picard, R. W. , 2005, Detecting stress during real-world driving tasks using physiological sensors, *IEEE Transactions on Intelligent Transportation Systems*, 2, 6, 156-166.
- Douglas-Cowie, E. , Cowie, R. , Sneddon, I. , Cox, C. , Lowry, O. , McRorie, M. , Devillers, L. , Abrilian, S. , Batliner, A. , Amir, N. , Karpouzis, K. , Martin, J. -C. , 2007, The HUMAINE Database: Addressing the Collection and Annotation of Naturalistic and Induced Emotional Data, *Affective Computing and Intelligent Interaction, Second International Conference, ACII* , Lisbon, Portugal.
- Soleymani, M. , Lichtenauer, J. , Pun, T. , Pantic, M. , 2012, A Multimodal Database for Affect Recognition and Implicit Tagging, *IEEE Transactions on Affective Computing*, 1, 3, 42-55.

- 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.
- Savran, A. , Ciftci, K. , Chanel, G. , Mota, J. C. , Viet, L. H. , Sankur, B. , Akarun, L. , Caplier, A. , Rombaut, M. , 2006, Emotion Detection in the Loop from Brain Signals and Facial Images, *Proceedings of the eINTERFACE 2006 Workshop.*, Dubrovnik (Croatia)
- Wu,S. , Xu, X. , Shu, L. , Hu, B. , 2017, Estimation of Valence of Emotion Using Two Frontal EEG Channels, *IEEE International Conference on Bioinformatics and Biomedicine*
- Flandrin, P. , Gonçalves, P. , Rilling, G., 2005 , EMD equivalent filter banks, from interpretation, *Interdisciplinary Mathematical Sciences, Hilbert–Huang Transform and Its Applications*, 55-74
- Auger, F. , Flandrin, P. , Lin, Y. -T. , McLaughlin, S. , Meignen, S. , Oberlin, T. , Wu, H. -T. , 2013, Time-Frequency Reassignment and Synchrosqueezing: an overview, *IEEE Signal Processing Magazine*, 6,30, 32-41.
- Ahrabian, A. , 2014 ,Multivariate Time Frequency Analysis, *Communications and Signal Processing Group Department of Electrical and Electronic Engineering Imperial College London*
- Takahashi, K., 2004, Remarks on Emotion Recognition from Bio-Potential, *2nd International Conference on Autonomous Robots and Agents, Palmerston North., New Zealand*
- Bos, D. O. , 2006, EEG-based Emotion Recognition, International Journal of ICTE EEG project, *Journal of ICTE EEG project. ICTE* , 57, 798-806
- Balconia, M. , Lucchiari, C. , 2006, EEG correlates (event-related desynchronization) of emotional face elaboration: A temporal analysis, *Neuroscience Letters* , 1-2, 392, 118-123
- Baumgartner, T. , Esslen, M. , Jänck, L. , 2006, From emotion perception to emotion experience: Emotions evoked by pictures and classical music, *International Journal of Psychophysiology* , 1, 60, 34-43
- Ansari-Asl, K. , Chanel, G. , Pun, T. , 2007, A channel selection method for EEG classification in emotion assessment based on synchronization likelihood, *15th European Signal Processing Conference, Poznan, Poland*
- Chanel, G. , Ansari-Asl, K. , Pun, T. , 2007, Valence-arousal evaluation using physiological signals in an emotion recall paradigm, *IEEE International Conference on Systems, Man and Cybernetics, Montreal, Que., Canada*
- Murugappan, M. , Rizon, M., Nagarajan, R., Yaacob, S., 2007, EEG feature extraction for classifying emotions using FCM and FKM, *International Journal of Computers and Communications & Control*, 2, 2, 299-304

