

T.C.
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**İYİ – KÖTÜ KOKULAR İLE İLİŞKİLİ EMOTİV – EPOC TABANLI
EEG KAYITLARININ MAKİNA ÖĞRENMESİ YÖNTEMLERİ İLE
SINIFLANDIRILMASI**

Mesut ŞEKER

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DİYARBAKIR

Haziran-2017

T.C
DİCLE UNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ
DİYARBAKIR

Mesut ŞEKER tarafından yapılan “İyi – kötü kokular ile ilişkili EMOTIV- EPOC tabanlı EEG kayıtlarının Makine Öğrenmesi yöntemleri ile sınıflandırılması” konulu bu çalışma, jürimiz tarafından Elektrik - Elektronik Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir

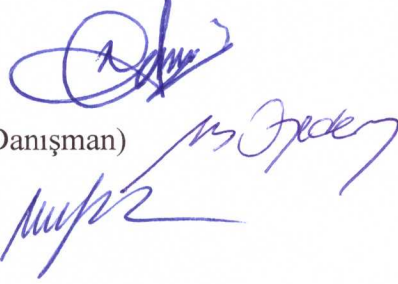
Jüri Üyesinin

Ünvanı Adı Soyadı

Başkan: Doç. Dr. Necmettin SEZGİN

Üye : Doç. Dr. Mehmet Sıraç ÖZERDEM (Danışman)

Üye : Yard. Doç. Dr. Abdulnasır YILDIZ



Tez Savunma Sınavı Tarihi: 20/06/2017

Yukarıdaki bilgilerin doğruluğunu onaylarım.

.../...../20

Doç.Dr.Sevtap SÜMER EKER

ENSTİTÜ MÜDÜR V.

(MÜHÜR)

TEŐEKKÜR

Bu tez alıőması boyunca birikimlerini ve tecrübelerini benden esirgemeyen deęerli danıőmanım Do. Dr. Mehmet Sıra ÖZERDEM'e yol gostericilięi adına teőekkürlerimi sunuyorum.

Ayrıca maddi – manevi desteklerini benden esirgemeyen aileme, tez boyunca bana destek olan alıőma arkadaşlarıma teőekkürü bir bor bilirim.



İÇİNDEKİLER

	Sayfa
TEŞEKKÜR.....	I
İÇİNDEKİLER.....	II
ÖZET.....	IV
ABSTRACT.....	V
ÇİZELGE LİSTESİ.....	VI
ŞEKİL LİSTESİ.....	VII
KISALTMA VE SİMGELER.....	IX
1. GİRİŞ.....	1
1.1. Nörolojik İşaret Ölçüm Teknikleri.....	1
1.2. Koku Olgusu ve Biyolojik Olarak Kokunun Algılanma Süreci.....	5
1.3. Tez Kapsamında Analiz Olarak İzlenen Temel Yaklaşım.....	7
2. KAYNAK ÖZETLERİ.....	9
3. MATERYAL VE METOT.....	25
3.1. Veri Setinin Oluşturulması	25
3.1.1. Kokuların Seçimi ve Deney Kurulumu.....	25
3.1.2. Kokuların Uygulanması (Paradigma)	27
3.1.3. Kullanılan Koku Uyartılarının Değerlendirilmesi	28
3.2. Dalgacık Dönüşümü ile Öznitelik Çıkarımı.....	30
3.2.1. Dalgacık Kavramı ve Genel Kullanılan Ana Dalgacıklar.....	32
3.2.2. Sürekli Dalgacık Dönüşümü (SDD).....	35
3.2.3. Ayrık Dalgacık Dönüşümü (ADD).....	35
3.3. Sınıflandırıcı Olarak Bir Veri Madenciliği Programı: WEKA.....	37
3.3.1. Sınıflandırıcı Olarak Yapay Sinir Ağları (YSA).....	39
3.3.2. Sınıflandırıcı olarak Naive Bayes (NB) Algoritması	42
3.3.3. Sınıflandırıcı Olarak k- En Yakın Komşuluk (kNN) Algoritması.....	43
3.3.4. Sınıflandırıcı Olarak Rastgele Orman (RO) Algoritması	44
3.4. Kanal Seçimi İçin Diferansiyel Gelişim Algoritması (DGA).....	46

3.4.1	Lineer Diskriminant Analiz (LDA).....	46
4.	ARAŞTIRMA BULGULARI	49
4.1.	Koku Seçimi	50
4.2.	ADD Kullanılarak EEG İşaretlerine Ait Öznitelik Çıkarımı	58
4.3.	İstatiksel İşlemlerle Öznitelik Boyutunun Küçültülmesi	60
4.4.	EEG Öznitelik Vektörlerinin WEKA ile Sınıflandırılması	62
4.5.	DGA ile Kanal Seçimi ve Sınıflandırma İşlemlerinin Tekrarlanması	68
5.	TARTIŞMA VE SONUÇ	73
6.	KAYNAKLAR	77
	ÖZGEÇMİŞ.....	83

ÖZET

İYİ – KÖTÜ KOKULAR İLE İLİŞKİLİ EMOTİV- EPOC TABANLI EEG KAYITLARININ MAKİNA ÖĞRENMESİ YÖNTEMLERİ İLE SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Mesut ŞEKER

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

2017

Koku uyarısının beynin elektriksel aktivitesi üzerinde etkileri olduğu bilinmektedir. Kokunun kişinin hislerine, davranışlarına ve ruh haline etkisi yadsınmaz. Birçok dış uyarana göre kokuların hem duyuşsal hem de bilişsel etkileri, kokuyu karmaşık bir olgu haline getirmiştir. Bu yüzden koku verilerinin insan sinir sistemi üzerine olan etkileri henüz kesin yargılarla ifade edilememektedir. Ayrıca koku fonksiyonu, bazı nörolojik hastalıklardan (Parkinson, Alzheimer, motor nöron rahatsızlıkları) etkilenmekte, kokuya olan hassasiyet, farklı kokuları ayırt etme ve kokuyu tanıma algısı azalabilmektedir. Klinik tedavilerde bu durum bazen gözden kaçırılmaktadır.

Beynin elektriksel aktivitesini inceleyebilmek için birçok elektro-fizyolojik yöntemler bulunmaktadır. Bu yöntemlerden biri olan Elektroensefalogram (EEG), beynin işleyişi hakkında yorumlar yapabilmek için önemli bir kaynaktır.

Bu çalışmada iyi – kötü koku verilerine ilişkin EEG işaretlerinin analizi ve sınıflandırılması amaçlanmıştır. Katılımcılara uygulanan değerlendirme anketleri ve kokulara ait güç spektrum grafikleri yardımıyla en baskın 2’şer iyi – kötü koku belirlenmiştir. Kokulara ait EEG verilerine ayırık dalgacık dönüşümü (ADD) uygulanmış ve istatistiksel işlemlerle öznitelik vektör boyutu azaltılmıştır. Sınıflandırıcı olarak WEKA veri madenciliği programına ait çok katmanlı algılayıcılar, k-en yakın komşuluk, naive bayes ve rastegele orman algoritmaları kullanılmıştır. Diferansiyel gelişim algoritması ile kanal seçimi yapıp sınıflandırma işlemleri tekrarlanmış ve sonuçlar karşılaştırılmıştır. Tüm kanalların kullanıldığı aşamada, her katılımcıya ait en başarılı 2 bandın birleştirildiği sınıflandırma sonuçlarına bakıldığında NB % 70.93, kNN % 92.76, ÇKA % 92.73 ve RO algoritması %99.19 başarı oranları elde edilmiştir. Seçilen 5 kanalın kullanıldığı aşamada sınıflandırma sonuçlarına bakıldığında NB % 68.45, kNN % 88.95, ÇKA % 88.83 ve RO algoritması %97.58 başarı oranları elde edilmiştir.

Mevcut çalışma ile beynin hangi bölgelerinin ve frekans bantlarının koku ile ilişkili olduğu kestirilmeye çalışılmıştır. Ayrıca yöntemin klinik tedavilerde bazı nörolojik hastalıkların erken tespitinde kullanılabileceği düşünülmektedir.

Anahtar Kelimeler: EEG, Koku, Dalgacık Dönüşümü, WEKA, Sınıflandırma, Kanal Seçimi

ABSTRACT

EMOTIV-EPOC BASED ELECTROENCEHALOGRAPHIC (EEG) RESPONSES TO PLEASANT - UNPLEASANT ODORS CLASSIFICATION USING MACHINE LEARNING ALGORITHMS

MsC THESIS

Mesut ŞEKER

DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
INSTITUTE OF NATURAL AND APPLIED SCIENCES
UNIVERSITY OF DICLE

2017

It is known that odor stimulus has effects on brain electrical activity. The odor effects on human emotions, behaviors and mood can not be denied. In contrast to other external stimulus, odor perception is a complex event due to its sensory and cognitive manners, so there is no exact statement for the effects of odors on human central nervous system. Some odor dysfunctions may appear as a result of some neurologic disease (Parkinson, Alzheimer, motor neuron disease, etc.). The sense of odor, ability to distinction different odors and recognizing odors can be decreased in these diseases. This situation is sometimes ignored in clinical treatment.

There are bunch of electro-physiological methods to analyse brain electrical activity. One of these method is Electroencehalogram (EEG) that is known as a good source to comment about functioning of brain.

In this study, it is aimed to analyze and classify the EEG responses related to pleasant – unpleasant odors. By the help of surveys belong to participant and graphs of power spectrum density, most dominant pleasant – unpleasant (two of each) odors were determined. Discrete Wavelet Transform (DWT) was applied to EEG odor responses and dimension of feature vectors was decreased by using some statistical operations. Multilayer perceptron, k-nearest neighbor, Naive Bayes and random forest algorithm were used as classifiers which belong to WEKA data mining program. Channel selection was performed to whole dataset by using differential evolution algorithm. Classification procedure was repeated and the results were compared with previous ones. When using whole channels, NB gives 70.93 %, kNN gives 92.76 %, MLP gives 92.73 % and finally RF gives 99.19 % classification rate if we combine 2 best EEG subbands belong to each participant. In same manner, when using 5 selected channels, NB gives 68.45 %, kNN gives 88.95 %, MLP gives 88.83 % and finally RF gives 97.58 % classification rate.

In present study, it is going to be examined which part of brain and frequency bands are responsible for odors. Besides, it is thought that proposed work is advisable to detect some neurological diseases in early stages.

Keywords: EEG, Odor, Wavelet Transform, WEKA, Classification, Channel selection

ÇİZELGE LİSTESİ

<u>Çizelge No</u>		<u>Sayfa</u>
Çizelge 1.1.	EEG işaretlerine ait bant frekansları	3
Çizelge 3.1.	EMOTIV – EPOC başlığına ait teknik özellikler	26
Çizelge 3.2.	Başlığa ait kanal numaraları ve etiketleri	27
Çizelge 3.3.	Katılımcılara (A-B-C-D-E-F) ait hoşnutluk durumu (0-9)	28
Çizelge 3.4.	Yapay ve biyolojik sinir arasındaki benzetimler	39
Çizelge 4.1.	EEG alt bantlarına karşılık gelen yaklaşım ve detay katsayıları	59
Çizelge 4.2.	Tüm kanalları kullanarak yapılan sınıflandırma işlemi	67
Çizelge 4.3.	Seçilen kanalları kullanarak yapılan sınıflandırma işlemi	70

ŞEKİL LİSTESİ

<u>Sekil No</u>		<u>Sayfa</u>
Şekil 1.1.	10–20 Sistemine Göre Elektrotların Dizilimi A)Profilden B) Üstten görünüm	2
Şekil 1.2.	Yüzey elektrotları aracılığıyla farklı kanallardan alınmış örnek EEG kayıtları	3
Şekil 1.3.	EEG işaretlerine ilişkin alt bantlar	4
Şekil 1.4.	Örnek bir ERP işaretinin gösterimi	5
Şekil 1.5.	Koku bölgesine ait kısımların beyin üzerindeki gösterimi	6
Şekil 1.6.	Koku hissinin yorumlanma sürecinde takip edilen yol	6
Şekil 1.7.	Koku verilerine ilişkin EEG verilerinin incelenmesinde genel yaklaşım	8
Şekil 3.1.	Başlığa ait elektrotların 10 – 20 sistemine göre dizilimi	26
Şekil 3.2.	8 farklı kokunun uygulama adımları	27
Şekil 3.3.	Katılımcılara uygulanan değerlendirme anketi	28
Şekil 3.4.	Kısa Zamanlı Fourier Dönüşümü	31
Şekil 3.5.	Dalgacık dönüşümü	32
Şekil 3.6.	Ana dalgacığın kaydırılması ve ölçeklenmesi	33
Şekil 3.7.	Haar dalgacığı	33
Şekil 3.8.	Meksika şapkası dalgacığı	34
Şekil 3.9.	Morlet dalgacığı	34
Şekil 3.10.	Daubechies ailesinden bazı ana dalgacıklar	34
Şekil 3.11.	Filtreler yardımıyla işaretin yaklaşım ve detay bileşenlerinin elde edilmesi	36
Şekil 3.12.	ADD yöntemiyle işaretin alt banlarının elde edilmesi	36
Şekil 3.13.	WEKA açılış menüsü	37
Şekil 3.14.	Dosya açma penceresi	37
Şekil 3.15.	Sınıflandırma algoritmalarını seçim penceresi	38
Şekil 3.16.	Yapay sinir hücresi modeli	39
Şekil 3.17.	YSA'da kullanılan Aktivasyon Fonksiyonları (a) basamak (b) doğrusal (c) log - sigmoid (d) tan - sigmoid	40
Şekil 3.18.	Çok katmanlı YSA yapısı	41
Şekil 3.19.	Bilinmeyen nesnenin bir sınıfa dahil edilme süreci	44

Şekil 3.20.	Nesnenin sınıflandırılması	44
Şekil 3.21.	Rastgele Orman algoritmasına ait örnek bir ağaç yapısı	45
Şekil 3.22.	LDA karar bölgesi	47
Şekil 4.1.	Mevcut çalışmanın akış diyagramı	49
Şekil 4.2.	Koku Seçimi	50
Şekil 4.3.	<i>Welch yönteminin</i> koku verisine uygulanışı	51
Şekil 4.4.	AF3 kanalına ait spektral güç yoğunluğu	51
Şekil 4.5.	F7 kanalına ait spektral güç yoğunluğu	52
Şekil 4.6.	F3 kanalına ait spektral güç yoğunluğu	52
Şekil 4.7.	FC5 kanalına ait spektral güç yoğunluğu	53
Şekil 4.8.	T7 kanalına ait spektral güç yoğunluğu	53
Şekil 4.9.	P7 kanalına ait spektral güç yoğunluğu	54
Şekil 4.10.	O1 kanalına ait spektral güç yoğunluğu	54
Şekil 4.11.	O2 kanalına ait spektral güç yoğunluğu	55
Şekil 4.12.	P8 kanalına ait spektral güç yoğunluğu	55
Şekil 4.13.	T8 kanalına ait spektral güç yoğunluğu	56
Şekil 4.14.	FC6 kanalına ait spektral güç yoğunluğu	56
Şekil 4.15.	F4 kanalına ait spektral güç yoğunluğu	57
Şekil 4.16.	F8 kanalına ait spektral güç yoğunluğu	57
Şekil 4.17.	AF4 kanalına ait spektral güç yoğunluğu	58
Şekil 4.18.	4. Seviye ADD akış diyagramı	59
Şekil 4.19.	ADD'nin verilere uygulanma sistematığı	60
Şekil 4.20.	Tüm kanallara ait iyi – kötü kokuların sınıflandırma akış şeması	62
Şekil 4.21.	WEKA ara yüzündeki ÇKA'ya ait parametreler	63
Şekil 4.22.	WEKA ara yüzündeki NB'ye ait parametreler	64
Şekil 4.23.	WEKA ara yüzündeki k-NN'e ait parametreler	65
Şekil 4.24.	WEKA ara yüzündeki RO'ya ait parametreler	66
Şekil 4.25.	Kanal seçimi aşamaları	68
Şekil 4.26.	Belirlenen en iyi 5 kanal ardına sınıflandırma işlemleri	69

KISALTMA VE SİMGELER

EEG	: Elektroensefalogram
ADC	: Analog – Dijital Konvertör
ERP	: Event-Related Potential
PET	: Pozitron Emisyon Tomografi
fMRI	: Fonksiyonel Manyetik Rezonans Görüntüleme
PE	: Permütasyon Entropi
LDA	: Lineer Diskriminant Analiz
FK	: Frontal Korteks
CK	: Central Korteks
EKG	: Elektrokardiyogram
HRV	: Heart Rate Variability
PC	: Prefrontal Korteks
PSD	: Güç Spektrum Yoğunluğu
DVM	: Destek Vektör Makinası
FFT	: Hızlı Fourier Dönüşümü
PCA	: Temel Bileşen Analizi
LDA	: Doğrusal Ayrıcılık Analizi
EP	: Uyarılmış Potansiyel
FD	: Fourier Dönüşümü
KZFD	: Kısa Zamanlı Fourier Dönüşümü
SE	: Shannon Entropisi
ApEn	: Yaklaşık Entropi
SamEn	: Örnek Entropi
ADD	: Ayrık Dalgacık Dönüşümü
SDD	: Sürekli Dalgacık Dönüşümü
NB	: Naive Bayes
ÇKA	: Çok Katmanlı Algılayıcılar
ROA	: Rastgele Orman Algoritması
DGA	: Diferansiyel Gelişim Algoritması
YSA	: Yapay Sinir Ağları
k-NN	: k En Yakın Komşuluk
nfft	: FFT hesabı için gereken nokta sayısı
Hz	: Hertz

μV	: micro - volt
d	: Uzaklık
$\psi(x)$: Dalgacık Fonksiyonu
$w(n)$: Pencere Fonksiyonu
$g[n]$: Alçak geçiren filtre
$h[n]$: Yüksek geçiren filtre
a	: Ölçekleme faktörü
b	: Öteleme parametresi
$cA1$: Birinci derece yaklaşım dalgacık katsayısı
$cD1$: Birinci derece detay dalgacık katsayısı
$db2$: Daubechies dalgacığı
w_i	: Ağırlıklar
x_i	: Girişler
y_i	: Çıkışlar
$f(n)$:Aktivasyon fonksiyonu
θ	: Teta bandı
α	: Alfa bandı
β	: Beta bandı
γ	:Gama Bandı
δ	: Delta bandı

1. GİRİŞ

İnsanlar geçmişten bu yana görsel, işitsel ve koku gibi dış uyaranlara oldukça maruz kalmaktadırlar. Bu uyaranlar kişilerin davranışlarına, hislerine, ruhsal durumlarına olumlu veya olumsuz yönde etkiler göstermektedir. Kötü kokulara karşı tikslenme ve irkilme tepkisi, iyi kokuların ise rahatlatıcı etkisi, kokuların insan merkezi sisteminde ne gibi bir yeri olduğunu sorgulamamıza neden olmaktadır.

Koku kavramı diğer dış uyaranlara nispeten daha karmaşık bir kavramdır. Koku duyusunun incelenmesi, insan merkezi sisteminin verdiği yanıtları yorumlayarak mümkündür. Elektroensefalogram (EEG) işaretleri, insan beyni hakkında önemli bilgiler içerdiğinden, bu amaca yönelik rahatlıkla kullanılabilir.

Bu çalışmada, iyi – kötü kokulara ait EEG kayıtlarının analiz edilip sınıflandırılması amaçlanmıştır. Yapılan çalışmalar, EEG kayıtlarına ait belirgin özniteliklerin çıkarılıp, bunların çeşitli sınıflandırma algoritmaları ile sınıflandırılmasına dayanmaktadır.