- Horlings, R. , Datcu, D. , Rothkrantz, L. J. M. , 2008, Emotion recognition using brain activity, *International Conference on Computer Systems and Technologies - CompSysTech'08*, Gabrovo, Bulgaria
- Khalili, Z. , Moradi, M. H., 2008, Emotion Detection using brain and peripheral signals, *Cairo International Biomedical Engineering Conference(CIBEC*, Cairo, Egypt
- Li, M. , Lu , B. L. , 2009, Emotion Classification Based on Gamma-band EEG, *31st Annual International Conference of the IEEE EMBS, Minneapolis, Minneapolis, Minnesota, USA*
- Khosrowabadi , R. , Quek, H. C. , Wahab, A. , Ang, K. K. , 2010, EEG-based Emotion Recognition Using Self-Organizing Map for Boundary Detection, *20th International Conference on Pattern Recognition (ICPR)*, Istanbul, Turkey
- Hosseini, S. A. , Khalilzadeh, M. A. , Naghibi-Sistani, M. B. , Niazmand, V. , 2010, Higher Order Spectra Analysis of EEG Signals in Emotional Stress States, *Second International Conference on Information Technology and Computer Science (ITCS)*, Kiev, Ukraine
- Nie, D. , Wang, X. -W. , Shi, L. -C, Lu, B. -L. , 2011, EEG based emotion recognition during watching movies, *5th International IEEE/EMBS Conference on Neural Engineering (NER)* , Cancun, Mexico
- Makeig, S. , Leslie, G. , Mullen, T. , Sarma, D. , Bigdely-Shamlo, N. , Kothe, C. , 2011, First Demonstration of a musical emotional BCI, *Affective Computing and Intelligent Interaction. Lecture Notes in Computer Science*) , 6975, 487-496.
- Brown, L. , Grundlehner, B. , Penders, J. , 2011, Towards wireless emotional valence detection from EEG, *Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC* , Boston, MA, USA,
- Kroupi, E. , Yazdani, A. , Ebrahimi, T. , 2011, EEG correlates of different emotional states elicited during watching music videos, *Affective Computing and Intelligent Interaction, Lecture Notes in Computer Science* , Berlin, Heidelberg, 6975, 457-466
- Wang, X. -W., Nie, D., Lu, B. L. , 2011, EEG based emotion recognition using frequency domain features and support vector machine *Neural Information Processing. ICONIP 2011. Lecture Notes in Computer Science*, 7062, 734-743
- Liu, Y. , Sourina, O. , 2012, EEG-based Dominance Level Recognition for Emotion-enabled Interaction, *IEEE International Conference on Multimedia and Expo*, Melbourne, VIC, Australia
- Konstantinidis, E. I. , Frantzidis, C. A. , Pappas, C. , Bamidis, P. D. , 2012, Real time emotion aware applications: A case study employing emotion evocative pictures and neuro-physiological sensing enhanced by graphic processor units, *Computer Methods and Programs in Biomedicine*, 1, 107, 16-27
- Rozgić, V. , Vitaladevuni, S. N. , Prasad, R. , 2013, Robust EEG emotion classification using segment level decision fusion, *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* , Vancouver, BC, Canada

- Reuderink, B. , Mühl, C. , Poel, M. , 2013, Valence, arousal and dominance in the EEG during game play, *International Journal of Autonomous and Adaptive Communications Systems*, 1, 6, 45-62
- Liu, Y. , Sourina, O. , 2013, Real time fractal based valence level recognition from EEG, *Transactions on Computational Science XVIII- Lecture Notes in Computer Science*, 7748, 101-120
- 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*, 2014, 1-10
- Jie, X. , Cao, R. , Li, L. , 2014, Emotion Recognition based on the sample entropy of EEG, *Biomedical Materials and Engineering*, 1, 24, 1185-1192
- Paul, S. , Mazumder, A. , Ghosh, P. , Tibarewala, D. N. , Vimalarani, G. , 2015, EEG Based Emotion Recognition System using MFDFA as Feature Extractor, *International Conference on Robotics, Automation, Control and Embedded Systems*, Chennai, India
- Lu, Y. , Zheng, W. L. , Li, B. , Lu, B. L. , 2015, Combining Eye Movements and EEG to Enhance Emotion Recognition, *Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence (IJCAI 2015)* , Buenos Aires, Argentina
- Gao, Y. , Lee , H. J. , Mehmood, R. M . , 2015, Deep Learning of EEG Signals for Emotion Recognition, *IEEE International Conference on Multimedia Expo Workshops (ICMEW)* , Turin, Italy, 1-5
- Vaid, S. , Singh, P. , Kaur, C. , 2015, Classification of Human Emotions using Multi-wavelet Transform based Features and Random Forest Technique, *Indian Journal Science and Technology*, 8, 28, 1-7
- Zhang, Y. , Ji , X. , Zhang, S. , 2016, An approach to EEG-based emotion recognition using combined feature extraction method, *Neuroscience Letters*, 633, 152-157
- Thammasan, N. , Moriyama, K. , Fukui, K. , Numao, M. , 2017, Familiarity effects in EEG based emotion recognition, *Brain Informatics*, 1, 4, 39-50
- Liu , J. , Meng, H. , Li, M. , Zhang , F. , Qin , R. , Nandi, A. K. , 2017, Emotion detection from EEG recordings based on supervised and unsupervised dimension reduction, *Concurrency Computat Pract Exper*, 1-13
- Tripathi, S. , Acharya, S. , Sharma, R. D. , 2017, Using Deep and Convolutional Neural Networks for Accurate Emotion Classification on DEAP Dataset, *Proceedings of the Twenty-Ninth AAAI Conference on Innovative Applications (IAAI-17)*, 4746-4752, 1-13, San Francisco, California USA
- Al-Naffjan, A. , Al-Wabil, A. , Hosny, M. , Al-Ohali, Y. , 2017, Classification of Human Emotions from Electroencephalogram (EEG) Signal using Deep Neural Network, *International Journal of Advanced Computer Science and Applications*, 9, 8, 419-425

- Cai, H. , Han, J. , Chen, Y. , Sha, X. , Wang, Z. , Hu , B. , Yang, J. , Feng ,L. , Ding, Z. , Chen, Y. , Gutknecht, J. , 2018, A Pervasive Approach to EEG-Based Depression Detection, *Complexity*, 2018, 1-13
- Mohanapriya, N. , Malathi, L. , Revathi, B. , 2018, A Survey on Emotion Recognition from EEG Signals for Autism Spectrum Disorder, *International Journal of Computer Applications*, 20, 180, 32-37
- Kumar, N. , Khaund, K., Hazarik, S. M. , 2016, Bispectral Analysis of EEG for Emotion Recognition, *Procedia Computer Science*, 84, 31-35
- López-Gil, J. -M. , Virgili-Gomá, J. , Gil, R. , Guilera, T. , Batalla, I. , Soler-González, J. , García, R. , 2016, Method for Improving EEG Based Emotion Recognition by Combining It with Synchronized Biometric and Eye Tracking Technologies in a Non-invasive and Low Cost Way, *Front Comput Neurosci*, 85, 10, 1-14
- Vijayan, A. E. , Sen, D. , Sudheer, A. P. , 2015, EEG-based emotion recognition using statistical measures and auto-regressive modelling, *IEEE International Conference on Computational Intelligence & Communication Technology (CICT)*, 587-591.
- Pham, T. D. , Tran, D. , Ma, W. , Tran, N. T., 2015, Enhancing Performance of EEG-based Emotion Recognition Systems Using Feature Smoothing, *22nd International Conference on Neural Information Processing*, 9492, 95-102
- Atkinson, J. , Campos, D. , 2015, Improving BCI-based emotion recognition by combining EEG feature selection and kernel classifiers, *Expert Systems with Applications*, 47, 35-41
- Pan, J. , Li, Y. , Wang, J. , 2016, An EEG-Based brain-computer interface for emotion recognition, *International Joint Conference on Neural Networks*, Vancouver, Canada, 2063–2067.
- Zhang, Y. , Xu, P. , Li, P. , Duan, K. , Wen, Y. , Yang, Q. , Zhang, T. , Yao, D. , 2017, Noise Assisted Multivariate Empirical Mode Decomposition for Multichannel EMG Signals, *BioMedical Engineering Online*, 107, 16, 1-17
- Sungkono, S. , Santosa, B. J. , Santos, F. M. , Iswahudi, A. , Bahri, A. S. , 2017, Application of Noise Assisted Multivariate Empirical Mode Decomposition in VLF-EM Data to Identify Underground River, *Advances in Data Science and Adaptive Analysis*, 1, 9, 1650011(23 sayfa)
- Huang, W. , Zeng, J. , Wang, Z. , Liang, J. , 2017, Partial noise assisted multivariate EMD: An improved noise assisted method for multivariate signals decomposition, *Biomedical Signal Processing and Control*, 36, 205-220
- Hao, H. , Wang, H. , Rehman, N. U. , Tian, H. , 2016, A Study of the Characteristics of MEMD for Fractional Gaussian Noise, *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, 6, E99, 1228-1232
- Ge, S. , Shi, Y. H. , Wang, R. M. , Lin, P. , Gao, J. F. , Sun, G. P. , Iramina, K. , Yang, Y. K. , Leng, Y. , Wang, H. X. , Zheng, W. M. , 2018, Sinusoidal Signal Assisted