Bu bölümde konuya açıklık getirmek açısından, başta EEG olmak üzere nörolojik görüntüleme teknikleri, koku algısının oluşma şekli, koku – EEG ilişkisine dair ilk örnekler ve bu çalışmada izlenen temel yaklaşımlar üzerinde durulacaktır.

1.1. Nörolojik İşaret Ölçüm Teknikleri

a) Nörolojik Görüntülemeye Dayalı Teknikler

EEG işaretleri yüzey elektrotları üzerinden beyne ait elektriksel işaretleri elde etmemizi sağlarken, Pozitron Emisyon Tomografi (PET) ve Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI) gibi görüntüleme yöntemleri ile beyin yüzeyinden daha derinde yer alan yapılarıdaki değişimleri de incelememiz mümkündür. PET beyindeki kanın hacmini, fMRI ise beyindeki oksijen yoğunluğunu resmeder. Tekniklere göre beyin kılcallarındaki kanın hacmindeki ve oksijen yoğunluğundaki artış, o bölgelerdeki aktivasyon yoğunluğunun göstergesidir.


b) EEG

EEG, beyin tarafından üretilen elektriksel aktivite değişimlerinin kafatası üzerinden okunmasına dayalı bir tıbbi görüntüleme tekniğidir. Elektrotlar ve iletken bir ortam yardımıyla kafatası yüzeyinden toplanıp kaydedilen elektriksel akım değişimleri EEG kayıtları olarak tanımlanır (Teplan 2002).

1. GİRİŞ


İngiliz fizikçi Rirhard Caton 1875 yılında maymun ve tavşanları inceleyerek beyindeki ilk elektriksel değişim kavramını ortaya atmıştır. 1924 yılında Alman nörolog Hans Berger, kendi radyo ekipmanlarından yaptığı düzenekle kafatası yüzeyindeki elektriksel aktiviteleri güçlendirmeyi başarmıştır. Kafatasını açmadan yüzeysel değişimleri kağıt üstüne aktararak beynin uyku, anestezi, nörolojik rahatsızlık ve oksijen azlığı gibi durumlarını gözlemleyebilmiştir. 1934 yılında Adrian ve Matthews yayınladıkları insan beynine ait dalgalarla ilgili makalelerinde ilk defa alfa ritmini vurgulamışlardır (Bronzino 2000).

Yüzey elektrotları uluslararası bir standart olan 10-20 sistemine göre kafatasına yerleştirilir. Bu sistemde elektrotlar burun ve başın arka kısmı arasına %10 – 20 – 20 – 20 – 20- 10 olacak dizilir (Jurcak ve ark. 2007). Elektrotların diziliş düzeni Şekil 1.1.'de gösterilmiştir. Elektrotlardan alınan ölçümler kuvvetlendirici devrelerin yardımıyla mikrovolt (μV) seviyesine getirilerek okunur hale gelir. Analog-dijital (A/D) dönüştürücü ile işaretler dijital bir ortamda kaydedilir.



Şekil 1.1. 10 – 20 Sistemine Göre Elektrotların Dizilimi A) Profilden B) Üstten görünüm

İnsan kafasından alınan örnek bir kayıt Şekil 1.2.'de gösterilmiştir. Düşey eksen μV kademesinde işarete ait büyüklüğü, yatay eksen ise zaman bilgisini göstermektedir.



Şekil 1.2. Yüze elektrotları aracılığıyla farklı kanallardan alınmış örnek EEG kayıtları

-EEG İşaretlerine Ait Alt Bantlar

EEG işaretleri belirli genlik, faz ve frekansa sahip periyodik olmayan işaretlerdir. EEG'ye ait frekans bileşenlerindeki aktivite, beynin o anki işlevine göre değişiklik gösterdiği birçok çalışmada görülmektedir [(Kroupi ve ark. 2014), (Martin 1998), (Placidi 2015)]. EEG işaretlerine ait anlam içeren bant bileşenleri ve bunlara ait frekans aralıkları Çizelge 1.1.'de gösterilmiştir.

Çizelge 1.1. EEG işaretlerine ait bant frekansları

Delta (δ)	0.5 – 4 Hz
Teta (θ)	4 – 8 Hz
Alfa (α)	8 – 13 Hz
Beta (β)	13 – 30 Hz
Gamma (γ)	30 – 100 Hz

1. GİRİŞ

Delta Bandı (δ) : Genellikle 4 Hz altındaki düşük frekans bandına karşılık gelir. Kişilerde derin uyku durumunda gözlenir (Placidi ve ark. 2015).

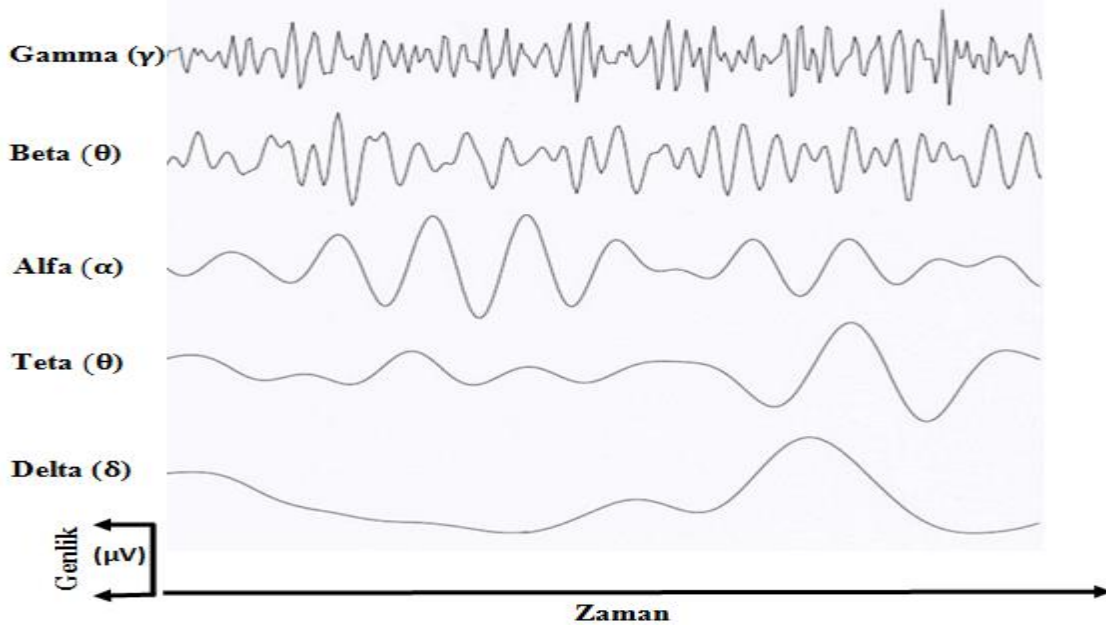
Teta Bandı (θ) : Genellikle kişilerde uyuşukluk ve dinginlik anında gözlemlenir. Frekans aralığı 4 – 8 Hz arasında değişip genlikleri 100 μ V (p-p)'den küçüktür (Placidi ve ark. 2015).

Alfa Bandı (α) : Gözler açıkken ve kişiler uyanıkken daha aktif olan bir banttır. Yoğunluk ve konsantrasyon anlarında bant gücünde azalma görülür. Frekans aralığı 8 – 14 Hz arasında değişir. Genlikleri genelde 50 μ V altındadır (Placidi ve ark. 2015).

Beta Bandı (β) : Aktif düşünme ve konsantrasyon anında belirgin olarak gözlenir. Alfa bandına göre daha yüksek frekansa ve daha düşük genliğe sahiplerdir. Frekans aralığı 14 – 30 Hz arasında değişir (Placidi ve ark. 2015).

Gamma Bandı (γ) : Gamma bandı klinik çalışmalarda genelde göz ardı edilse de zihinsel işlemler, hafıza, karşılaştırma ve duygusal durumlarla yakından ilgilidir. Beyne ait yüksek frekans bileşenlerini temsil eder (Placidi ve ark. 2015).

Bahsi geçen EEG alt band bileşenlerine ait örnek çizimler Şekil 1.3.'de görülmektedir.

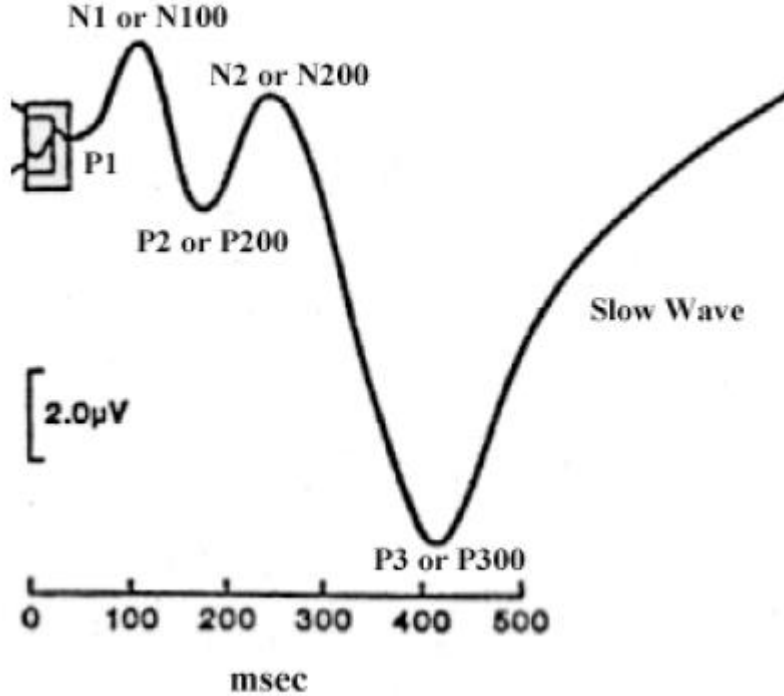


Şekil 1.3. EEG işaretlerine ilişkin alt bantlar

c) ERP (Event-Related Potential)

EEG ile beynin sinirsel davranışıyla ilgili uzun bir zaman skalasında bilgi elde edilirken, ERP işaretleri, uyarının (görsel, işitsel, koku vb.) hemen ardından meydana

gelen sinirsel deęişimleri incelememize olanak verir. Kısa süreler içinde sinirsel deęişimleri incelemeye olanak tanıdığından, zaman çözünürlüğü ERP’de oldukça fazladır. Şekil 1.4.’de örnek bir ERP işareti gösterilmiştir.



Şekil 1.4. Örnek bir ERP işaretinin gösterimi

ERP işaretleri pozitif (P) veya negatif (N) formlarda olurlar. Genel olarak P aşağı doğru, N ise yukarı doğru tepe noktalarını gösterir. P ve N’nin ardına gelen 1, 2, 3 rakamları, işaretin ortaya çıkış süresi olan 100 ms, 200 ms ve 300 ms’nin kısa formlarıdır. P ve N’nin büyüklüğü o anki uyarının yoğunluğuyla ilgilidir. Daha büyük bileşen, o an daha aktive olmuş bir nöron anlamına gelir. İşaretlerinin ortaya çıkış süreleri ise o anki tepkinin hızını gösterir. Daha küçük zaman değerleri, daha hızlı tepki veren nöron anlamına gelmektedir. P1, P2, P3, N1 ve N2 dalga formları beyin araştırmalarında sıkça kullanılmaktadır (Key ve ark. 2005).


1.2. Koku Olgusu ve Biyolojik Olarak Kokunun Algılanma Süreci

İnsana ait koku fonksiyonunun işlevselliği, birçok nörolojik hastalıklardan (Parkinson, Alzheimer, Huntington, motor nöron rahatsızlıkları vb.) dolayı azalmaktadır. Kişilerin kokulara olan hassasiyetleri, kokuları tanıma ve ayırt etme kabiliyetleri bu rahatsızlıklardan etkilenmektedir. Klinik tedavilerde bu durum çoğu zaman ihmal

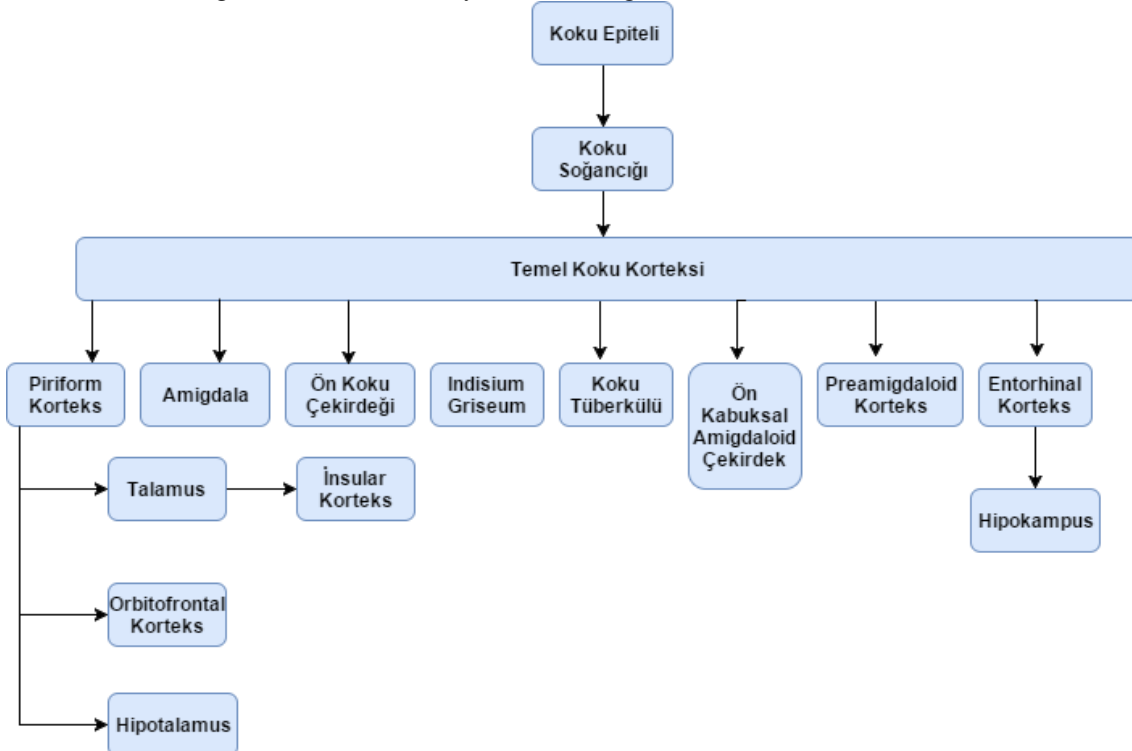
1. GİRİŞ

edilmektedir. Koku fonksiyonu, klinik tedavilerde nörolojik hastalıkların erken teşhisini belirlemede önemli bir işaret olarak kullanılabilir (Barresi ve ark. 2012).

Koku kavramı insan beyninde bilişsel ve hissi olgularla bağlantılı olduğundan karmaşık bir yapıdadır. Bu karmaşık olguya ait fizyolojik yapıyı incelemek de oldukça önemlidir. Koku bölgesine ait kısımların beyin üzerindeki gösterimi Şekil 1.5.'de gösterilmiştir. Kokunun algılanmasına kadar takip ettiği yol Şekil 1.6.'de gösterilmiştir. Bu fizyolojik yapıya ait en önemli bileşenler Koku Soğancığı, Piriform Korteks, Amigdala ve Entorhinal Korteks'dir.



Şekil 1.5. Koku bölgesine ait kısımların beyin üzerindeki gösterimi



Şekil 1.6. Koku hissini yorumlanma sürecinde takip edilen yol

-Koku Soğancığı: Gelen koku işaretleri ilk bu merkezde toplanır. Beynin ön bölümünde bulunur. Koku daha sonra sinirler vasıtası ile diğer kısımlara iletilir (Barresi ve ark. 2012).

-Piriform Korteks: Temporal lobun ucuna ve iç kısmına yerleştirilmiştir. Farklı kokuların ayırt edilmesinde önemli rol oynar. Bu bölge hasar görürse koku halüsinasyonları görülebilir (Barresi ve ark. 2012).

-Amigdala: Kokulara ait duygusal yorumların oluştuğı kısımdır. Kokuların kişilerde meydana getirdiğı hoşnut olma, tikslenme, keyif gibi cevapların ana oluşum noktasıdır (Barresi ve ark. 2012).


-Entorhinal Korteks: Koku hafızasının oluşması ve alınan kokuların tanınmasında rol oynar (Barresi ve ark. 2012).

1.3. Tez Kapsamında Analiz Olarak İzlenen Temel Yaklaşım

EEG işaretlerinin beyin aktivitesiyle ilgili süreklilik içeren bilgiler vermesi, geniş bir zaman çözünürlüğüne sahip olması ve uygulanabilirliğinin kolay oluşu, EEG tabanlı sistemlerin başlıca tercih edilme sebebidir. EEG analizlerinde sıklıkla izlenen işlem akışının benzer olduğu literatürden görülebilmektedir. Bu yaklaşım, daha çok biyomedikal mühendisliği alanındaki çalışmalarda rağbet görmektedir. Genel olarak analizler için izlenen yaklaşım; EEG kayıtlarında önışlem, öznitelik çıkarımı ve sınıflandırmadır. Bu tez çalışmasında da aynı yaklaşım izlenilmiş olup, detaylar aşağıda verilmiştir.

Bu tez çalışmasında iyi- kötü kokuların insan beyni üzerine etkisi ve ayrıştırılmasında EEG verilerinden faydalanılmıştır. Çalışmada izlenen genel yaklaşım Şekil 1.7’de gösterilmiştir. İlk olarak hangi kokulara ait işaretlerin kullanılacağına karar verilir. Kokulara ait EEG verileri çeşitli ön işlemlerden geçirilip gürültülerden ayrıştırılır ve analiz edilmek istenen bant(lar) elde edilir. EEG verilerinin yorumlanmasını kolaylaştırmak ve boyut uzayını azaltmak için özniteliklerden faydalanılır. Son olarak elde edilen öznitelikler çeşitli makine öğrenmesi algoritmaları ile sınıflandırılır. Literatüre bakıldığında bu aşamaların birçok çalışmada farklılık gösterdiği gözlemlenmektedir.

1. GİRİŞ



Şekil 1.7. Koku verilerine ilişkin EEG verilerinin incelenmesinde genel yaklaşım

2. KAYNAK ÖZETLERİ

Koku uyarıları sonucu oluşan EEG cevaplarına dair çalışmalar 1958 yılından başlayıp günümüze kadar devam etmektedir. Yapılan çalışmaları konuyla ilgili ilk çalışmalar ve güncel çalışmalar şeklinde 2 başlık altında incelemek, literatürü anlamamıza daha çok yardımcı olacaktır.

1) Koku uyarıları sonucu oluşan EEG cevaplarına dair ilk çalışmalar:

Martin (1998), çalışmasında 1958 - 1995 yılları arasında çeşitli kokuların insanlarda oluşturduğu EEG cevaplarını derlemiştir. Katılımcılar, kokular ve yoğunlukları, kullanılan elektrotlar, EEG'ye ait incelenen alt bantlar, kokuların uygulanma süresi ve kokuların etkileri detaylarıyla verilmiştir. Bahsedilen çalışmalar aşağıda verildiği gibidir.

Bushteva ve ark. (1958), 8 kız katılımcıya hidrojen sülfidin farklı yoğunluklarda çözeltilerini uygulayıp beyindeki alfa aktivitesini incelemiştir. Çalışma literatürdeki ilk örnek olduğu için kullanılan elektrotlar ve kokuların uygulanma süresi bilgisine henüz ulaşamamıştır. Çalışma sonucunda alfa bandının salınımında bozunumlar (desenkronizasyon) görülmüştür.