- Multivariate Empirical Mode Decomposition for Brain-Computer Interfaces, *IEEE Journal of Biomedical and Health Informatics*, 5, 22.
- Ahrabian, A. , Looney ,D. , Tobar, F. A. , Hallatt, J. , Mandic, D. P. , 2012, Noise Assisted Multivariate Empirical Mode Decomposition Applied to Doppler Radar Data, *Sensor Signal Processing for Defence* , London, UK, 2012.
- She, Q. S. , Ma, Y. L. , Meng, M. , Xi, X. G. , Luo, Z. Z. , 2017, Noise-assisted MEMD based relevant IMFs identification and EEG classification, *Journal of Central South University* , 3, 24, 599-608
- Cortés, A. , Sánchez, S. , Pizá, Á. G. , Albarracín, A. L. , Farfán, F. D. , Felice, C. J. , Fernández, E. , 2016, Time-frequency analysis of neuronal populations with instantaneous resolution based on noise-assisted multivariate empirical mode decomposition, *Journal of Neuroscience Methods* , 267, 35-44
- Cho, D. , Min, B. , Kim, J. , Lee, B. , 2016, EEG-based Prediction of Epileptic Seizures Using Phase Synchronization Elicited from Noise-Assisted Multivariate Empirical Mode Decomposition, *IEEE Transactions on Neural Systems and Rehabilitation Engineering* , 99, PP, 1-1
- Lin, C. S. , Tanumihardja, W. A. , Shih, H. H. , 2013, Lung-heart sound separation using noise assisted multivariate empirical mode decomposition, *Intelligent Signal Processing and Communications Systems (ISPACS)* , Naha, Japan.
- Lin, Y. -Y. , Wu, H. , Hsu, C. -A., Huang, P. -C. , Huang, Y. -H. , Lo, Y. -L. , 2017, Sleep Apnea Detection Based on Thoracic and Abdominal Movement Signals of Wearable Piezo-Electric Bands, *IEEE Journal of Biomedical and Health Informatics* , 6, 21, 1533-1545
- Khasnobish, A. , Bhattacharyya, S. , Singh, G. , Jati, A. , Konar, A. , Tibarewala, D. N. , Janarthanan, R. , 2013, The role of Empirical Mode Decomposition on Emotion Classification Using Stimulated EEG signals, *Advances in Computing and Information Technology* , 55-62
- Santillan-Guzman, A. , Fischer, M. , Heute, U. , Schmidt, G. , 2013, Real-time Empirical Mode Decomposition for EEG signal enhancement, *Signal Processing Conference (EUSIPCO)2013 Proceedings of the 21st European*, Marrakech, Morocco
- Petrantonakis, P. C. , Hadjileontiadis, L. J. , 2013, EEG-based emotion recognition using hybrid filtering and higher order crossings, *Affective Computing and Intelligent Interaction and Workshops, 2009. ACII 2009. 3rd International Conference on*, Amsterdam,, Amsterdam, Netherlands
- Shahnaz, C. , Masud, S. B. , Hasan, S. M. S. , 2016, Emotion recognition based on wavelet analysis of Empirical Mode Decomposed EEG signals responsive to music videos, *IEEE Region 10 Conference (TENCON)*, Singapore, Singapore
- Rutkowski, T. M. , Cichocki, A. , Ralescu, A. L. , Mandic, D. P. , 2008, Emotional States Estimation from Multichannel EEG Maps, *Advances in Cognitive Neurodynamics ICCN 2007*

- Bajaj, V. , Pachori, R. B. , 2011, EEG Signal Classification Using Empirical Mode Decomposition and Support Vector Machine, *International Conference on Soft Computing for Problem Solving*, At Roorkee, India
- Xu, H. , 2012, Towards Automated Recognition of Human Emotion using EEG, *Toronto, Canada: University of Toronto*
- Tonoyan, Y. , Looney, D. , Mandic, D. P. , Hulle, M. M. V. , 2012, Discriminating Multiple Emotional States from EEG Using a Data-Adaptive, Multiscale Information-Theoretic Approach, *International Journal of Neural Systems*, 26, 1650005 (15 pages),
- Yin, Y. , Cao, J. , Tanaka, T. , 2012, EEG energy analysis based on MEMD with ICA pre-processing, *Signal Information Processing Association Annual Summit and Conference (APSIPA ASC)*, Asia-Pacific
- Chen, X. , Xu, X. , Liu, A. , McKeown, M. J. , Wang, Z. J. , 2018, The Use of Multivariate EMD and CCA for Denoising Muscle Artifacts From Few-Channel EEG Recordings, *IEEE Transactions on Instrumentation and Measurement*, 2, 67, 359-370
- Chen, Y. -F. , Atal, K. , Xie, S. -Q. , Liu, Q. , 2017, A new multivariate empirical mode decomposition method for improving the performance of SSVEP-based brain-computer interface, *Journal of Neural Engineering*, 4, 14
- Azami, H. , Smith, K. , Escudero, J. , 2016, MEMD-enhanced multivariate fuzzy entropy for the evaluation of complexity in biomedical signals, *IEEE 38th Annual International Conference of the Engineering in Medicine and Biology Society (EMBC)*
- Khosropanah, P. , Ramli, A. R. , Lim, K. S. , Lim, K. S. , 2017, Fused multivariate empirical mode decomposition (MEMD) and inverse solution method for EEG source localization, *Biomedical Engineering / Biomedizinische Technik*
- Xu, H. , Plataniotis, K. N. , Lim, K. S. , Lim, K. S. , 2015, Application of Multivariate Empirical Mode Decomposition in EEG signals for Subject Independent Affective States Classification, *International Journal of Communications*, 9, 91-97
- Bhattacharyya, A. , Pachori, R. B. , 2017, A Multivariate Approach for Patient-Specific EEG Seizure Detection Using Empirical Wavelet Transform, *IEEE Transactions on Biomedical Engineering*, 9, 64
- Ricci, R. , Pennacchi, P. , 2011, Diagnostics of gear faults based on EMD and automatic selection of intrinsic mode functions, *Mechanical Systems and Signal Processing*, 3, 25, 821-838
- Cho, S. , Shahriar, R. , Chong, U. , 2014, Identification of significant intrinsic mode functions for the diagnosis of induction motor fault, *The Journal of the Acoustical Society of America* 136, 2, 36
- Boutana, D. , Benidir, M. , Barkat, B. , 2010, On the selection of Intrinsic Mode Function in EMD method: Application on heart sound signal, *3rd International Symposium on Applied Sciences in Biomedical and Communication Technologies*