Monierieff (1962), çalışmasında 1 erkek katılımcıdan 4 sağ- 4 sol bölgeye ait elektrotlar yardımıyla bitkisel parfüm kokularının uygulanması sonucu EEG kayıtları almıştır. Her kokunun 6 – 7 sn. süresince uygulandığı çalışmada alfa bandı incelenmiştir. Alfa bandı aktivitesinde azalmalar görülmüştür. Benzer çalışma 4 erkek katılımcı için aynı gruba ait başka kokularla denendiğinde alfa aktivitesinin iyice baskılandığı görülmüştür.

Stacher ve ark. (1979), 8 erkek – 8 kız katılımcıya tereyağı sürülmüş ekmek üzerine dilimlenmiş soğan, kızartılmış tereyağı, yumurta ve pastırma kokularını 15 dk. boyunca Cz elektrodu aracılığıyla uygulamış ve teta, alfa, beta aktivitesini incelemiştir. Teta aktivitesinde kokulara bağlı olarak azalmalar ve artmalar olduğu gözlemlenmiştir.

Brandl ve ark. (1980), 17 katılımcıya aldehit bileşenleri, eugenol (karanfil kokusu) ve linalool (zambak kokusu)'ü Cz, Pz, Fz elektrotları aracılığıyla uygulayıp bantlara ait güç spektrum grafiklerini incelemiştir. İyi ve kötü kokulara ait bant gücü yoğunluğuna bakıldığında kötü kokuların iyilere göre az da olsa baskın olduğu görülmüştür.

2. KAYNAK ÖZETLERİ

Lorig ve Schwartz (1988), yaptıkları iki çalışmanın ilkinde 9 erkek, 4 kız katılımcıya baharatlı elma, okaliptüs ve lavanta kokularını, ikincisinde 6 erkek, 4 kız katılımcıya 5 farklı hoş kokuyu uygulayıp F7, F8, T5, T6 elektrotları ile EEG kayıtlarını her koku için birer dk. boyunca almışlardır. Çalışmalarda teta ve alfa aktivitelerindeki değişimler göz önünde bulundurulmuştur. İlk çalışmada sağ frontal ve sol posterior bölgede teta aktivitesinde azalma görülmüştür. Baharatlı elma, lavanta kokusuna göre daha az teta aktivitesine sebep olmuştur. Baharatlı elma ve okaliptüs kokuları kişilerde daha az anksiyet ve gerginlik oluşturmuştur. İkinci çalışmada ise asimetric alfa aktivitesi gözlemlenmiştir ve birçok koku sol yarımkürede daha fazla teta aktivitesi göstermiştir.

Lorig ve ark. (1990), çalışmalarında lavanta yağı ile baharatlı elma kokuları, düşük, orta ve yüksek yoğunluklarda 8 erkek – 8 kız katılımcıya uygulamışlardır. Kokular 15 sn. uygulanıp F7, F8, T5, T6 elektrotları ile kaydedilerek teta – alfa – beta aktiviteleri incelenmiştir. Yoğunluklar düşük yoğunluktan orta yoğunluğa doğru gittikçe teta bandında farklılıklar görülmüştür. Sol – arka bölgede lavanta kokusu için bir aktivite artışı söz konusudur.

Bedia ve ark. (1990), çalışmalarında nane kokusunu 4 erkek, 6 kız katılımcıya C3, C4, O1, O2 elektrotları ile uykunun Evre II ve REM kısımlarında uygulamıştır. Çalışmada EEG'nin yapısında koku uygulanma sırasında daha hızlı değişimlerin olduğu gözlemlenmiştir.

Lorig ve ark. (1991), 10 ml galaxolide'nin %80, %20 ve %5 yoğunluktaki çözeltilerini 12 katılımcıya F7, F8, T3, T4, T5, T6, Cz, Pz elektrotları ile uygulayıp alfa ve Factor 1 diye adlandırdıkları 5 – 8 Hz arası bantları incelemişlerdir. Koku 10 sn. boyunca uygulanmıştır. Çalışmada koku uygulama sırasında alfa aktivitesinde bir azalma görülmüştür.

Klemm ve ark. (1992), 16 kız katılımcıya birch tar, galbanum, heliotropin, yasemin, lavanta, limon, nane ve oda kokularını beynin frontal – central – temporal – oksipital- parietal bölgelerine ait 19 elektrot aracılığı ile 2 dk. süresince uygulamış ve delta- teta – alfa beta bantlarını incelemişlerdir. Nane kokusuna karşı tüm bantlarda aktivite artışı görülürken, teta bandında birch tar, yasemin, lavanta ve limon kokuları sonucu aktivite artışı görülmüştür.

2) Koku uyarıları sonucu oluşan EEG cevaplarına dair güncel çalışmalar:

Literatür incelendiğinde, farklı kokuların canlılara ait merkezi sinir sisteminde, fizyolojik ve psikolojik oluşumları üzerinde nasıl değişimler oluşturduğuyla ilgili çeşitli çalışmalar yapıldığı görülmektedir. Bu çalışmaları koku uyarılarının değerlendirme teknikleri açısından 3 başlık altında toplamak mümkündür. Bunlar koku uyarılarının EEG, ERP, ve nörolojik görüntüleme (fMRI, PET) teknikleri ile incelenmesine dayalı çalışmalardır. Bu yöntemler kapsamında yer alan temel çalışmalar aşağıda belirtilmiştir.

a. Koku uyarılarında EEG kullanımı: EEG yoluyla alınan kayıtlar, beynin durumuyla ilgili sürekli bilgi içerdiğinden, yüksek çözünürlüğünden ve uygulanabilirliğinin kolay oluşundan dolayı koku bilgilerinin değerlendirilmesinde en çok kullanılan yöntemdir. Konuya ilişkin yapılmış literatür çalışmaları aşağıda verilmiştir.

Klemm ve ark. (1992), 16 kız bireye 7 farklı koku (zift, acı reçine, piperonal kimsiyal bileşeni, yasemin, lavanta, limon, nane) uygulayarak 19 elektrot aracılığıyla beynin fizyolojik tepkisini ölçmeye çalışmışlardır. Katılımcılara anket uygulayarak (1-9 arası puanlama) en iyi (limon, nane) ve en kötü (zift, acı reçine) ikişer koku belirlemişlerdir. EEG alt bantlarının güç spektral analizlerini inceleyerek koku ile ilişkili en etkin bandın teta bandı olduğunu gözlemlemişlerdir.

Skoric ve ark. (2015), insan merkezi sinir sisteminin 3 iyi kokuya (limon, nane, vanilya) tepkisini 16 kişiden (7 kız-9 erkek) gözleri açık durumda aldıkları EEG verileri ile incelemişlerdir. Tüm analizler teta bandı üzerinde yapılmıştır. Yapılan istatistiksel analizler (ANOVA) sonucu nane ve limon kokuları beynin tüm bölgelerinde (özellikle central bölgede aktivite azalması şeklinde) değişimler meydana getirmiştir. Vanilya kokusu için beynin bölgeleri arasında büyük bir fark gözlemlenmemiştir.

Kroupi ve ark. (2014), 10 adet iyi, kötü ve nötr kokuları 25 katılımcıya (9 kız-16 erkek) gözler kapalı iken uygulamışlardır. Kokular gül suyu, lavanta, yasemin, kakao tozu, nane, kediotu, sarımsak tozu, anason, pişmiş karnabahar ve bebek şampuanı şeklindedir. Çalışmada işaretin karmaşıklık ölçüsü olan Permütasyon Entropi (PE) ve EEG zaman serisinin fraktal karakteristiği lineer olmayan öznelik olarak seçilmiş ve Lineer Discriminant Analysis (LDA) ile sınıflandırılmıştır. Frontal korteks kötü kokular, central korteks ise iyi kokular yüksek frekanslarda aktivasyon artışına sebep olmuşlardır. Ayrıca temporal bölgede asimetri olduğu görülmüştür. Diğer bir

2. KAYNAK ÖZETLERİ

söyleyişle, iyi kokular sol temporal bölgede aktivite artışına sebep olurken, kötü kokular sağ temporal bölgede aynı etkiyi göstermiştir.

Kroupi ve ark. (2016), bir önceki çalışma ile aynı deney paradigması ve kokularla EEG ve Elektrokardiyogram (EKG) kayıtları almışlardır. EEG kayıtları için alt bantların gücü, Wasserstein Mesafesi (WM) ve Normalized Length Density (NLD); EKG kayıtları için HRV (Heart Rate Variability) öznitelikleri çıkarılmıştır. Öznitelikler EEG, EKG, EEG+EKG şeklinde oluşturulup LDA ile sınıflandırılmıştır. EKG verileri koku verilerine ilişkin daha az çözünürlük göstermiştir. Kokudan sorumlu bölgeler beynin frontal ve temporal bölgeleri olarak belirlenmiştir. Bu bölgelerin Priform Korteks (PC) ile yakından alakalı olduğuna vurgu yapılmıştır. Kokuların beyindeki değişimleriyle en ilgili bandın beta 2 (21-29 Hz) olduğu görülmüştür. Koku verilerinin sınıflandırılmasında Bayes Ağları (BA) ve Nöral Ağlar (NA) gibi daha lineer olmayan yöntemler önerilmiştir.

Kroupi ve ark. (2012), EEG işaretlerine ait frekans bantlarının farklı kokulardan nasıl etkilendiğiyle ilgili bir çalışma yapmışlardır. Kedi otu, lotus çiçeği, gül suyu ve peynir kokularını 5 erkek bireye gözler kapalı konumda uygulanıp EEG kaydı alınmıştır. Katılımcılara anket uygulanıp (0-10 arası puanlama) en iyi ve en kötü birer koku seçilmiştir. Çalışmada Welch metodu kullanılarak teta, alfa, beta, gama bantlarına ait güç spektrum yoğunlukları (PSD) elde edilmiş ve bunlar öznitelik olarak kullanılmıştır. Sınıflayıcı olarak Destek Vektör Makinası (DVM) kullanılarak en yüksek başarımlar frontal (63.4) ve occipital (63.3) bölgede elde edilmiştir. Ayrıca frontal ve central bölgede iyi koku için teta, alfa bant gücünde azalma, gama bandında ise artma gözlemlenmiştir. Son olarak beta ve gama bantlarının bilişsel ve hissi uyaranlara en duyarlı bantlar olduğuna vurgu yapılmıştır.

Kroupi ve ark. (2014), çalışmalarında beyinde oluşan işaretlerde iyi-kötü kokuya göre değişim olup olmadığı, varsa bu değişimin sübjektif mi objektif mi olduğu, iyi ve kötü kokulara beynin hangi bölgesinin hassas olduğu, açık-kapalı göz konumunun beyindeki koku algısı durumunu değiştirip değiştirmediği sorularına cevap aramışlardır. 5 katılımcıdan gözler açık-kapalı konuma göre kokular uygulanarak 216 kanal aracılığıyla EEG kayıtları alınmıştır. Çalışmada lotus çiçeği ve gül suyu kokuları iyi, peynir ve kedi otuna ait kokular ise kötü koku olarak seçilmiştir. Kokulardan her biri deneme sayısı 20 ile 30 arasında değişecek şekilde uygulanıp her bir deneme arasında 2

saniye ara verilmiştir. Öteki kokuya geçilmeden 2 dakika ara verilip kokuların oluşturduğu hoşnutlukla ilgili anket uygulanmıştır. Genel olarak iyi kokuların EEG alt bantlarında salınım gücünü arttırdığı, kötü kokuların ise azalttığı görülmüştür. Beta ve gama bandının kokuyla en ilgili bant olduğu gösterilmiştir. Frontal bölgenin kokulardan asıl sorumlu bölge olduğu çıkarımı yapılmıştır. Kokularla ilgili kişi bazında genel çıkarımlar yapılabildiği halde, kişiden kişiye değişmeyen kesin yargılar çıkarmanın zor olduğu anlaşılmıştır. Gözler açık konumdayken kokuların beyindeki ayırt edilebilirliği gözler kapalı konuma göre daha fazla olduğu görülmüştür. Son olarak beynin frontal bölgesinde bir asimetri olduğu gözlemlenmiştir.

Lanata ve ark. (2016), bir grup katılımcıya uygulanan koku uyartısı sonucu elde edilen EEG işaretlerine makine öğrenmesi yaklaşımı ile kokulardaki iyi-kötü bileşenleri otomatik tanımlayan bir yaklaşım sergilemişlerdir. 32 katılımcıya (16 kız-16 erkek) iyi koku olarak benzaldehit, kötü koku olarak izovalerik asid uygulamışlardır. Çalışmada kullanılan elektrodların her birine Hızlı Fourier Dönüşümü (FFT) aracılığıyla PSD'leri hesaplanıp öznitelik olarak kullanılmıştır. Temel Bileşen Analizi (PCA) ile öznitelik boyutu azaltılmıştır. Sınıflandırıcı olarak LDA kullanılmıştır. Sınıflandırma başarımı %75 olarak elde edilmiştir. Yapılan istatistiksel çalışmalar sonucu elde edilen bulgulara göre beynin her iki yarım küresinin kokulara karşı farklı davranışlar sergilediği gözlemlenmiştir.

Lorig ve ark. (1990), çalışmalarında oda havası içinde bulunan ve varlığı belirsiz kokuların insan beynindeki aktiviteye ve kişinin ruhsal moduna etki edebileceği fikrini öne sürmüşlerdir. Bu bağlamda 16 kişilik (8 kız-8erkek) katılımcılara iki farklı kokuyu (lavanta yağı ve baharatlı elma) 4 farklı yoğunlukta (kokusuz, düşük, orta, yüksek) uygulamışlardır. Çalışmada F7, F8, T5, T6 elektrotları kullanılmıştır. Normalde oda içinde koku almadığını sanan kişilere ait teta bandında kokuya ve yoğunluğuna bağlı olarak değişimler gözlemlenmiştir.

Martin (1998), çalışmasını iki aşamada gerçekleştirmiştir. İlk olarak çikolata, nane, badem, çilek, sebze, sarımsak, soğan ve kimyona ait sentetik kokuları 21 katılımcıya, ikinci aşamada ise gerçek yiyecek kokularını (çikolata, pişmiş fasülye, çürük et) 15 katılımcıya uygulamıştır. Her iki aşamada da herhangi bir kokunun uygulanmadığı kontrol grubu oluşturulmuştur. Kokuların uygulanması sonucu EEG alt bantlarındaki tepkiler gözlemlenmiştir. Her iki aşamada da çikolata kokusunun

2. KAYNAK ÖZETLERİ

uygulanması sonucu teta aktivitesinde azalma gözlenirken diğer bantlarda önemli bir bulguya rastlanmamıştır. Ayrıca bu çalışmada 1958-1995 yılları arasında koku uyarılarına insan EEG'sinin cevabı kapsamında yapılan çalışmaların özeti bulunmaktadır.

Muralı ve Vladımır (2007), çalışmalarında koku uyarıtısı sonucu insan beyinde meydana gelen uyarılmış potansiyelleri (EP) gözlemek için işarete ait FFT ve Fraktal Boyut (FD) hesabı yapılmıştır. Çalışmada İngiliz gülü, yasemin, limon, portakal, gül bahçesi ve kereste kokuları 3 kişiye uygulanmıştır. Deney ilk 20 sn. için normal nefes alıp verme, 21-64 sn. arası gözler açık ve kapalı iki durum için koku uygulanması şeklindedir. FFT güç spektrumu sonucu ön loba ait elektrotlarda delta salınımı, diğer elektrotlarda ise alfa salınımı belirgin şekilde gözlemlenmiştir ancak normal nefes alıp verme ile koku uyarıtısına ait EP'leri ayırt etmede yeterli olmamıştır. Verilerin FD'si incelendiğinde ise koku uyarıtısına ait EEG verileri daha fraktal bir boyuta sahip olduğu görülmüştür. Kapalı-açık göz durumu için benzer spektal analiz gözlemlenmiştir. Fraktal spektrum analizin insan EEG'sine ait EP'leri tanıyan bir araç olarak koku sisteminde olası hasarları tespitinde kullanılabileceği öngörülmüştür.

Namazi ve ark. (2016), çalışmalarında uygulanan kokuların moleküler yapısı ile EEG işaretleri arasındaki ilişkiyi irdelemişlerdir. 40 katılımcının (20 kız-20 erkek) olduğu deneyde 5 farklı moleküler yapıda koku uygulanmıştır. Kokunun moleküler kompleksliği arttıkça EEG işaretlerinin karmaşıklığının arttığını ve buna bağlı olarak daha az fraktal yapıda oldukları görülmüştür. Çalışmada ayrıca bir öznitelik olarak entropinin, EEG işaretlerine ait belirgin özellikler elde etmemize yardımcı olduğu vurgulanmıştır. Shannon Entropi (SE), Permütasyon Entropi (PE) ve Yaklaşık entropi (AE) örnek olarak belirtilmiştir.

Pinto ve ark. (2014), 12 katılımcıdan (7 kız, 5 erkek) oluşan gruba gözler kapalı konumda 2 gruptan (esansiyel ve karma) oluşan kokular uygulayarak EEG işaretlerini kayda almışlardır. Çalışmanın amacı EEG cevaplarına göre kişilerin kokulara olan reaksiyonunu analiz etmektir. Esansiyel kokular doğadan direkt alınabilen limon ve nane kokusu iken; karma kokular ise farklı esansiyel kokuların karışımı olan 4 farklı kokudan oluşmaktadır. Çalışmada katılımcıların temel (base) duruma bağlı olarak spektrumdaki frekans değişimleri her koku için incelenmiştir. Esansiyel kokuların diğer karışık

kokulara göre daha etkin olduğu, kızların erkeklere göre kokulara daha hassas olduğu, her kokunun en az bir kişiye etki ettiği gözlemlenmiştir.

Placidi ve ark. (2015), çalışmalarında kötü kokuları hatırlamaya yönelik bir Beyin Bilgisayar Arayüzü (BBA) oluşturup 2 sınıflandırma tekniği uygulamışlardır. 4 katılımcı kullanılmıştır. Ekranaya gelen (+) işareti kişinin rahatlamasını, ok işareti ise tiksiniş bir kokuyu anımsamasını istemektedir. Her uyarı 3.6 sn. sürmektedir. Toplam 60 deneme alınmıştır. Çalışmada sağ yarım küreye ait olan P4, C4, T8, P8 elektrotları dikkate alınmıştır. Bunun sebebi kötü kokuların oluşturduğu etkinin beynin sağ lobunda daha etkin olmasıdır. Çalışmada ilk olarak bant geçiren filtre ile alfa (konsantrasyonla ilgili) ve gama (negatif duygulara karşı hassasiyet) bantları çıkarılmıştır. İkinci olarak Ayrık Dalgacık Dönüşümü (ADD) kullanılarak aynı bantlar elde edilmiştir. PCA ile öznitelik seçimi yapılmış ve sınıflandırıcı olarak DVM kullanılmıştır. İki farklı yöntemle de benzer sınıflandırma başarısı (%88.3-93.3 arası) elde edilmiştir. Yüksek sınıflandırma oranları temporal bölgeden elde edilmiştir.

Sanders ve ark. (2002), çalışmalarında aromaterapinin kişilerin ruhsal modu üzerindeki etkilerini incelemişlerdir. Lavanta ve biberiye kokuları yetişkinler ve çocuklar üzerinde denenmiştir. Lavanta beynin sol ön bölgesinde aktivasyon artışı sağlarken, biberiye sağ ön bölgede aktivasyon artışı göstermiştir. Bu durum, kokuların EEG üzerinde asimetrik cevap oluşturduğunu göstermektedir. Çalışmada fazla sol frontal aktivite kişinin ruhsal modunda olumlu işaretken, sağ frontal aktivitenin anksiyet ve depresyon belirtisi olduğu vurgusu yapılmıştır.