- Uddin, B. , Uddin, J. , Sultana, R. , Islam, S. , 2016, A new machine learning approach to select adaptive IMFs of EMD, *2nd International Conference on Electrical, Computer & Telecommunication Engineering*
- Zhang,L. , Zhang, C. , Higashi,H. , Cao,J. , Tanaka, T. , 2011, Common Spatial Pattern Using Multivariate EMD for EEG Classification, *Asia-Pasific Signal and Information Processing Association*
- Channel, G. , Kierkels, J. J. M. , Suleymani, M. , Pun, T. , 2009, Short-term emotion assessment in a recall paradigm, *International Journal of Human-Computer Science*, 8, 67 , 607-627
- Wyczesany, M. , Ligeza, T. S. , 2015,Towards a constructionist approach to emotions: verification of the three-dimensional model of affect with EEG-independent component analysis, *Experimental Brain Research*, 3, 233 , 723-733
- Shipp, M. A. , Ross, K. N. , Tamayo, P., Weng, A. P. , Kutok, J. L. , Aguiar, R. C. , Gaasenbeek, M. , Angelo, M. , Reich, M. , Pinkus, G. S. , 2002, Diffuse large B- cell lymphoma outcome prediction by gene-expression profiling and supervised machine learning. *Nature medicine*, 8, 68-74.
- Hofmann, T. , 2001, Unsupervised learning by probabilistic latent semantic analysis, *Machine learning*, 42, 177-196.
- Boser, B. E. , Guyon, I. M. , Vapnik, V. N. A. , 1992, UA training algorithm for optimal margin classifiers, *Proceedings of the fifth annual workshop on Computational learning theory, ACM*, 144-152
- Vapnik, V. N. , Vapnik, V. , 1998, Statistical learning theory, *Wiley New York*.
- Osowski, S. , Siwek, K. , Markiewicz, T. , 2004, Mlp and svm networks-a comparative study, *Signal Processing Symposium, 2004. NORSIG 2004. Proceedings of the 6th Nordic*, 37-40
- Friedman, J. , Hastie, T. , Tibshirani, R. , 2001, The elements of statistical learning, *Springer series in statistics New York*
- Bishop, C. M. , 2006, Pattern recognition and machine learning, *Springer*
- Ben-hur, A. , Weston, J. , 2010, A user's guide to support vector machines, *Data mining techniques for the life sciences*, 223-239
- Lessmann, S. , Baesens, B. , Seow, H. V. , Thomas, L. C. , 2015, Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research, *European Journal of Operational Research*, 1, 247, 124-136
- Myoung, -J. , K. , Sung. , H. , M. , Ingoo, H. , 2006, An evolutionary approach to the combination of multiple classifiers to predict a stock price index, *Expert Systems with Applications*, 2, 31, 241-247
- Tsai, C. -F. , Hsiao, Y. -C. , 2011, Combining multiple feature selection methods for stock prediction: Union, intersection, and multi-intersection approaches, *Decision Support Systems*, 50, 258-269


- Finlay, S. , 2011, Multiple classifier architectures and their application to credit risk assessment, *European Journal of Operational Research*, 210, 368-378
- Paleologo, G. , Elisseeff, A. , Antonini, G. , 2010, Subagging for credit scoring models, *European Journal of Operational Research*, 201, 490-499
- Freund, Y. , Schapire, R. E. , 1996, Experiments with a New Boosting Algorithm. In L. Saitta (Ed.), *Proc. of the 13th Intern. Conf. on Machine Learning*, Bari, Italy: Morgan Kaufmann, 148-156)
- Mitchell, T. M. , 1997, Machine learning, *Boston: McGraw-Hill*
- Bell, J. F. , 1999, Application of classification trees to habitat preference of upland birds, *J Appl Stat*, 23, 349-359
- Duda, R. O. , Hart, P. E. , Stork, D. G. , 2000, Pattern classification, *2nd ed. New York: John Wiley Sons.*
- Mosier, C. I. , 1951, I. Problems and designs of cross-validation *I. Educational and Psychological Measurement*, 11, 5-11
- Browne, M. W. , 1951, Cross-validation methods, *Journal of mathematical psychology*, 44, 108-132
- Gutierrez, -O. R. , 2006, Lecture 13: Validation. Retrieved February, 28, 2007
- Cohen, L. , 1995, Time-frequency analysis. Chap. 5. , *Prentice Hall Signal Processing Series*
- Groutage, D. , Bennink, D. 2000, A new matrix decomposition based on optimum transaction of the singular value decomposition basis sets yields principal features of time-frequency distributions , *Proceedings of the tenth IEEE Workshop on Statistical Signal and Array Processing*, 598-602
- Nakos, G. , Joyner, D. , 1998, Linear Algebra with Applications, *Brooks/Coles Pub. Co.*
- Sreeshakthy, M. , Preethi, J. , Dhilipan, A. , 2016, A Survey On Emotion Classification From Eeg Signal Using Various Techniques and Performance Analysis, *I.J. Information Technology and Computer Science*, 12, 19-26
- Burges, C. J. , 1998, A tutorial on support vector machines for pattern recognition, *Data mining and knowledge discovery*, 2, 121-167
- Soman, K. , Loganathan, R. , Ajay, V. , 2009, Machine learning with SVM and other kernel methods, *PHI Learning Pvt. Ltd.*
- Cho, T. , Choi, J. -H. , Kim, H. -J., Choi, S. -M. , 2015, Emotional Avatars: Appearance Augmentation and Animation based on Facial Expression Analysis, *Applied Mathematics & Information Sciences*, 9, 461-469
- Mallat, S. G. , 1989, A Theory for Multiresolution Signal Decomposition: The Wavelet Representation, *IEEE Transactions on Patterns Analysis and Machine Intelligence*, 7, 13