Sowndhararajan ve ark. (2015), çalışmalarında bileşik formülü olarak aynı fakat yapı olarak farklı iki izomerik aroma bileşenlerinin (limonene ve terpinolene) insan EEG'sinde oluşturduğu değişimleri gözlemlemişlerdir. Limonene molekülü portakal kokusunu, terpinolene ise çam kokusunu andırmaktadır. Katılımcılar 18 kişiden (9 kız-9 erkek) oluşmakta ve EEG verileri 8 elektrot (FP1, FP2, F3, F4, T3, T4, P3, P4) aracılığıyla kaydedilmiştir. Bu elektrotlara ait güç spektrumları incelenmiştir. Limonene bileşiği uygulanması sonucu sağ temporal bölgede beta aktivitesi artmıştır. Terpinolene bileşiğinde ise sağ prefrontal bölgede beta aktivitesi azalırken alfa aktivitesi artmıştır. Kızlar her iki bileşiğe de artan alfa ile tepki vermişlerdir. Çalışmada iki izomer bileşiğin benzer formüle sahip olsa bile farklı yapısal özelliklerinden dolayı beyinde farklı etkiye sebep olduğu gözlemlenmiştir.

2. KAYNAK ÖZETLERİ

Xu ve ark. (2015), çalışmalarında, Kroupi ve ark. (2014)'nin oluşturduğu 10 farklı kokudan oluşan deney paradigmasını kullanarak iyi-kötü kokuların uyarımı sırasında beynin farklı bölgeleri arasında fonksiyonel olarak bir bağlantı oluşup oluşmadığını analiz etmişlerdir. Çalışmada fonksiyonel bağlantı, karmaşık bilişsel ve algısal bir faaliyette, farklı sinir bölgeleri arasındaki aktivitelerin koordinasyonları için bir tür mekanizma olarak tanımlanmıştır. Çalışmada ağ tabanlı öznetelikler kullanılmıştır. Sınıflandırıcı olarak DVM seçilmiştir. Sınıflandırma başarısının lineer olmayan ağ yapıları yardımı ile artması bizlere koku alım sırasında karmaşık patternlerin oluştuğunu göstermektedir.

Harada ve ark. (1996), çalışmalarında koku uyarımı sonucu EEG işaretlerinde meydana gelen değişimlerin benzerlik (coherence) analizini yapmışlardır. Amaç beynin farklı bölgeleri arasındaki fonksiyonel ilişkiye açıklık kazandırmaktır. Çalışmada iyi koku olarak methly-cyclopentenolone, kötü koku olarak scatol kimyasal bileşenleri kullanılmıştır. Veriler 16 elektrot aracılığıyla 10 katılımcıdan alınıp ayrıca hiç koku uygulanmayan kontrol grubu da oluşturulmuştur. Çalışmada uyumluluk fonksiyonu, iki işarete ait frekans bileşenleri arasındaki korelasyonu ölçen bir kavram olarak tanımlanmıştır. Bu uyumluluğun büyüklük olarak 0-1 arasında değiştiği düşünülürse, 0 iki nokta arasında herhangi bir lineer ilişkinin olmadığını; 1 ise o iki nokta arasında sıkı bir bağ olduğu anlamına gelmektedir. Koku verileri ile kontrol grubu arasındaki uyumluluk değerleri karşılaştırılınca, iyi koku sonucu frontal bölgeye ait delta bandındaki uyumluluk değeri azalırken, temporal bölgedeki alfa bandında bu değer artmıştır. Kötü koku sonucunda ise frontal bölgedeki delta bandında yine azalırken, alfa bandı frontalden oksipitale doğru boylamsal elektrotlarda artış görülmüştür. Çalışmada frontal bölgede azalan uyumluluk değeri, özellikle baş, yüz hareketleri veya nefes almadan kaynaklanan gürültülere yorulmuştur. Alfa bandında artan bu değer, elektrotlar arasındaki iyi bir uyumun sonucudur.

Harada ve ark. (2002), çalışmalarında damardan enjekte yoluyla koku uyarımı sonucu EEG işaretlerindeki frekans değişimlerini incelemeyi amaçlamışlardır. Thiamin Propyl Disulfide (TPD) enjekte edilmesi sonucu kanda açığa çıkan n-propyl mercaptan ürünü alveollara iletilip kişilerde sanki sarımsak kokusu almış gibi bir his uyandırır ve bu etki bir süre devam eder. Yapılan deney 3 aşamadan oluşmaktadır. Katılımcı ilk olarak gözler kapalı dinlenme durumundadır. İkinci durumda TPD maddesi enjekte

edilir ve son olarak kokunun etkisi geçene dek beklenir. 16 kanal aracılığıyla elde edilen EEG kayıtlarındaki alt bantların güç spektrum değişimleri incelenir. Çalışmada TPD enjekte edildiği aşamadan sonra alfa 2 ve beta 2 bantlarının frontal ve temporal bölgelerde aktive olduğu gözlemlenmiştir.

Min ve ark. (2003), çalışmalarında gün içinde çeşitli kokulara maruz kalan insanların farklı kokulara karşı tepkilerini incelemek istemişlerdir. Katılımcıları genel çalışan (10 kişi), parfüm satıcısı (9 kişi) ve profesyonel parfüm araştırmacılarından (10 kişi) seçmişlerdir. Fesleğen, limon, yasemin, ylang ylang yağı ve scatol kimyasal bileşeni koku uygulaması için seçilmiştir. Çalışmada ortak bilgi analizi (Mutual Information Analysis) kullanılmıştır. Bu ortak bilgi iki zaman serisi tamamen aynı ise maksimum değerde, bağımsız ise minimum değere sahiptir. Profesyonel parfüm araştırmacılarında beynin frontal lobunda (kokuyla en ilgili bölge) bu ortak bilgi bileşenleri belirgin olarak gözlenmiştir. Bu gözlem kokuları yorumlayıp ayırt etmede kişilerin üstün olduğunun kanıtı sayılmıştır.

Yavuz ve Aydemir (2016), çalışmalarında 5 katılımcıdan gözler açık-kapalı konuma göre, lotus çiçeği ve peynir kokuları uygulanarak alınmış olan EEG verilerini kullanmışlardır. Öznitelik olarak Sürekli Dalgacık Dönüşümü (SDD) katsayılarının ortalama ve standart sapma değerleri kullanılmıştır. Wavelet katsayıları, Morlet, Mexican, Meyer, Coiflet ve Daubechies wavelet kullanılarak delta-teta-alfa-beta-tüm bant bazında sınıflandırma oranları karşılaştırılmıştır. Sınıflandırma algoritması olarak k En Yakın Komşuluk (k-NN) kullanılmıştır. Mexican wavelet öznitelikleri gözler açık-kapalı konuma göre en iyi sınıflandırma oranlarını vermiştir. Gözler açıkken en yüksek başarımlar teta bandında (%96.69), en düşük başarımlar delta bandında (%86.80) görülmüştür. Gözler kapalıyken en yüksek başarımlar beta bandında (%85.91), en düşük başarımlar teta bandında (%76.64) görülmüştür.

Yavuz ve Aydemir (2016), yine aynı veri setine ait nilüfer çiçeği ve kediotu kokularını kullanmışlardır. İşaret olarak gözler açıkken çarpıklık değeri ve FFT; kapalı iken FFT öznitelik kümesini oluşturmaktadır. Sınıflandırıcı olarak k-NN kullanılmıştır. Gözler açıkken %97.28, kapalıyken %90.97 sınıflama başarımları elde edilmiştir.

2. KAYNAK ÖZETLERİ

b. Koku uyarılarında ERP kullanımı: ERP ile koku uyarıları sonucu insan beyninde oluşan anlık sonuçları inceleyebilmek mümkündür. Bu kapsamda yapılan çalışmalar aşağıda verilmiştir.

Bensafi ve ark. (2002), çalışmalarında koku uyarımı sonucu kişilerin görsel ERP'sinde ve davranışlarındaki değişimleri incelemişlerdir. 15 kız katılımcıya, iyi-kötü yüz ifadeleri içeren 32 farklı resim gösterilmiştir. Resimlerden 16'sı iyi koku ile, geri kalanı ise nötr koku ile uygulanmıştır. Bu sırada bir olfaktometre yardımı ile iyi (karışık çiçek kokusu) ve kokusuz (hava) üflenmiştir. Katılımcılardan istenen en kısa sürede resimleri iyi-kötü diye düğmeler yardımıyla değerlendirmesidir. Bu sırada Fz, Cz, Pz, Oz elektrot konumlarından veriler alınmıştır. Çalışmada ERP'ye ait N4 (negatif 400 ms gecikmeli oluşan) dalga formunun alınan koku ile değişen yaygın bir işaret olduğu belirtilmiştir. Ayrıca gecikmeli pozitif kompleks (LPC) olan P3'ün (pozitif 300 ms gecikmeli oluşan) değişimin duygusal tepkilere duyarlı olduğu belirtilmiştir. Resimlerin %36.6'sı iyi olarak nitelendirilmiştir. N4 dalga formunda her iki koku durumuna göre davranışsal bir farklılık görülmemiştir. Kötü ifadeli yüzler, iyilere göre daha hızlı tanınmıştır. Çalışmada P3'ün iyi koku sonucu frontal bölgede pozitif artan bir aktivite gösterdiği gözlemlenmiştir.

Bulsing ve ark. (2007), çalışmalarında H_2S 'i acı vermeyen, CO_2 'yi ise acı veren koku olarak seçmişlerdir. 30 katılımcıya kokular hakkında bilgi vermeyip her bir koku için acı veren-vermeyen koku şeklinde etiket koymuşlardır. Böylece katılımcılar kokuları acı verecek-vermeyecek şeklinde beklenti ile koklamışlardır. Çalışmada bu beklenti ile alınan kokuların algıdaki büyüklükte ve hızda nasıl değişimler meydana getirdiği incelenmiştir. ERP dalga formunun büyüklüğü (amplitude) artmış ise kişi uyarandan fazla etkilenmiş, gecikme (latency) az ise uyaran hızlı şekilde algılanmıştır sonuçları çıkarılabilir. Çalışmada N1 (tepkinin yoğunluk ve niteliği ile ilgili) ve P2 (algının bilişselliğiyle ilgili) dalga formları incelenmiştir. EEG kayıtları Fz, Cz ve Pz bölgelerinden alınmıştır. Acı veren bir kokunun koklanacağı sanılan durumlarda N1 ve P2 dalga formlarının büyüklüğünde pek bir değişim gözlenmemiştir ancak N1 dalga formu tepkimeye daha hızlı cevap vermiştir. Yani acı beklentisi algıdaki hızı arttırmıştır.

Covington ve ark. (1999), çalışmalarında katılımcıların yaşının ve kokunun yoğunluğunun kokuya ait ERP'lerde nasıl değişimlere sebep olduğunu

gözlemlemişlerdir. Çalışmada 14 genç – 14 yaşlı kişiye izoamil asetat'ın farklı yoğunluktaki çözeltileri koklatılmıştır. Genç kişiler yaşlılara göre daha büyük N1/P2, N2/P3, daha az gecikmeli N1, P2, N2 göstermişlerdir. Her iki yaş grubunda da orta ve çok yoğun koku çözeltileri, düşük yoğunluklu kokulara nazaran P2 ve N2'de hız az gecikme cevabı göstermişlerdir. Kokunun yoğun olması katılımcıların yaşından bağımsız olarak koku uyarısına daha hızlı tepki verilmesini sağlamıştır.

Daniels ve ark. (2001), çalışmalarında koku uyarılarına beyin tümörüne sahip hastaların nasıl reaksiyon verdiğini araştırmışlardır. Çalışmada 10 hasta ve 20 sağlıklı katılımcıdan linalool (zambak kokusuna benzer kimyasal bileşik) ve allylcaproate (ananas kokusuna benzer bileşik) kokularını ayırt etmeleri istenmiş ve elektrotlar Fz, Cz, Pz, F3, F4, P3, P4 konumundayken ERP kayıtları alınmıştır. N1, P2 ve P3'e ait büyüklük ve gecikmeler ölçülmüştür. Beynin sağ yarım küresinde lezyon bulduran katılımcılarda, solda lezyon bulduranlara nazaran, kokuları ayırt etme oranında büyük azalma görülmüştür. Buradan beynin sağ yarım küresinin koku algısında daha aktif rol aldığı görülmüştür. Ayrıca bu hastalarda, parietal konumdaki elektrotlardan alınan ERP'ye ait P2- P3 dalga formlarının büyüklüğünde azalma görülmüştür. Genel anlamda hastalıklı kişilerde koku fonksiyonunda ciddi bozukluk olduğu çıkarımı yapılmıştır.

Evans ve ark. (1995), çalışmalarında sağlıklı insanlardaki kokuya ait ERP'ler üzerinde yaş ve cinsiyetin etkisini incelemişlerdir. Amil asetat (muz yağı) katılımcılara uygulanıp ardına davranışsal bir test uygulanmıştır. Test sonucunda farklı cinsiyetler arasında koku tanımada pek farklılık görülmezken, yaşa bağlı olarak bir azalma görülmüştür. Çalışmada P2 dalga formu koku ile en ilgili dalga formu olarak belirlenmiştir. Kadınlarda P2-N1 büyüklüğünün fazla olması, ERP üzerinde hormonal etkilerin olabileceğine işaret etmiştir.

Maurage ve ark. (2011), çalışmalarında alkolizmin kişilerdeki koku fonksiyonuna etkilerini araştırmışlardır. 10 kişilik alkolik grup ve 10 normal kontrol grubuna benzil karbinol (hoş çiçeksi koku) bileşiği koklatılmış ve N1-P2'nin davranışları izlenmiştir. Alkolik kişilerde N1 ve P2'de gecikme ve P2'nin büyüklüğünde azalma görülmüştür. Bulgulardan yola çıkılarak alkolün kişilerde koku yeteneğinde azaltıcı rol oynadığı tespit edilmiştir.

2. KAYNAK ÖZETLERİ

Olofsson ve ark. (2005), yaptıkları çalışmada hamile kadınların kokulara olan hassasiyetlerini ve tepkilerini incelemişlerdir. Hamileliğin 21-23 haftasını yaşayan 15 kadın ile hamile olmayan 15 kadına piridin bileşiğinin 3 farklı yoğunlukta çözeltisi koklatılmıştır. EEG kayıtları Fz, Cz ve Pz bölgelerinden alınmıştır. ERP'ye ait N1, P2 ve P3 dalga formlarının büyüklüklerine ve gecikmelerine bakılmıştır. Çözelti yoğunluğu arttıkça tüm dalga formlarında büyüklük artmış, gecikme azalmıştır. Aynı konsantrasyondaki kokular için N1 ve P2'de hamile olan ve olmayan kadınlar için değişiklik gözlemlenmezsen, ERP'nin geç evresinde görülen P3'de, hamile kadınlarda büyüklük olarak fazla ve gecikme olarak kısa bir dalga şekli görülmüştür. Hamile kadınlarda kokuya olan hassasiyetin ve eğilimin daha fazla olduğu çıkarımı yapılmıştır.

Schriever ve ark. (2014), çalışmalarında 23-41 günlük 13 bebeğe phenylethyl alkol (gül kokusuna benzer) uygulanarak bebeklerdeki koku fonksiyonunu incelemişlerdir. Fz, Cz, Pz, C3 ve C4 bölgelerindeki elektrotlardan veri alınmıştır. 7 bebekten alınan kayıtlar değerlendirmeye alınmıştır. En sağlıklı kayıtlar Fz ve Cz bölgelerindeki elektrotlardan elde edilmiştir. İncelenen ERP'lerde N1 ve P2 dalga formları gözlemlenmiştir. N1 328. ms.'de, P2 ise 505. ms.'de görülmüştür. Çalışmada 4-7 Hz arasında artan bir frekans aktivitesi gözlemlenmiştir.

Wetter ve Murphy (2003), literatürde koku ile ilgili çalışmalarda, kokunun uygulanma süresinin kısa tutulması (90 s. ve daha az), katılımcılarda kokuya karşı alışkanlık oluşturduğu tezini öne sürmüşlerdir. Bu alışkanlığın ERP bileşenlerindeki büyüklüklerin azalmasından anlaşılabilceği söylenmiştir. Çalışmada amil asetat kokusu, 10 katılımcıya (5 kız, 5 erkek) 10'ar dakika ve az sayıda (3 defa) uygulanarak Fz, Cz, Pz bölgelerinden kayıtlar alınmıştır. İlk deneme ile karşılaştırıldığında ERP dalga formlarında büyüklük ve gecikmeye bağlı değişimler görülmemiştir. Bu yöntemin burnun kokuya alışmasına engel olduğu görülmüştür.

Wetter ve Murphy (1999), çalışmalarında koku fonksiyonunun down sendromlu kişilerde nasıl değiştiğini gözlemlemek için sağlıklı ve hastalıklı kişilerden kayıtlar alıp ERP bileşenlerini gözlemlemişlerdir. Kayıt alınan tüm elektrotlara ait N1, P2, N2 ve P3 bileşenlerinde gecikme gözlemlenmiştir. Hastalıklı kişilerde koku fonksiyonunun azaldığı çıkarımı yapılmıştır.

c. Koku uyartılarında nörolojik görüntüleme tekniklerinin kullanımı: Nörolojik görüntüleme teknikleri kapsamında bulunan fMRI ve PET uygulamaları, uyartılar

sonucu beynin metabolizmasında ve kan dolaşımında meydana gelen değişimleri inceleme imkanı sunar. Bu kapsamda yapılan literatür çalışmaları aşağıda verilmiştir.

Bensafi (2012), çalışmasında Priform Korteksin (PC) insan koku algısındaki rolünü, fMRI ve PET yöntemleri ile yapılmış çalışmaları inceleyerek derlemiştir. PC beynin frontal ve temporal bölgesince uzanan koku korteksinin en büyük parçasıdır. Çalışmaya değinildiğine göre PC'nin koku algısındaki rolü, birçok faktöre göre değişiklik göstermektedir. Bu faktörler, gürültüden dolayı işaret kaybı, kokuya alışmak, ortamın kokusunun istenmeyen etkileri, uyarı yolu (ağız-burun), kokunun özellikleri (hoşnutluk-yoğunluk-nitelik) ve kişilerin yaşı, kültürü gereği kokulara verilen farklı bilişsel tepkiler olarak sıralanmıştır.

Berlin ve ark. (2017), çalışmalarında fMRI kullanarak Obsesif Kompulsif Bozukluğa (OKB) sahip kişilerin iyi-kötü kokulara olan tepkilerini ve insular lobda meydana getirdiği değişimleri bir ilk olarak gerçekleştirmişlerdir. İnsular lob frontal parietal ve temporal lobun altında bir yapıdır ve incelenmesi yüzey elektrotlarından ziyade fMRI gibi görüntüleme tekniğiyle mümkündür. İnsular lob duyuşal işlevler, otonom sinir sistemi ve tad almayla ilişkilendirilmektedir. Çalışmada 15 sağlıklı ve 15 OKB rahatsızlığı bulunan katılımcı bulunmaktadır. OKB hastaları kötü kokulara sol-ön insulada artan, iyi kokulara ise sol- ön ve temporal insulada artan tepkiler vermişlerdir. Hasta grup, sağlıklı kontrol gruba göre kötü uyarınları daha kötü, iyi uyarınları ise daha az iyi olarak değerlendirmişlerdir. Bu onların uyarınlara genel olarak negatif tepki verdiklerini göstermektedir.

Cerf-Ducastel ve Murphy (2006,2009), çalışmalarında beynin hangi kısımlarının koku hafızası ile daha ilgili olduğunu araştırmışlardır. 10 katılımcıya (5 erkek- 5 kız) fMRI taraması öncesi 16 farklı koku uygulanmıştır. Tarama sırasında bu kokuların isimlerini içeren ve içermeyen koku isimleri katılımcılara gösterilmiştir. Koku, katılımcı tarafından koklanmışsa bir tuş yardımıyla tanıdığına dair işaret alınmıştır. Bu aşama 3 defa tekrarlanmıştır. Çalışma sonucunda hippocampus, mesiotemporal ve frontal lob kısımlarında en çok aktivite görülmüştür. Ayrıca aktivasyon beynin sağ yarım küresinde daha fazladır. Kokuları hatırlama oranı ilk denemeden üçüncü denemeye doğru azalmıştır. Aynı prosedür genç ve yaşlı katılımcılar üzerinde de denenmiştir. Yaşlı katılımcılarda gençlere göre benzer bölgelerde aktivite azalması görülmüştür. Ayrıca

2. KAYNAK ÖZETLERİ

frontal lobda bir aktivite artışı görülmemiştir. Yaşlılardaki en büyük aktivite beyincikte gözlemlenmiştir.

Masaoka ve ark. (2014), fMRI yönteminin yüksek derinlik bilgisinden ve EEG'nin yüksek zaman çözünürlüğünden faydalanmak için iki sistemin bir arada olduğu kaskad bir yöntem denemiştir. İyi- kötü kokuların uygulanması sonucu koku korteksindeki değişimler bu kaskad sistemle incelenerek hem derinlik hem de zaman anlamında yüksek çözünürlük elde edilerek en küçük nöral aktiviteler dahi gözden kaçırılmamaya başlanmıştır.

Royet ve ark. (2003), çalışmalarında 28 katılımcıya iyi-kötü kokular uygulayıp fMRI ile duygu değişimlerini incelemiştir. Yapılan çalışma kişilerin hangi elini kullandığına ve cinsiyetlerine göre farklı sonuçlar vermiştir. Kötü kokuların uygulanmasıyla Priform - amigdala bölgesi ve ön insulada iyi kokulara nazaran daha fazla etkinlik gözlenmiştir. Kötü kokular sonucu sol elini kullanan kişilerde sağ ön insulada, sağ elini kullanan kişilerde sol ön insulada etkinlik gözlenmiştir. Sol orbito-frontal bölgede kadınlara ait aktivitenin erkeklere nazaran daha fazla olduğu görülmüştür. Koku ile ilgili çalışmalarda kişilerin kullandığı elleri ve cinsiyetleri farklı sonuçlar doğurduğundan katılımcı seçiminde önem arz etmektedir.

Wang ve ark. (2010), fMRI yöntemi ile yaptıkları çalışmada Alzheimer hastalarının koku fonksiyonlarında azalma olduğunu görmüşlerdir. Hastalığın erken dönemlerindeki 12 ve sağlıklı 13 kişiye lavanta kokusunun 3 farklı konsantrasyonu uygulanmıştır. fMRI kandaki oksijen oranının görüntülenmesinin sonucudur. Alzheimer hastalarında sağlıklı gruba göre koku korteksinde daha az oksijen akışından dolayı daha zayıf işaretler elde edilmiştir. Koku konsantrasyonlarının farklılığı hasta kişilerin fMRI görüntülerinde sağlıklı kişilere nazaran daha değişken tepkiler olarak ortaya çıkmıştır. Buradan hasta kişilerde daha hassas ölçümler elde edildiği anlaşılmaktadır.

Bu tez çalışmasında katılımcılara 8 farklı koku uygulanarak 14 kanallı EMOTIV-EPOC başlığı ile EEG kayıtları alınmıştır. 8 farklı koku arasından, uygulanan anket sonuçları ve güç spektrum analizleri neticesinde en baskın 2'şer adet iyi-kötü koku belirlenmiştir. Katılımcıların bu iyi- kötü kokulara ilişkin EEG işaretleri sınıflandırılmıştır. Elde edilen EEG işaretlerinden ayırık dalgacık dönüşümü (ADD) yardımıyla öznitelik vektörleri çıkarılmıştır. Sınıflandırıcı olarak WEKA veri

madencilięi programı zerinden bayes aęları, ok katmanlı perceptron, k-en yakın komşuluk ve random forest (rastgele orman) algoritmaları kullanılarak sınıflandırma başarımları karşılaştırılmıştır. alıřmada Diferansiyel Geliřim Algoritması (DGA) kullanılarak kanal sayısı azaltılıp benzer sınıflandırma başarımları yakalanmaya alışılmıştır.





3. MATERYAL VE METOD

Bu çalışmada, iyi – kötü koku uyaranları sonucu insan beyninde meydana gelen değişimleri incelemek adına EEG işaretlerinin sınıflandırılması amaçlanmıştır. Bu kapsamda kullanılan kokular, deney paradigması, elde edilen veri seti, sınıflandırmada kullanılacak kokuların tayini ve EEG işaretlerinin sınıflandırılmasına ilişkin tez kapsamında kullanılan yöntemler detayları ile açıklanmıştır.

3.1. Veri Setinin Oluşturulması

Bu tez çalışmasında kullanılan EEG verileri, yaşları 22 – 26 arasında değişen lisans öğrencisi 6 erkek katılımcıdan alınarak kaydedilmiştir. Katılımcılar yerel etik kurul kararı onayı ile deneye gönüllü olarak katılmışlardır. Veri setinin oluşturulmasında belirli ön koşullar mevcuttur. Bunlar şu şekilde sıralanabilir;

a) Katılımcılar sağ elinin kullanan, sigara kullanmayan, solunum sistemiyle ilgili herhangi bir cerrahi operasyon geçirmemiş, koku duyusuyla ilgili problem yaşamayan ve herhangi bir mental – kronik rahatsızlık yaşamayan kişilerden seçilmiştir.

b) Katılımcılara deneyin protokolü ve çalışmanın amacı hakkında bilgi verilmiş ancak uygulanacak kokularla ilgili bilgi verilmemiştir.

c) Katılımcılar kontrollü bir ortamda rahat bir koltuğa oturtulmuş, veri alınan oda sesten, ışıktan korunmuş ve iyi havalandırılmıştır.

d) Verilerin alınacağı gün katılımcı ve verileri alan kişi giysilerine kalıcı olarak sinen herhangi bir kozmetik ürünü kullanmamıştır.

e) Veri alma sırasında denek gözler kapalı (istenmeyen etkilerin oluşmasını önlemek için) ve normal nefes alıyor konumdadır.

f) Kokular birer tüp içerisinde, deneğin burnuna 1 – 2 cm uzakta tutularak uygulanmıştır.

g) Kokuların yoğunluk farkları deney sırasında gözetilmemiştir.

h) Veriler alınırken katılımcıların sadece burundan nefes alması ve ağızdan vermesi istenmiştir.

3.1.1. Kokuların Seçimi ve Deney Kurulumu

Farklı kişilerin aynı kokulardan farklı şekillerde etkileneceği öngörüsü bir yana, genel anlamda iyi (gül, vanilya, şeftali, nar çiçeği) ve kötü (domates salçası, peynir, soğan, sarımsak) kokular şeklinde 2 sınıf oluşturulmuştur. Kokuların seçiminde literatürden faydalanılmıştır [(Kroupi ve ark. 2016), (Kroupi ve ark. 2014), (Xu ve ark.


3. MATERYAL VE METOD

2015)]. Kokulara ait EEG verileri EMOTIV – EPOC başlığı kullanılarak MATLAB ortamında kaydedilmiştir. Kullanılan başlığa ait özellikler Çizelge 3.1.’de verilmiştir.

Çizelge 3.1. EMOTIV – EPOC başlığına ait teknik özellikler

Kanal Sayısı	14 (artı olarak CMS/DRL referans elektrotları)
Kanallar (Uluslararası 10-20 düzenine göre)	AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6 F4, F8, AF4
Örnekleme Metodu	Ardışık örnekleme. Analog/ Dijital Çevirici
Örnekleme Frekansı	128 Hz
Çözünürlük	16 bit Analog/Dijital Çevirici
Bant Geniliği	0.16 - 45 Hz, 50-60 Hz için dijital notch filtre
Filtreleme	Cihaza gömülü 5. dereceden dijital Sinc filtresi
Dinamik Aralık	8400 μ V (pp)
Kuplaj Mod	AC kuplaj
Bağlantı	Kablosuz, 2.4GHz band
Güç	Lityum Polimer pil
Batarya Ömrü	12 saat

EMOTIV – EPOC başlığına ait elektrotlar, Çizelge 3.1.’de belirtildiği üzere uluslararası 10 – 20 sistemine göre konumlandırılmıştır. Elektrotların konumları Şekil 3.1.’de gösterilmiştir.



Şekil 3.1. Başlığa ait elektrotların 10 – 20 sistemine göre dizilimi


Şekil 3.1.'de 10 – 20 sistemine göre dizili olan elektrotların numaraları ve etiket bilgileri Çizelge 3.2.'de belirtilmiştir.

Çizelge 3.2. Başlığa ait kanal numaraları ve etiketleri

Kanal No	Kanal Etiketi
1	AF3 (sol en - ön)
2	F7 (en – sol ön)
3	F3 (sol ön)
4	FC5 (sol ön-orta)
5	T7 (sol temporal)
6	P7 (sol parietal)
7	O1 (sol oksipital)
8	O2 (sağ oksipital)
9	P8 (sağ parietal)
10	T8 (sağ temporal)
11	FC6 (sağ ön-orta)
12	F4 (sağ frontal)
13	F8 (en-sağ ön)
14	AF4 (sağ en - ön)

3.1.2. Kokuların Uygulanması (Paradigma)

Deney sırasında tüp içerisindeki 8 farklı kokudan biri rastgele seçilerek katılımcının burnuna 1 – 2 cm uzaktan yaklaştırılıp 8 saniye süresince bekletilmiş ve bu deneme aynı koku için 10 defa tekrarlanmıştır. Aynı 2 koku arasında 10'ar saniyelik aralar verilmiş ve kokunun etkisinin geçmesi beklenmiştir. 10 saniyelik bu süreçler kayda alınmamıştır. İşlem bitiminde, 2 dakika ara verilip katılımcının kokuyla ilgili hoşnutluk seviyesini ölçen bir anket düzenlenmiştir. Bir sonraki koku yine rastgele seçilip aynı adımlar tekrarlanmıştır. Veri alımında her koku bir kez kullanılmıştır. Literatür incelendiğinde iki koku arası bekleme süresi 2 saniye ile 5 dakika arasında, kokunun uygulanma süresi ise birkaç saniye ile 1 dakika arasında değişmektedir (Kroupi ve ark. 2014). Bu tez çalışmasında da bu parametrelerin dışına çıkılmamıştır. Kokuların uygulanma adımları Şekil 3.2.'de gösterilmiştir.



Şekil 3.2. 8 farklı kokunun uygulama adımları

3. MATERYAL VE METOD

3.1.3. Kullanılan Koku Uyarılarının Değerlendirilmesi

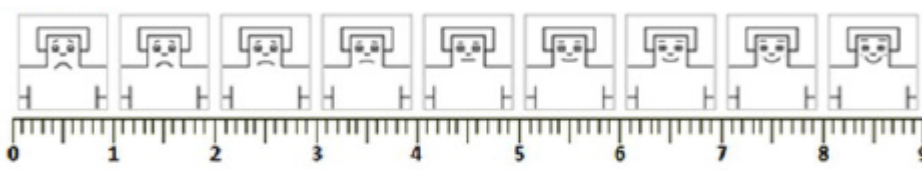
a) Anket Değerlendirmesi

Şekil 3.2.'de gösterilen paradigmada olduğu gibi katılımcılardan uygulanan kokuların kendilerinde oluşturduğu hoşnutluk hissini değerlendirmeleri istenmiştir. 2 dakika süre içinde uygulanan ankette kokunun hoşnutluk durumuna göre 0 – 9 arası değerlendirme sistemi yapılmıştır. Uygulanan koku “ çok kötü – kötü – normal – iyi – çok iyi” şeklinde değerlendirilmiştir. Anket formu Şekil 3.3.'de görülmektedir.

Koku No:

1. Çok Kötü 2. Kötü 3. Normal 4. İyi 5. Çok İyi

2. Hoşnutluk:



3. Koku tanıdık ve kokunun ne olduğunu biliyorum:

Tanıdık ama sadece tahminde bulunabilirim Kokuyu tanıyamadım

Sizce hangi koku en hoşnutluk verici ?

Sizce hangi koku en kötü olanı ?

Şekil 3.3. Katılımcılara uygulanan değerlendirme anketi

Katılımcılara uygulanan anket değerlendirmeleri neticesinde tüm kokular için 0 – 9 arası hoşnutluk değerlendirmesi Çizelge 3.3'de verilmiştir.

Çizelge 3.3. Katılımcılara (A- B- C- D- E- F) ait hoşnutluk durumu (0-9)

Katılımcılar						
Kokular	A	B	C	D	E	F
Gül	7	8	7	8	8	6
Peynir	3	3	2	4	4	3
Vanilya	7	7	8	7	9	6
Domates Salçası	4	4	6	2	2	4
Şeftali	6	7	7	7	5	5
Sarımsak	2	3	3	1	3	1
Nar Çiçeği	8	6	6	6	6	7
Soğan	3	2	3	2	1	1

b) Welch Yöntemi ile Kokulara Ait Güç Spektrum Analizi

- Welch Yöntemi

Spektral analiz yöntemlerinden biri olan periyodogram, parametrik olmayan Hızlı Fourier Dönüşümü (FFT) temelli bir yaklaşımdır. Periyodogram yöntemi ile bir zaman serisine ait güç spektrum yoğunluğu elde edilirken, kullanılan işaret 2'nin kuvvetleri olacak şekilde pencerelere bölünür. Periyodogramın iyileştirilmiş hali, Welch tarafından öne sürülüp işaretin üst üste binecek şekilde pencerelere bölünebileceği söylenmiştir. Elde edilen bu pencerelerin periyodogramı ayrı ayrı elde edilip sonrasında ortalaması alınır. Bu işlem, tüm zaman serisinin tek bir periyodogram kestirimine göre varyansı azaltır. Varyans değerindeki azalma ile çözünürlük arasında bir ters orantı vardır. Pencereler arasında üst üste binmeler sonucu bazı gereksiz bilgiler oluşsa da değişik pencereleme yöntemleri bunun önüne geçer. *Welch Yöntemi*, iyileştirilmiş periyodogramların ortalamasını alarak güç spektrum yoğunluğunu kestirir. *i*. periyodogram Eşitlik (3.1)'de gösterilmiştir.

$$\hat{S}_{xx}^{(i)}(f) = \frac{T_s}{K.M} \left| \sum_{n=0}^{M-1} x_i(n)w(n) \cdot e^{-j2\pi f n} \right|^2 \quad (3.1)$$

Eşitlik (3.1)'deki *f* normalize edilmiş frekans değeridir. Örnekleme faktörü olan *T_s* ayrık zaman işaret spektrumuna ait genlikle analog işaret spektrumunu eşitler. *w(n)* pencereleme fonksiyonu, *K* ise normalize sabiti olup aralarındaki ilişki Eşitlik (3.2)'deki gibidir.

$$K = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n) \quad (3.2)$$

Sonuç olarak güç spektral yoğunluğu:

$$\hat{P}_{Welch}(f) = \frac{1}{L} \sum_{i=0}^{L-1} \hat{S}_{xx}^{(i)}(f) \quad (3.3)$$

eşitliği ile elde edilir. Eşitlik (3.3)'deki *L* zaman serisinin uzunluğudur. İşaretteki gürültü oranı fazla ise daha fazla çözünürlük elde etmek için *Welch Yöntemi* oldukça elverişlidir (Alkan ve Yılmaz 2007).

- Welch Yönteminin MATLAB Platformunda Kullanımı

İşaretlere ait güç spektrum grafikleri aşağıda verilen kod satırı ile MATLAB ortamında incelenebilir:

3. MATERYAL VE METOD

[p_{xx},f]= pwelch ({işaret}, pencere (pencere uzunluğu), örtüşme oranı, nfft, fs, 'psd')

Welch yönteminde uygulamaya göre farklı uzunlukta çeşitli pencere türleri kullanılır. Pencere segment uzunluklarının ne oranda örtüşeceği yüzdelik oran olarak belirlenir. nfft işaretin kendi uzunluğunu geçmemelidir. fs işaretin örnekleme frekansını temsil eder.

Welch yöntemine ait bazı pencere türleri *rectangular, hann, hamming, bartlett, blackman, kaiser* olarak sıralanabilir. Bu pencere türleri Eşitlik (3.1), (3.2)'de geçen $w(n)$ 'e göre değişir. N terimi 2'nin kuvveti olan pencere genişliği, n ise $0 \leq n \leq N-1$ olarak alınır bazı pencere türlerine ait bağıntılar şu şekildedir:

$$w(n) = 1 \quad (3.4)$$

$$w(n) = 0.5 \left(1 - \cos \left(\frac{2\pi n}{N-1} \right) \right) \quad (3.5)$$

$$w(n) = 0.54 - 0.46 \cos \left(\frac{2\pi n}{N-1} \right) \quad (3.6)$$

$$w(n) = \frac{2}{N} \left(\frac{N}{2} - \left| n - \frac{N-1}{2} \right| \right) \quad (3.7)$$

$$w(n) = a_0 - a_1 \cos \left(\frac{2\pi n}{N-1} \right) + a_2 \cos \left(\frac{4\pi n}{N-1} \right); a_0 = 0.62 \quad a_1 = 0.48 \quad a_2 = 0.38 \quad (3.8)$$

$$w(n) = \frac{\left(\pi \alpha \sqrt{1 - \left(\frac{2n}{N-1} - 1 \right)^2} \right)}{(\pi \alpha)}; \alpha = sbt \quad (3.9)$$

Eşitlik (3.4) – (3.9) arası sırası ile *rectangular, hann, hamming, bartlett, blackman* ve *kaiser* pencere türlerine aittir.

(Musson ve Li 2010) yaptıkları çalışmada, çeşitli pencereleme yöntemleri kullanarak EEG işaretlerine ait güç spektrum grafiklerini çizdirip elde edilen grafiklerin çözünürlüklerini karşılaştırmışlardır. Biyomedikal uygulamalarda *hamming* pencere türünün %50 örtüşme oranı ile genel anlamda başarılı sonuçlar elde edildiği görülmüştür. Bu tez çalışmasında kokulara ait güç spektrum grafikleri çizdirilirken benzer yöntem uygulanmıştır

3.2. Dalgacık Dönüşümü ile Öznitelik Çıkarımı

EEG işaretleri periyodik olmayan işaretler olarak bilinir ve dalgacık dönüşümü bu işaretlerin analizinde oldukça avantaj sağlamaktadır. Bir işaretin daha iyi anlaşılması

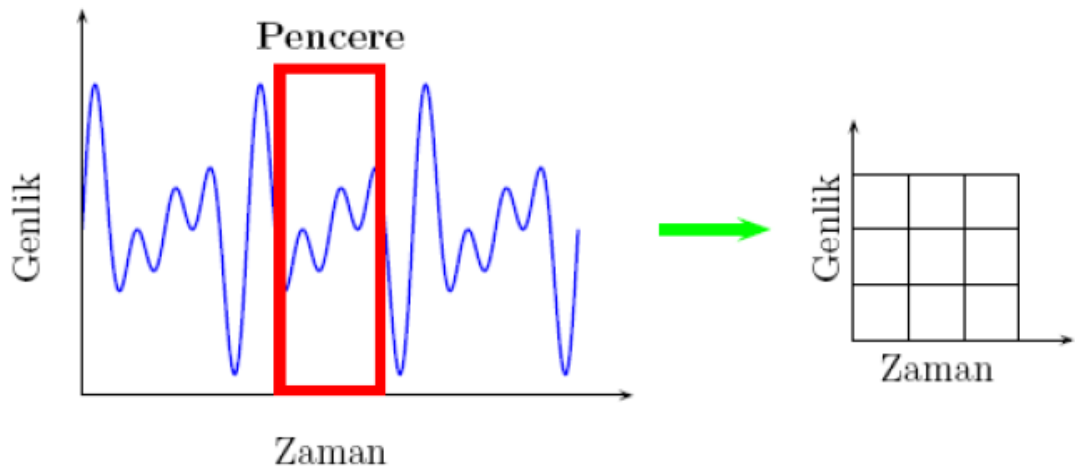
ve yorumlanması, o işaretin frekans bilgilerini incelemekle mümkündür. İşarete ait zaman bilgisi bu durum için yeterli olmayabilir. İşareti frekans alanında incelemek için dalgacık dönüşümü dışında Fourier dönüşümü (FD) ve Kısa zaman Fourier dönüşümü (KZFD) gibi yöntemler de kullanılır.