- Aydin, S. G. , Kaya, T. , Guler, H. , 2016, Wavelet-based study of valence–arousal model of emotions on EEG signals with LabVIEW, *Brain Informatics*, 2, 3, 109-117.
- Lan, Z. , Sourina, O. , Wang, L. , Liu, Y. , 2016, Real-time EEG-based emotion monitoring using stable features, *The Visual Computer*, 3, 32
- <http://www.androidreview.com/html/emorate.php>
- Vamvakousis, Z. , Ramirez, R. , 2012, A Brain-Gaze Controlled Musical Interface, *Advances in Neurotechnology*, 4
- Kirke, A. , Miranda, E. , 2011, Combining EEG Frontal Asymmetry Studies with Affective Algorithmic Composition and Expressive Performance Models, *Proceedings of 37th International Computer Music Conference (ICMC)*
- Ramirez, R. , Vamvakousis, Z. , 2012, Detecting Emotion from EEG signals Using the Emotive Epoc Device, *Brain Informatics. BI 2012. Lecture Notes in Computer Science*, 7670
- Ramirez, R. , Palencia-Lefler, M. , Giraldo, S. , Vamvakousis, Z. , 2012, Musical neuro-feedback for treating depression in elderly people, *Frontiers in Neuroscience*, 354, 15, 1-10
- Oberlin, T. , Meignen, S. , Perrier, V. , 2014, The Fourier-based synchrosqueezing transform, *Acoustics, Speech and Signal Processing (ICASSP), 2014 IEEE International Conference on*, Florence, Italy
- Ozel, P. , Akan, A. , Yilmaz, B. , 2018a, Noise Assisted Multivariate Empirical Mode Decomposition Based Emotion Recognition, *ELECTRICA*, 2 ,18.
- Ozel, P. , Akan, A. , Yilmaz, B. , 2018b, Emotion Modelling Based on Multivariate Adaptive Orthogonal Signal Decomposition, *1st International Symposium on Graduate Research in Science, Focus on Entrepreneurship and Innovation*
- Ozel, P. , Akan, A. , Yilmaz, B. , 2018c, Emotion Sensing Analysis based on Gamma Band-EEG, *16. Ulusal Sinir Bilimleri Kongresi (USK)*
- Ozel, P. , Akan, A. , Yilmaz, B. , 2018d, Emotion Detection Using Multivariate Synchrosqueezing Transform via 2D Circumplex Model, *Medical Technologies National Congress (TIPTEKNO)*
- Ozel, P. , Akan, A. , Yilmaz, B. , 2018e, Emotional State Sensing by Using Hybrid Multivariate Empirical Mode Decomposition and Synchrosqueezing Transform, *Medical Technologies National Congress (TIPTEKNO)*
- Ozel, P. , Akan, A. , Yilmaz, B. , 2017b, Emotional State Analysis from EEG signals via Noise-Assisted Multivariate Empirical Mode Decomposition Method, *10th International Conference on Electrical and Electronics Engineering (ELECO)*
- Ozel, P. , Akan, A. , Yilmaz, B. , 2017c, Emotion recognition classification in EEG signals using multivariate synchrosqueezing transform, *Medical Technologies National Congress (TIPTEKNO)*

- Kotan, S. , Akan, A. , 2018, Güç Yoğunluk Spektrumu Tabanlı Yeni Bir Öz Kip Fonksiyonu Seçme Yöntemi, *Medical Technologies National Congress (TIPTEKNO)*
- Walter, S. , Kim, J. , Hrabal, D. , Crawcour, S. C. , Kessler, H. , Traue, H. C. , 2013, Trans-situational Individual-Specific Biopsychological Classification of Emotions, *IEEE Transactions on Systems, Man and Cybernetics Systems*, 4, 43
- Guendil, Z. , Lachiri, Z. , Maaoui, C. , 2017, Computational framework for emotional VAD prediction using regularized Extreme Learning Machine, *International Journal of Multimedia Information Retrieval*, 3, 6, 251-261
- Iacoviello, D. , Petracca, A. , Spezialetti, M. , Placidi, G. , 2015, A Real-time Classification Algorithm for EEG-based BCI Driven by Self-induced Emotions, *Computer Methods and Programs in Biomedicine*, 3, 122, 293-303