Fransız bilim adamı Jean Baptise Joseph Fourier, sürekli ve periyodik bir işareti çeşitli sinüzoidal işaretlerin toplamı şeklinde göstermeyi başarmıştır. FD, işareti zaman bilgisinden frekans bilgisine aktarırken, işaretin zaman bilgisi kaybolur. İşaret incelendiğinde spesifik bir değişimin hangi aralıkta gerçekleştiğini görmek güçtür. Sürekli işaretlerde FD başarılı sonuçlar verirken, durağan olmayan işaretlerde bunu söylemek güçtür. Zaman bilgisinden frekans bilgisine geçiş Eşitlik (3.10) ve (3.11)' de gösterilmiştir.

$$f(t) = \frac{1}{T} \int_{-\infty}^{\infty} F(w)e^{-j\omega t} dw \quad (3.10)$$

$$F(w) = \int_{-\infty}^{\infty} f(t)e^{j\omega t} dt \quad (3.11)$$

FD işaretin tamamını ele alırken, KZFD'de işaret belirli bölütlere ayrılarak durağan işaretlerin analizinde oluşan dezavantajın ortadan kaldırılması amaçlanmıştır (Şekil 3.4). KZFD'de işarete ait zaman ve frekans bilgisi birlikte bulunur ancak bölüt diye adlandırılan zaman pencerelerinin sabit olması, frekans çözünürlüğünü düşürmektedir. Pencere boyutunun büyüklüğü frekans çözünürlüğünü artırırken, küçük pencere boyutu çözünürlüğü azaltmaktadır (Demir 2008).

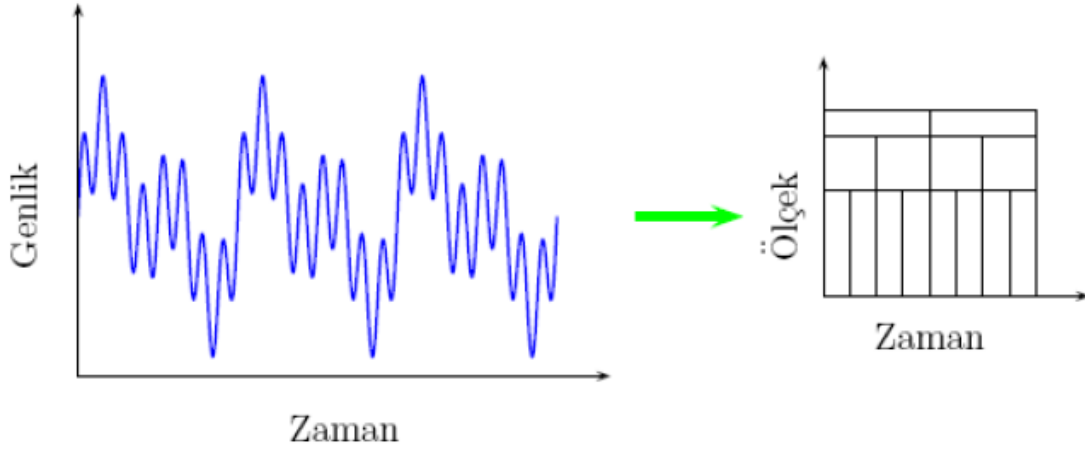


Şekil 3.4. Kısa Zamanlı Fourier Dönüşümü

Dalgacık dönüşümünün FD ve KZFD' göre durağan olmayan işaretlerin analizinde bazı avantajları bulunmaktadır. Dalgacık dönüşümünde pencere boyutunun

3. MATERYAL VE METOD

sabit olmaması, ani deęişimler içeren EEG gibi işaretlerin analizinde üstünlük sağlamaktadır. Düşük frekans bantlarında geniş pencereler, yüksek frekans bantlarında ise dar pencereler kullanılması deęişken pencere boyutunu ifade etmektedir. Şekil 3.5’de örnek bir işaret ve deęişken pencere boyutları gösterilmiştir.



Şekil 3.5. Dalgacık dönüşümü


3.2.1. Dalgacık Kavramı ve Genel Kullanılan Ana Dalgacıklar

Dalgacık dönüşümünde kullanılacak ana dalgacığın reel bir $\psi(x)$ fonksiyonu olabilmesi için Eşitlik 3.12 ve 3.13’deki şartları sağlaması gerekir. Dalgacığın integrali 0’a, karesinin integrali ise 1’e eşittir.

$$\int_{-\infty}^{\infty} \psi(x) dx = 0 \quad (3.12)$$

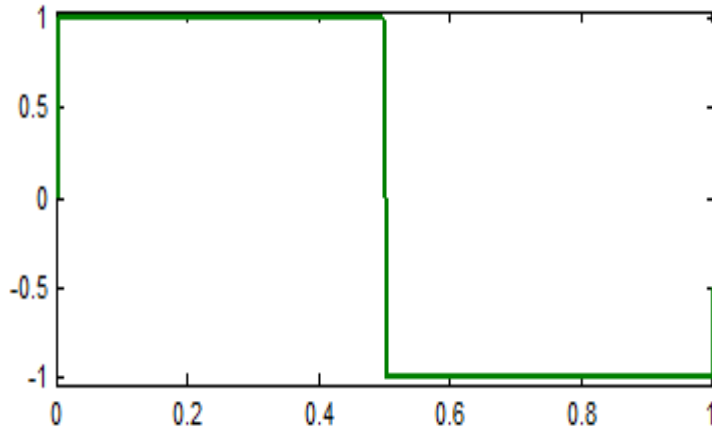
$$\int_{-\infty}^{\infty} \psi(x)^2 dx = 1 \quad (3.13)$$

Dalgacık dönüşümü de diğer FD’de olduğu gibi işareti alt bileşenlerine ayırır. FD’ de işarete ait çeşitli sinüs ve cosinüs bileşenleri elde edilirken, dalgacık dönüşüm yöntemi ise ana dalgacığın kaydırılıp ölçeklenmiş alt dalgacıklarına böler (Demir 2008). Ana dalgacığın kaydırma ve ölçeklendirme işlemi Şekil 3.6’da gösterilmiştir.




Şekil 3.6. Ana dalgacığın kaydırılması ve ölçeklenmesi

Uygulamalarda kullanılan ana dalgacık aileleri Haar (Şekil 3.7), Meksika şapkası (Şekil 3.8), Morlet (Şekil 3.9) ve Daubechies (Şekil 3.10) olarak sayılabilir.




Şekil 3.7. Haar dalgacığı (y : $\psi(w)$; x : w)

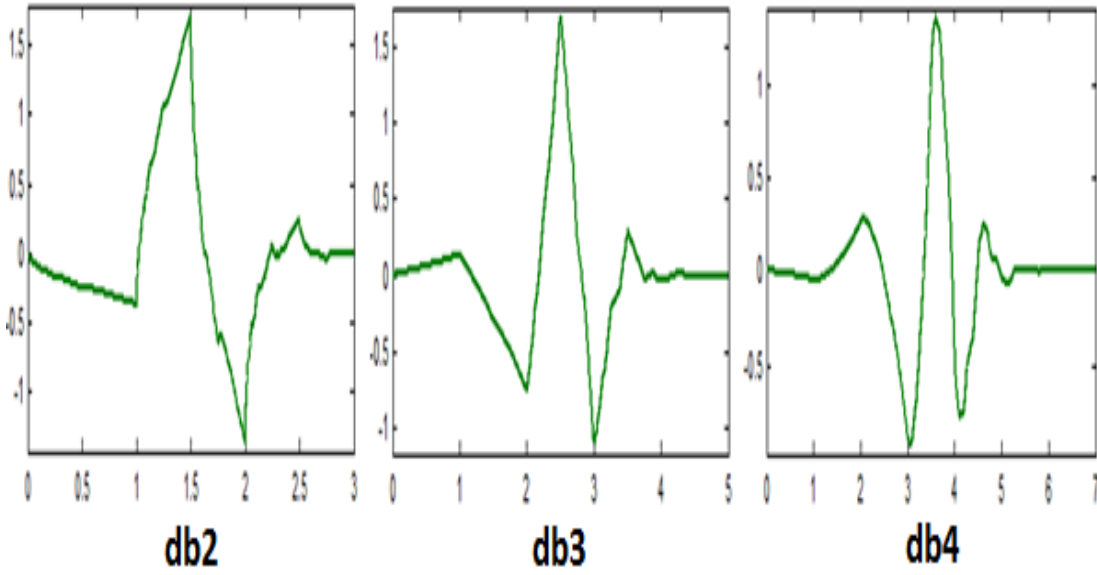
3. MATERYAL VE METOD



Şekil 3.8. Meksika şapkası dalgacı (y : $\psi(w)$); x: w)



Şekil 3.9. Morlet dalgacı (y : $\psi(w)$); x: w)



Şekil 3.10. Daubechies ailesinden bazı ana dalgacıklar (y : $\psi(w)$); x: w)

Özellikle Daubechies ana dalgacı EEG işaretlerini kapsayan analizlerde sıkça kullanılmaktadır. Bu tez çalışmasında Şekil 3.10'da görülen 'db3' ana dalgacı kullanılmıştır.

3.2.2. Sürekli Dalgacık Dönüşümü (SDD)

Analiz edilecek $x(t)$ işareti, seçilen $\psi(x)$ dalgacık fonksiyonunun ötelenip ölçeklendirilmiş hali ile çarpılıp o işarete ait SDD elde edilir. Bir $x(t)$ işaretinin ait SDD aşağıda verildiği gibidir:

$$W(a, b) = \int_{-\infty}^{\infty} x(t)\psi_{a,b}(t)dt \quad (3.14)$$

Eşitlik 3.14'deki $W(a, b)$, $x(t)$ işarete ait SDD'dir. $\psi_{a,b}(t)$ fonksiyonu, ana dalgacık fonksiyonu $\psi(t)$ 'nin ötelenip ölçeklendirilmiş şekli ile aşağıdaki gibi ifade edilir:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right) \quad (3.15)$$

Eşitlik 3.15'deki b öteleme; a ise ölçekleme parametresidir. Ölçekleme $\psi(x)$ 'nin sıkıştırılıp genişletilmesi, öteleme ise kaydırılarak konumunun değiştirilmesi anlamındadır. Bu parametrelerin sürekli olarak değişmesi daha fazla hesap yüküne ve zamana neden olmaktadır. Bu nedenle ADD yöntemi, SDD'ye göre daha uygulanabilir (Polat 2016).

3.2.3. Ayırık Dalgacık Dönüşümü (ADD)


ADD yönteminde, SDD'de olduğu gibi olası tüm öteleme ve ölçekleme parametrelerinin hesaplanması yerine, bu parametreler belirli bir alt küme kadar seçilir. Dalgacık fonksiyonlarının ölçekleme işlemi 2'nin kuvvetleri ile ölçeklenir ve tam sayılar kullanılarak ötelenip işaret ayırık hale gelir. Eşitlik 3.15'deki $a = 2^j$ ve k tam sayı olmak üzere $b = k2^j$ olarak alınırsa ADD'ye ait matematiksel ifade Eşitlik 3.16'daki gibidir:

$$C_{(a,b)} = C_{(j,k)} = \sum x[n] \cdot 2^{-\left(\frac{j}{2}\right)} \cdot g((2^{-j})n - k) \quad (3.16)$$

Bir işarete ait alçak frekans bilgisi o işaretin en anlamlı kısmı ve kimliği niteliğindeki, yüksek frekans bilgisi genelde gürültü veya işarete ait daha az bilgi içeren kısımdır. ADD yönteminde işaret alçak ve yüksek geçiren filtre çiftleri

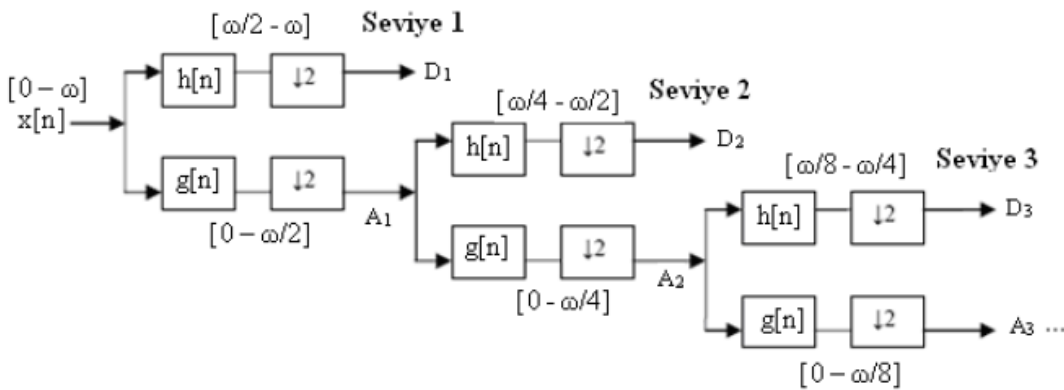
3. MATERYAL VE METOD

kullanılarak yaklaşım ve detay bileşenleri elde edilir. Yaklaşım işaretin alçak frekans, detay ise yüksek frekans bilgisi olarak kabul edilir. Şekil 3.11’de filtreler ve alt bileşenler bütünü gösterilmiştir.



Şekil 3.11. Filtreler yardımıyla işaretin yaklaşım ve detay bileşenlerinin elde edilmesi

Frekans spektrum aralığı $[0-w]$ olan bir $x[n]$ işaretine ait ADD Şekil 3.12’de gösterilmiştir. $x[n]$ işaretine, $g[n]$ alçak geçiren filtresi ardına aşağı örnekleme ($\downarrow 2$) uygulanarak A1 yaklaşım alt bandına, $h[n]$ yüksek geçiren filtresi ardına aşağı örnekleme ($\downarrow 2$) uygulanarak D1 detay alt bandına ulaşılır. Böylece 1. Seviye ADD uygulanmış olur. A1 (1. seviye yaklaşım bandı) 'e aynı işlem uygulanması sonucu 2. seviye alt bantları (A2 ve D2) elde edilir. Her ayrıştırma aşamasında frekans çözünürlüğü 2 kat artarken, zaman çözünürlüğü 2 kat azaltılmış olur.



Şekil 3.12. ADD yöntemiyle işaretin alt bantlarının elde edilmesi

ADD yöntemi kullanılarak EEG işaretlerine ait istenilen alt frekans aralığına kolaylıkla erişilebilmektedir. Bu tez çalışmasında EEG alt bantları elde edilirken

ADD'den faydalanılmıştır. Bu sırada seçilecek ana dalgacık çeşidi ve hangi seviyeye inilmek istediği veriye uygun seçilmelidir.


3.3. Sınıflandırıcı Olarak Bir Veri Madenciliği Programı: WEKA

WEKA, Yeni Zelanda'da bulunan Waikato Üniversitesi tarafından geliştirilmiş java tabanlı, açık kaynaklı ve veri madenciliğinde yaygın olarak kullanılan bir programdır. WEKA yazılımında verilere ön-işlem, sınıflandırma, kümeleme vb. gibi birçok analiz yöntemi uygulamak mümkündür. Bu çalışmada WEKA'ya ait sınıflandırma algoritmaları kullanılmıştır.

Şekil 3.13'deki açılış menüsünde *Explorer* seçeneği tıklanır ve karşımıza Şekil 3.14'deki pencere çıkar.



Şekil 3.13. WEKA açılış menüsü




Şekil 3.14. Dosya açma penceresi

3. MATERYAL VE METOD

Şekil 3.14’de gösterilen sekmede *Open file* seçeneği tıklanıp önceden *Notepad* ile hazırlanmış *.arff* uzantılı dosya seçilir. Örnek bir *dosya.arff* oluşturulması aşağıda verilmiştir:

```
@RELATION Başlık
@ATTRIBUTE Oznitelik I NUMERIC
@ATTRIBUTE Oznitelik II NUMERIC
.
.
.
@ATTRIBUTE Oznitelik N NUMERIC
@ATTRIBUTE class {Class I, Class II, ....., Class M }
@Data
Öz nitelik I, Oz nitelik II, ....., Oz nitelik N, Sınıf Etiketi
```


Dosya.arff seçimi ardına Şekil 3.15’de görülen *classify* üst sekmesi altındaki *choose* seçeneğinden sınıflandırma algoritmalarını bulmak mümkündür.



Şekil 3.15. Sınıflandırma algoritmalarını seçim penceresi

3.3.1. Sınıflandırıcı Olarak Yapay Sinir Ağları (YSA)

YSA, insan beynine ait biyolojik sinir modelinden esinlenerek geliştirilen, öğrenme, özellik belirleme, sınıflandırma, ilişkilendirme, hatırlama ve genelleme yapabilme yeteneğine sahip matematiksel modellemelere dayanır. Şekil 3.16.'da yapay bir sinir modeli gösterilmiştir.



Şekil 3.16. Yapay sinir hücresi modeli

Şekil 3.15.'de görüldüğü üzere yapay bir sinir modelinde girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkış bulunur. Biyolojik sinir ile yapay sinir modeli arasındaki benzerlik Çizelge 3.4.'de gözlemlenebilir

Çizelge 3.4. Yapay ve biyolojik sinir arasındaki benzetimler


Biyolojik Sinir Hücresi	Yapay Sinir Hücresi
Nöron	İşlem elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Eleman Çıkışı
Sinapslar	Ağırlıklar

YSA'da girişler ($x_1, x_2, x_3, \dots, x_n$) dış ortamdan, başka sinirlerden veya hücrenin kendi geri beslemesinden aldığı bilgileri sinir hücresine aktarırlar. k . nörona kadar olan ağırlıklar ($w_{k1}, w_{k2}, w_{k3}, \dots, w_{kn}$), nörondaki karar mekanizmasına hangi girişin ne kadar oranda etki edeceğini belirlerler. İstenilen çıkış değerine göre kendilerini günceller veya sabit kalırlar. Toplama fonksiyonu, sinire gelen giriş vektörlerini ağırlık vektörleri ile çarpıp toplayarak giren net girişi hesaplar. Bu giriş;

3. MATERYAL VE METOD

$$I_k = \sum_{j=1}^n w_{kj} x_j + \theta_k \quad (3.17)$$

ile elde edilir. Aktivasyon fonksiyonu $\psi (\cdot)$, belirlenen net girişe (I_k) karşılık uygun çıktıyı (y_k) belirler. YSA'da kullanılan aktivasyon fonksiyonları Şekil 3.17.'de gösterilmiştir.




Şekil 3.17. YSA'da kullanılan Aktivasyon Fonksiyonları (a) basamak (b) doğrusal (c) log - sigmoid (d) tan - sigmoid

Çıkış değerinden ($y_k = \psi(I_k)$) her sinirde sadece bir tane bulunur ve üretilen sonucu dış dünyaya aktarır.

YSA'lar yapılarına göre İleri Beslemeli ve Geri Beslemeli YSA olmak üzere 2'ye ayrılır. Öğrenme algoritmalarına göre ise Danışmalı Öğrenme, Danışmasız Öğrenme ve Takviyeli Öğrenme şeklindedir.

a) Tez Çalışması İçin Önerilen Çok Katmanlı Algılayıcı (ÇKA) Modeli ve Öğrenme Algoritması

Çok sayıda YSA mimarileri arasında ÇKA, bilinen en yaygın ve en iyi sınıflandırma başarısına sahip modeldir. Bu model sahip olduğu öğrenme algoritması sebebiyle hatanın geriye yayılımı olarak da bilinir. ÇKA, yapısında giriş katmanı, orta (gizli) katman ve çıkış katmanı bulundurur (Yıldız 2011). Örnek bir ağ yapısı Şekil 3.18.'de gösterilmiştir.



Şekil 3.18. Çok katmanlı YSA yapısı

Şekil 3.18.'de görüldüğü üzere her hücrenin çıktısı, diğer katmanlardaki tüm hücrelerin girdisi ile bağlantılıdır. ÇKA birden fazla ara katmana sahip olabilir. Ağ yapısındaki giriş – çıkış katmanında bulunan hücre sayısı veya kullanılacak ara katman sayısı, sınıflandırma problemine göre değişiklik gösterir. Ağa düşen görev, eğitim sırasında verilen girişlere ve beklenen çıkışlara göre ağırlık güncellemesi yapmasıdır.

Hatanın geriye yayılım algoritması ÇKA'ya ait öğrenme kuralıdır. Bu algoritma 3 temel aşamadan oluşmaktadır. Bu aşamalar, eğitim kümesine ait girdilere karşın üretilen çıktıların ileriye doğru hesaplanması, üretilen çıktıların beklenen çıktıların karşılaştırılıp hatanın hesaplanması ve hesaplanan bu hatanın geriye doğru yayılarak ağırlık güncellemelerinin yapılmasıdır. Şekil 3.17.'deki mimari, konunun daha iyi anlaşılması açısından 1 adet gizli katman kullanılarak bu aşamalar şöyle hesaplanabilir:

Ara katmandaki j . hücrenin net girdisi (3.18) ve çıktısı (3.19) aşağıda verilmiştir.

3. MATERYAL VE METOD

$$\bar{I}_{vj} = \sum_{n=1}^N (\bar{w}_{jn} x_{vn} + \theta_j) \quad (3.18)$$

$$\bar{y}_{vj} = \psi_j(\bar{I}_{vj}) \quad (3.19)$$

Çıkış katmanındaki bir hücre için elde edilen girdi (3.20) ve çıktılar (3.21) aşağıda verilmiştir.

$$I_{vk} = \sum_{j=1}^J (w_{kj} \bar{y}_{vj} + \theta_k) \quad (3.20)$$

$$y_{vk} = \psi_k(I_{vk}) \quad (3.21)$$

Hatanın hesaplanması ve geriye yayılmasında ağırlık çıktısı y_{vk} ile beklenen değer d_{vk} karşılaştırılır. Aradaki toplam karesel hata Eşitlik 3.22.'deki gibi hesaplanır.

$$E_v = \frac{1}{2} \sum_{k=1}^K (d_{vk} - y_{vk})^2 \quad (3.22)$$

Ara katman ile çıkış katmanı arasındaki ağırlıkların (w_{kj}) güncellenmesi için gerekli olan eğim Eşitlik 3.23.'de verilen kısmi türevlerle hesaplanır.

$$\frac{\partial E}{\partial w_{kj}} = \frac{\partial E}{\partial y_{vk}} \frac{\partial y_{vk}}{\partial I_{vk}} \frac{\partial I_{vk}}{\partial w_{kj}} \quad (3.23)$$

Bulunan eğim değerinden faydalanılıp ağırlık değerleri güncellenir. Bu güncelleme;

$$W^{s+1} = W^s + \beta \Delta W \quad (3.23)$$

$$\Delta W = -\frac{\partial E}{\partial W} \quad (3.24)$$

'e göre yapılır. Eşitlik 3.23.'deki W^s güncelleme öncesi ağırlık değeri, W^{s+1} ise güncellenmiş ağırlık değeridir. Öğrenme oranı olan β , Eşitlik 3.24.'deki ΔW ile çarpıldığında ağırlığın ne kadar değişmesi gerektiği elde edilir.

3.3.2. Sınıflandırıcı olarak Naive Bayes (NB) Algoritması

Temeli Bayes teoremine dayanan NB, örüntü tanıma problemlerine olasılıksal bir yöntemle yaklaşan sınıflandırıcı çeşididir. Sınıflandırılmış mevcut verileri kullanıp yeni gelen verilerin var olan sınıflardan hangisine ait olduğunu olasılık hesaplarıyla kestiren bir yöntemdir. NB sınıflandıracığı verileri birbirinden bağımsız, her biri ayrı öneme sahip veriler olarak kabul eder (Eraldemir 2014).

Her biri k tane özellikten oluşan n adet sınıfın var olduğunu ve bu sınıflardan birine dahil olan bir veri seti üzerinde çalışıldığı varsayalım. Hangi sınıfa ait olduğu bilinmeyen bir Y verisi Eşitlik 3.25.'e göre, bu verinin tüm sınıflar için ait olma olasılıkları hesaplanır. Çıkan sonuçlardan en büyüğüne göre o verinin sahip olduğu sınıf belirlenir.

$$P(S_i | Y) = \frac{P(Y | S_i) * P(S_i)}{P(Y)} \quad (3.25)$$

$P(S_i | Y)$: Y olayı gerçekleştiğinde, S_i olayının gerçekleşme olasılığı,

$P(Y | S_i)$: S_i olayı gerçekleştiğinde, Y olayının gerçekleşme olasılığı,

$P(Y), P(S_i)$: Y ve S_i olaylarının önsel olasılığıdır.

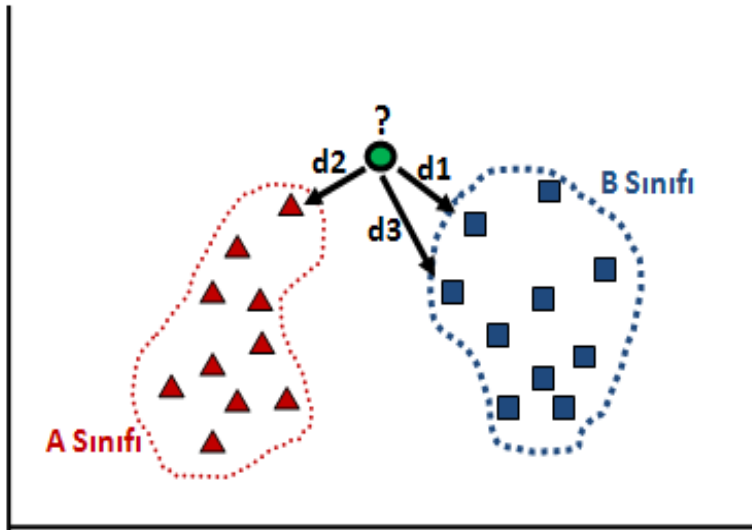
Her bir Y verisi sınıflandırmada aynı derecede öneme sahiptir. Bundan dolayı $P(Y)$ değeri her örnek veri için aynı olur. Bundan dolayı Eşitlik 3.25. yeniden yazılabilir.

$$P(S_i | Y) = P(Y | S_i) * P(S_i) \quad (3.26)$$

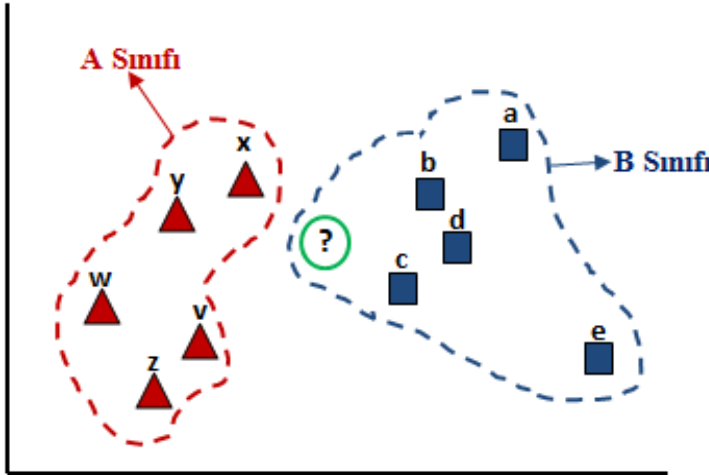
Eşitlik 3.26. her sınıf için uygulanıp elde edilen olasılık değerleriyle örneğin ait olduğu sınıf belirlenir.

3.3.3. Sınıflandırıcı Olarak k - En Yakın Komşuluk (kNN) Algoritması

K - en yakın komşuluk algoritması, en temel sınıflandırma yaklaşımlarından biridir. Bu algoritmada birbirine yakın verilerin aynı kümeye ait olduğu yaklaşımıyla hareket edilir. Daha önceden sınıflandırılmış verilere, yeni bir örnek katıldığı zaman, bu örneğin kümelenecek k tane veriye olan uzaklığı incelenir. Örneğin sınıflandırmaya çalışılan veri için $k=2$ ise, en yakın iki komşuya bakılır. Genellikle hangi sınıfa yakınsa, o sınıfa ait olduğu yaklaşımı vardır (Polat 2016). Sınıflandırma süreci Şekil 3.19. ve Şekil 3.20.'de gösterilmiştir.



Şekil 3.19. Bilinmeyen nesnenin bir sınıfa dahil edilme süreci



Şekil 3.20. Nesnenin sınıflandırılması

kNN algoritmasında uzaklık ölçütlerinin hesabında Minkowski, Eclidean, Manhattan ve Hamming yöntemleri kullanılabilir. Bu çalışmada veriler arasındaki mesafenin ölçümünde Öklid uzaklığı kullanılmıştır. Öklid hesabı Eşitlik 3.27.'de verilmiştir.

$$d(x, y) = \sqrt{\sum_{i=1}^n (X_i - Y_i)^2} \quad (3.27)$$

3.3.4. Sınıflandırıcı Olarak Rastgele Orman (RO) Algoritması

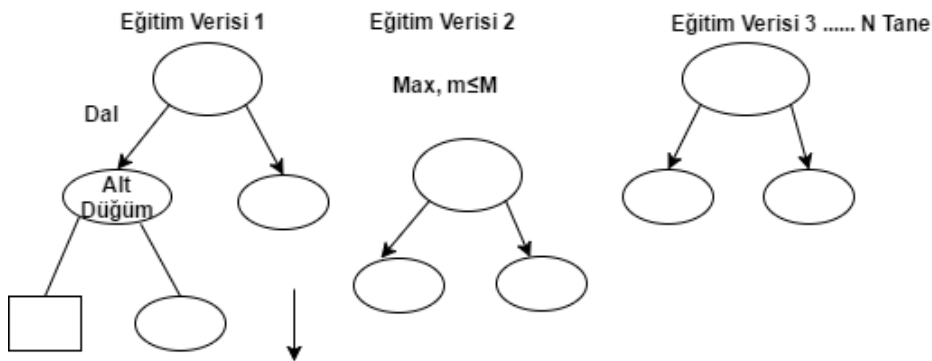
RO algoritması sınıflandırma işlemlerinde yüksek performans sergileyen, hızlı, yüksek düzeyde doğruluk oranına sahip ve gürültüye az duyarlı ağaç tipinde bir sınıflandırıcılar bütünüdür. Belirli bir kalıbı yoktur ve yöntem ile istenildiği kadar ağaç sayısı kullanılabilir. Bu yöntemde $\{h(x, \theta_k) \mid k = 1, \dots\}$ şeklinde ağaç tipi

sınıflandırıcılar kullanılmaktadır. Yöntemde verilen x giriş verisini, θ_k ise rastgele vektörü ifade eder (Breiman 2001). RO yönteminde giriş verisinden yer değiştirme şeklinde bir eğitim seti oluşturulur. Bu eğitim setinden öznelikler rastgele seçilere bir ağaç oluşturulur. Oluşturulan bu ağaca budama işlemi yapılmaz. Budama işlemi yapılmadan en büyük ağaç oluşturmak CART (Classification and Regression Tree) algoritmasını kullanarak gerçekleşir (Breiman 2001). Ağaç oluşumunda iki parametre etkilidir. Bunlar bir düğümde kullanılacak değişken sayısı (m) ve oluşturulacak ağaç sayısı (N)'dir. (m) ilk olarak rastgele seçilir ve sonraki aşamalarda hata oranlarına göre artırılıp azaltılır. En uygun (m) değeri ile sınıflandırma oranı artarken hata oranı da azalır. RO düğüm homojenliği seçiminde Gini indeksini kullanır. Bir T eğitim seti için rastgele bir örnek seçilip bu örneğin C_i sınıfına ait olduğu varsayımı yapılırsa Gini indeksi;

$$\sum \sum_{j \neq i} (f(c_i, T)/|T|) (f(c_j, T)/|T|) \quad (3.28)$$

Eşitlik 3.28.'deki $f(c_i, T)/|T|$, seçilen örneğin c_i 'ye ait olma olasılığını temsil eder.

Gini indeksinin hesabı ile düğümün bölünme pozisyonu belirlenir. Gini indeksi ne kadar küçükse dallanmadaki homojenlik o kadar fazla olur. Bir dalın başarılı olması bir alt düğümdeki indeks değerinin bir üst düğümdeki indeks değerinden küçük olmasıyla sağlanır. Bu indeks değeri 0'a ulaşıncaya dek ağaçtaki dallanma devam eder. Düğümler dallara bu şekilde ayrılıp ağaç yapısı oluşur (Özdarıcı ve ark. 2011). Şekil 3.21.'de N tane eğitim verisi kullanarak en uygun bölünme ölçütleri ile belirlenen ağaç yapısı verilmiştir.



Şekil 3.21. Rastgele Orman algoritmasına ait örnek bir ağaç yapısı

3. MATERYAL VE METOD

Şekil 3.21.'deki gibi ağacın oluşumundan sonraki adım istenilen verileri sınıflandırma aşamasıdır. Sınıflandırılmak istenilen veriler her bir ağaca yerleştirilir. Ağaçlar arasında oylamaya benzer bir seçim yapılır ve en çok oyu alan ağaç bir sınıfa atanır (Liaw ve Wiener 2002).

3.4. Kanal Seçimi İçin Diferansiyel Gelişim Algoritması (DGA)

Bir problemdeki değişken sayısı ve veri tipine bağlı olarak zorluk derecesi artıp azalabilmektedir. Doğrusal olmayan problemlerin çözümünde deterministik yaklaşımlar yeterli olmayıp sezgisel yöntemlere ihtiyaç duyulur. Diferansiyel gelişim algoritması (DGA) da genelde sürekli verileri içeren problemlerde verimli sonuçlar üreten, işleyiş yönüyle genetik algoritmaya benzer, popülasyon temelli sezgisel optimizasyon tekniklerinden biridir (Keskintürk 2006). DGA, belirlenen bir iterasyon sayısı içinde, operatörler yardımıyla işlem durana kadar en iyi çözümü bulmaya çalışır.

EEG verileri doğrusal olmayan ve sürekli bir yapıya sahiptir. Çözümlemek istenen problem şu şekilde ifade edilebilir. 14 kanallı EMOTIV-EPOC başlığından alınan verilerle yapılan sınıflandırma işleminden belirli bir başarı elde edilmektedir. Acaba aynı başarı oranına daha az kanal sayısı ile ulaşılabilir mi sorusunun cevabı aranmaktadır.

(Khusbaba ve ark. 2011)'nın önerdikleri yöntemde kanal seçimi yapılırken diferansiyel gelişim algoritması kullanılmıştır. Yöntem her kanalı ayrı ayrı inceleyip birlikte iyi çalışan bir alt küme oluşturur. Seçilmek istenen kanal sayısı, popülasyon boyutu, kullanılacak sınıflandırıcı, iterasyon sayısı ve her kanala ait öznelik sayısı belirlenir.

3.4.1. Lineer Diskriminant Analiz (LDA)

Bu çalışmada kanal seçiminde sınıflandırıcı olarak LDA kullanılmıştır. LDA, ikili veya daha fazla sınıfa ait verileri birbirinden maksimum oranda ayırmaya odaklı, istatistik ve makine öğrenmesinde kullanılan bir yöntemdir. LDA, sınıflar arasındaki varyans değerini yükseltip iki sınıf arasında bir karar bölgesi oluşturur. Böylelikle veri ayrışması daha anlaşılır bir formata dönüşür (Başçıl 2015).

k sayıda lineer fonksiyona sahip k sınıflı (2'den fazla) bir diskriminant fonksiyonu;


$$y_k(x) = w_k^T x + w_{k0} \quad (3.29)$$

şeklinde yazılır. Sınıflar ise;

$$C = \begin{cases} 1, & y(x) < 0 \\ 2, & y(x) \geq 0 \end{cases} \quad (3.30)$$

şeklindedir. Eşitlik 3.29.'daki $y(x)$ diskriminant fonksiyonu, x girişler, w özellik vektörüne ait ağırlık değeri, w_0 eşik değeri, C ise ayrılan iki sınıftır. $y(x) = 0$ bölgesi bölge sınırını belirten kararlılık bölgesidir.

$y_k(x) > y_j(x)$ durumunda, x girişlerinin sınıfı $j \neq k$ için C_k olur. C_j ile C_k sınıfı arasındaki bölge $(w_k - w_j)^T x + (w_{k0} - w_{j0}) = 0$ şeklinde hesaplanır. LDA'ya ait karar bölgesi Şekil 3.22.'de gösterilmiştir.



Şekil 3.22. LDA karar bölgesi

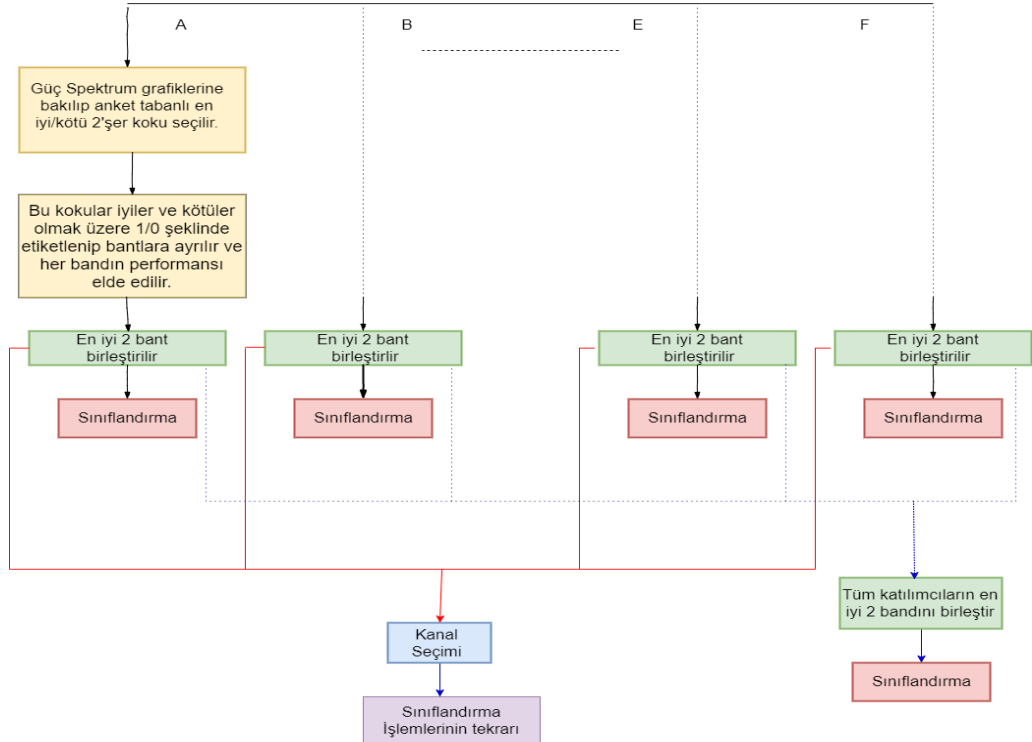


4. ARAŞTIRMA BULGULARI

Bu tez çalışmasında, anket değerlendirmeleri ve güç spektrum grafikleri referans alınarak belirlenen iyi – kötü kokulara ilişkin EEG işaretlerinin yorumlanması ve sınıflandırılması gerçekleştirilmiştir.