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Pınar ÖZEL
Doğum Yeri	Kayseri
Doğum Tarihi	26.12.1984
Uyruğu	☒ T.C. ☐ Diğer:
Telefon	0505 650 43 82
E-Posta Adresi	pinarozel@nevsehir.edu.tr
Web Adresi	http://biz.nevsehir.edu.tr/pinarozel



Eğitim Bilgileri	
Lisans	
Üniversite	Erciyes Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Elektrik-Elektronik Mühendisliği Bölümü
Mezuniyet Yılı	2007

Yüksek Lisans	
Üniversite	Boğaziçi Üniversitesi
Enstitü Adı	Biyomedikal Mühendisliği Entitüsü
Anabilim Dalı	Biyomedikal Mühendisliği Anabilim Dalı
Programı	Biyomedikal Mühendisliği Programı
Mezuniyet Tarihi	2011

Doktora	
Üniversite	İstanbul Üniversitesi
Enstitü Adı	Fen Bilimleri
Anabilim Dalı	Biyomedikal Mühendisliği Anabilim Dalı
Programı	Biyomedikal Mühendisliği Programı
Mezuniyet Tarihi	2019

Makale ve Bildiriler	
Makaleler	
Ozel, P. , Akan, A. , Yılmaz, B. , 2018, Noise Assisted Multivariate Empirical Mode Decomposition Based Emotion Recognition, ELECTRICA, 2, 18	
Bildiriler	
Ozel, P. , Akan, A. , Yılmaz, B. , 2018, Emotion Modelling Based on Multivariate Adaptive Orthogonal Signal Decomposition, 16. Ulusal Sinir Bilimleri Kong-	

resi (USK)

- Ozel, P.** , Aydın, A. , Yılmaz, B. , 2018, Emotion Sensing Analysis based on Gamma Band-EEG, 1st International Symposium on Graduate Research in Science, Focus on Entrepreneurship and Innovation
- Ozel, P.** , Akan, A. , Yılmaz, B. , 2018, Emotion Detection Using Multivariate Synchrosqueezing Transform via 2D Circumplex Model, Medical Technologies National Congress (TIPTEKNO)
- Ozel, P.** , Akan, A. , Yılmaz, B. , 2018, Emotional State Sensing by Using Hybrid Multivariate Empirical Mode Decomposition and Synchrosqueezing Transform , Medical Technologies National Congress (TIPTEKNO)
- Ozel, P.** , Akan, A. , Yılmaz, B. , 2017, Multivariate Pseudo Wigner Ville Distribution based Emotion Detection from Electrical Activity of Brain, 10th International Conference on Electrical and Electronics Engineering (ELECO)
- Ozel, P.** , Akan, A. , Yılmaz, B. , 2017, Emotional State Analysis from EEG Signals via Noise-Assisted Multivariate Empirical Mode Decomposition Method, 10th International Conference on Electrical and Electronics Engineering (ELECO)
- Ozel, P.** , Akan, A. , Yılmaz, B. , 2017, Emotion Recognition Classification in EEG signals Using Multivariate Synchrosqueezing transform, Medical Technologies National Congress (TIPTEKNO)
- Ozel, P.** , Akan, A. , Yılmaz, B. , 2017, Emotion Elicitation Analysis in Multi-channel EEG Signals Using Multivariate Empirical Mode Decomposition and Discrete Wavelet Transform, Medical Technologies National Congress (TIPTEKNO)
- Ozel, P.** , Duru, A. D. , Erdoğan, S. B. , Uslu, F. İ. , Ademoğlu, A. , 2010, Determination and Anatomical Mapping of Thalamic Stroke Regions to Anatomical Atlas, 15. Biyomedikal Mühendisliği Ulusal Toplantısı (BIYOMUT)
- Kara, S. , **Ozel, P.** , 2007, Müzik Yoluyla Değişen Ritimlerin Yüzeysel EMG ile Analizi, 12. Biyomedikal Mühendisliği Ulusal Toplantısı (BIYOMUT)
- Kara, S. , **Ozel, P.** , 2007, Determination of Effects of Different Music on Frontal Muscle by Using EMG Signal, Frontiers in the Convergence of Bioscience and Information Technologies (FBIT))