EMOTIV – EPOC başlığına gömülü filtre sistemlerinden geçerek elde edilen EEG işaretlerine ADD uygulanarak EEG işaretlerine ilişkin alt bantlar elde edilmiştir. Alt bantlara normalizasyon işlemi uygulanıp banda ait tüm değerler 0 – 1 aralığına indirgenmiştir. Elde edilen alt bantlara bazı istatistiksel işlemler uygulanıp öznitelik vektörleri elde edilerek işarete ait boyut azaltılmıştır. Sınıflandırıcı olarak YSA, NB, kNN ve RO algoritması kullanılmıştır. Sınıflandırmalar sonucu elde edilen başarımlar karşılaştırılmıştır.

Çalışmada kullanılan EEG işaretleri 14 kanallı olup, analizlerde tüm kanallar bir arada kullanılmıştır. Ayrıca DGA kullanılarak birlikte en iyi çalışan 5 kanal her katılımcı için belirlenip benzer sınıflandırma işlemleri tekrarlanmıştır. Yakalanan başarımların daha az kanalla yapılabileceği araştırılmıştır. Seçilen kanalların beynin hangi bölgelerine ait olduğu belirlenip beynin koku ile alakalı bölgeleri tespit edilmeye çalışılmıştır. Mevcut çalışmanın akış diyagramı Şekil 4.1.'de gösterilmiştir.

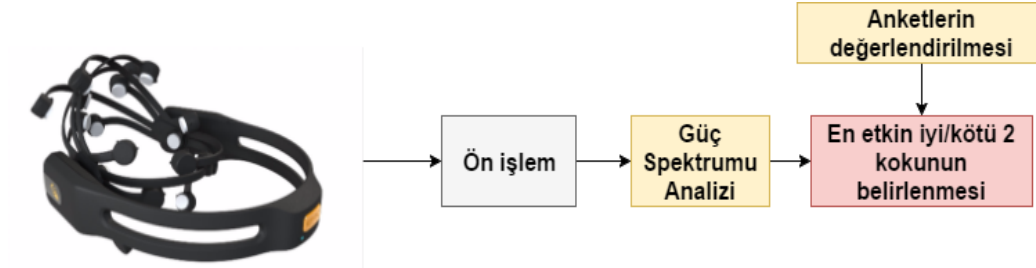


Şekil 4.1. Mevcut çalışmanın akış diyagramı

4. ARAŞTIRMA BULGULARI

4.1. Koku Seçimi

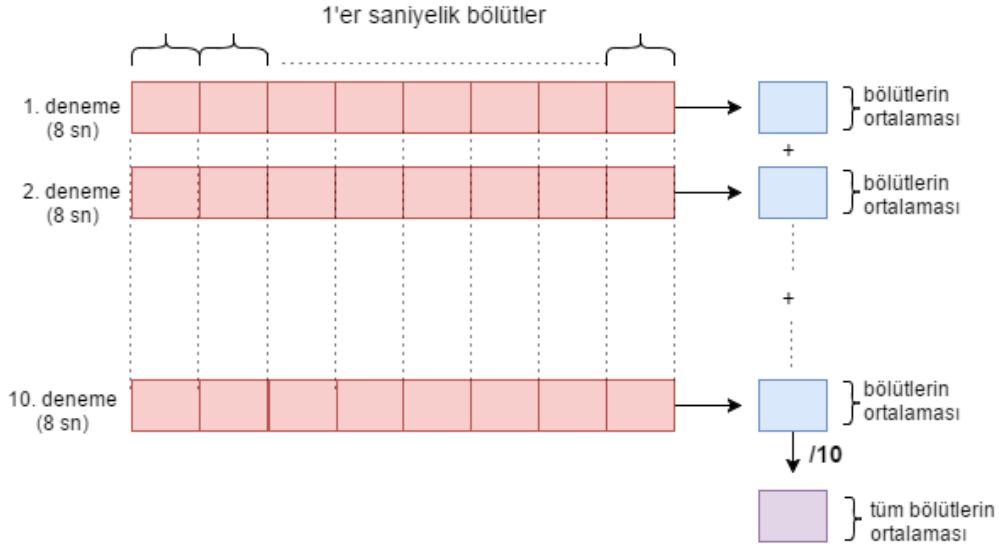
Çalışmada kullanılan 4 iyi – 4 kötü koku arasından en baskın 2 iyi – 2 kötü koku, katılımcıların anket değerlendirmeleri ve güç spektrum grafikleri ile belirlenmiştir. Bu durum Şekil 4.2.'de gösterilmiştir. Koku sayısının azaltılarak en baskın kokuların belirlenmesi ile sınıflandırma sonuçlarının arttırılması amaçlanmıştır. Anket sonuçlarında belirlenen iyi – kötü kokularının diğer kokulara nazaran daha güçlü salınıp yapıp yapmadıkları, güç spektrum grafiklerini incelemekle mümkün olabilir. Koku seçiminde en çok anket sonuçları belirleyici rol oynayacaktır.



Şekil 4.2. Koku Seçimi


EMOTIV – EPOC başlığı kendi yapısında bulunan alçak ve yüksek geçiren filtreler yardımıyla 0.16 – 45 Hz bant çıkışına sahip işaret üretir. Ayrıca işaret 5. dereceden bir sinc filtre yardımı ile 50 Hz şebeke gürültüsünden arındırılır. Deney sırasında katılımcıların gözlerinin kapalı konumda olması ve hareketsiz kalmalarının istenmesi, gereksiz göz kırpma ve kas gürültülerinin önüne geçmiştir.

Veri alımı sırasında her bir kokuya ait veriler 8'er saniye olmak üzere 10 defa kayda alınmıştır. Şekil 4.3.'de görüldüğü üzere *Welch yöntemi* verilerin 1'er saniyelik bölütlerine uygulanmıştır. Bu bölütlerin ortalaması alınarak bir denemenin güç spektrum değeri elde edilmiştir. Aynı işlem 10 deneme için uygulanmış ve ortalaması nihai spektrum değerini vermiştir.




Şekil 4.3. Welch yönteminin koku verisine uygulanışı

Katılımcılara ait anket değerlendirmesi Çizelge 3.3.'de verilmişti. *Welch yöntemi* kullanılarak 8 farklı kokuya ait güç salınımları 14 kanal için Şekil 4.4- 4.17'de verilmiştir. Elde edilen grafikler 6 katılımcıdan ayrı ayrı alınan verilerin ortalama spektrum değerleridir.




Şekil 4.4. AF3 kanalına ait spektral güç yoğunluğu

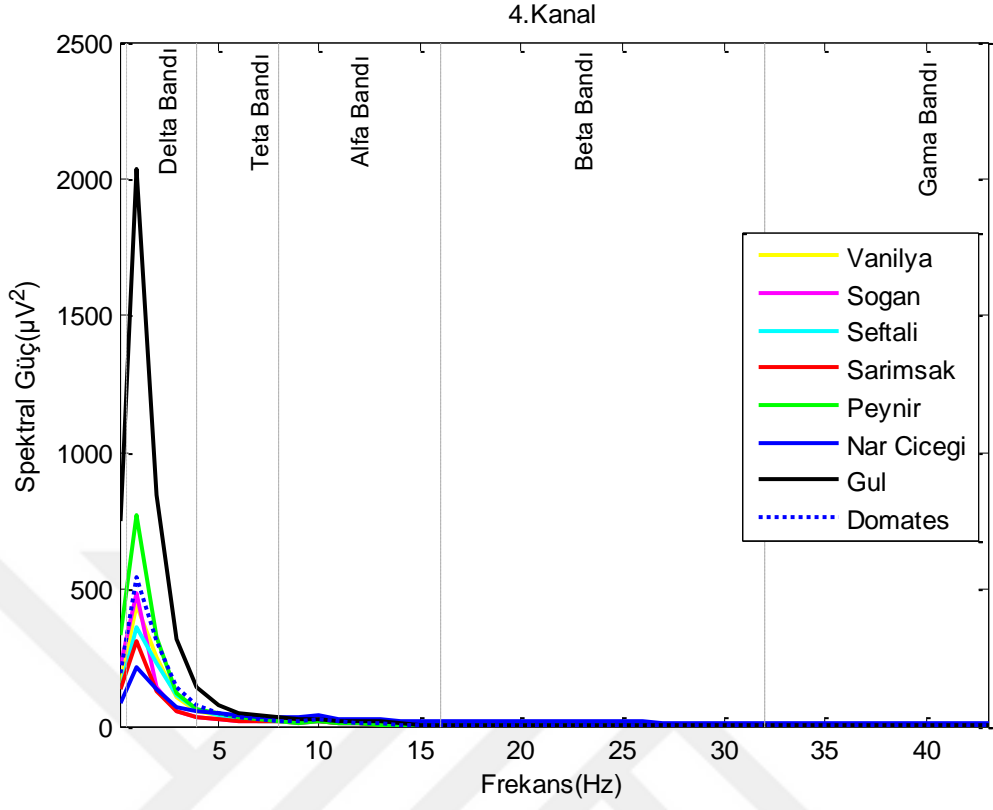
4. ARAŞTIRMA BULGULARI




Şekil 4.5. F7 kanalına ait spektral güç yoğunluğu



Şekil 4.6. F3 kanalına ait spektral güç yoğunluğu




Şekil 4.7. FC5 kanalına ait spektral güç yoğunluğu




Şekil 4.8. T7 kanalına ait spektral güç yoğunluğu


4. ARAŞTIRMA BULGULARI




Şekil 4.9. P7 kanalına ait spektral güç yoğunluğu



Şekil 4.10. O1 kanalına ait spektral güç yoğunluğu




Şekil 4.11. O2 kanalına ait spektral güç yoğunluğu




Şekil 4.12. P8 kanalına ait spektral güç yoğunluğu


4. ARAŞTIRMA BULGULARI




Şekil 4.13. T8 kanalına ait spektral güç yoğunluğu



Şekil 4.14. FC6 kanalına ait spektral güç yoğunluğu

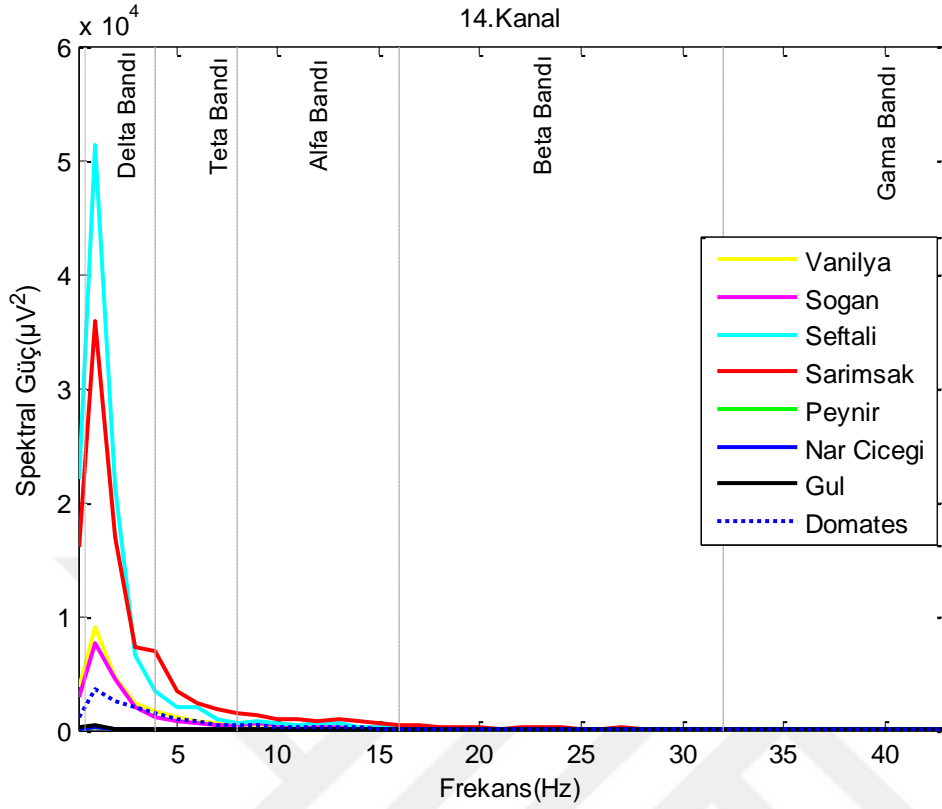


Şekil 4.15. F4 kanalına ait spektral güç yoğunluğu



Şekil 4.16. F8 kanalına ait spektral güç yoğunluğu

4. ARAŞTIRMA BULGULARI



Şekil 4.17. AF4 kanalına ait spektral güç yoğunluğu


Yukarıdaki değerlendirmeler neticesinde vanilya ve gül iyi koku, soğan ve sarımsak ise kötü koku sınıfı olarak kabul edilmiştir. Anket değerlendirmelerine bakıldığında katılımcılar en çok vanilya ve gül kokusunu beğenip soğan ve sarımsak kokularını kötü bulmuşlardır. 14 kanal için spektrumlar incelendiğinde bu 4 kokunun beynin birçok bölgesinde yüksek güçte salınım gösterdiği grafiklerden görülebilmektedir. Grafik ve anketler ışığında koku seçimi böylece tamamlanmış olur.

4.2. ADD Kullanılarak EEG İşaretlerine Ait Öznitelik Çıkarımı

EEG işaretlerinin analizinde istenilen frekans bandına ulaşabilmek için dalgacık seçimi ve istenilen ayrıştırma seviyesi önem arz etmektedir. Literatür incelendiğinde, koku ile ilgili EEG alt bantlarının değişiklik göstermekle birlikte teta, alfa, beta ve gama bandının önemli bilgiler içerdiği görülmektedir [(Kroupi ve ark. 2014), (Skoric ve ark. 2015), (Placidi ve ark. 2015)]. Çalışmada öznitelik çıkarımında tüm alt bantlar kullanılmıştır.

EMOTIV – EPOC başlığı 128 Hz örnekleme frekansına sahiptir. Bu nedenle ayrıştırma seviyesi 4 olarak seçilmiştir. Literatüre bakıldığında Daubechies dalgacık ailesinin EEG işaretlerinin alt seviyelerine ayrıştırılmasında başarılı sonuçlar verdiği

bilinmektedir [(Chavan ve Kolte 2013), (Gandhi ve ark. 2011)]. Bu çalışmada 3. dereceden Daubechies (db3) dalgacık modeli seçilmiştir. Şekil 4.18.'de EEG işaretine uygulanan 4. seviye ADD görülmektedir.



Şekil 4.18. 4. Seviye ADD akış diyagramı

Şekil 4.18.'de görülen dalgacık katsayılarının hangi frekans aralığına karşılık geldiği Çizelge 4.1.'de gösterilmiştir.

Çizelge 4.1. EEG alt bantlarına karşılık gelen yaklaşım ve detay katsayıları

Wavelet Katsayıları	Frekans Aralığı (Hz)	Karşılık gelen EEG bandı
cA4	0.5-4	Delta (δ)
cD4	4-8	Teta (θ)
cD3	8-16	Alfa (α)
cD2	16-32	Beta (β)
cD1	32-64	Gama (γ)

Çizelge 4.1.'de verilen dalgacık katsayıları, Şekil 4.19.'da gösterilen bölütlere uygulanmıştır.

4. ARAŞTIRMA BULGULARI



128 Hz örnekleme frekansında alınmış 14 kanala sahip 8 saniyelik koku bilgisi 1024 x 14 mimarisine sahiptir. 8 saniyelik işaretler 1'er saniyelik bölütlere ayrılarak 128 x 14 şeklinde bölütlere elde edilmiştir. Bu bölütlere ADD uygulanarak cA4, cD4, cD3, cD2, cD1 dalgacık katsayıları elde edilmiş ve ortalamaları alınmıştır. 10 denemeden her biri ayrı örüntü kabul edilip benzer işlemler uygulanmıştır. Sonuç olarak 128 x 140 mimarisine sahip EEG alt bantları elde edilmiştir.

4.3. İstatiksel İşlemlerle Öznitelik Boyutunun Küçültülmesi

Bu çalışmada 6 katılımcının iyi – kötü kokulara ilişkin EEG işaretleri için öznitelik vektörleri ADD kullanılarak elde edilmiştir. EEG işaretlerinin Çizelge 4.1.'de gösterilen delta – teta – alfa – beta – gamma alt bantları öznitelik olarak değerlendirilmiştir. Bu alt bantlar ilk olarak normalizasyon işleminden geçirilip banda ait tüm değerler 0 – 1 değeri arasına çekilmiştir. Sonrasında 128 x 140 boyutundaki vektör boyutlarının azaltılması için 7 adet istatiksel işlemden elde edilen veriler kullanılmıştır. Bunlar; yaklaşık entropi, örnek entropi, mutlak değerlerin minimum ve maksimum değerleri, ortalama değer, standart sapma ve medyan değerleridir. Bu istatiksel işlemlere ait matematiksel ifadeler;

a) Yaklaşık entropi:

$$ApEn(m, r, N) = -\frac{1}{N-m} \sum_{i=1}^{N-m} \log \left(\frac{A_i}{B_i} \right) \quad (4.1)$$

x_1, x_2, \dots, x_N zaman serisinde, $x_m(i)$, $x_i, x_{i+1}, \dots, x_{i+m-1}$ 'deki m nokta sayısı veya vektör uzunluğu, r, $x_m(i)$ ile $x_m(j)$ arasındaki uzaklık, $p_i = \frac{A_i}{B_i}$ ise $x_m(i)$ ile $x_m(j)$ 'nin benzeşmesine dayalı şartlı olasılıktır.

b) Örnek entropi;

$$SamEn(m, r, N) = -\log\left(\frac{\sum_{i=1}^{N-m} A_i}{\sum_{i=1}^{N-m} B_i}\right) \quad (4.2)$$

c) Katsayıların mutlak değerlerinin minimumu:

$$x_{min} = \min|x(n)| \quad (4.3)$$

d) Katsayıların mutlak değerinin maksimumu:

$$x_{max} = \max|x(n)| \quad (4.4)$$

e) Katsayı kuvvetlerinin ortalaması:

$$x_{ort} = \frac{\sum_{n=1}^N x(n)}{N} \quad (4.5)$$

$x(n)$, $n= 1, 2, 3, \dots, N$ içindir

f)Standart sapma:

$$x_{std} = \sqrt{\frac{1}{N} \sum_{n=1}^N (x(n) - x_{ort})^2} \quad (4.6)$$

g) Medyan:

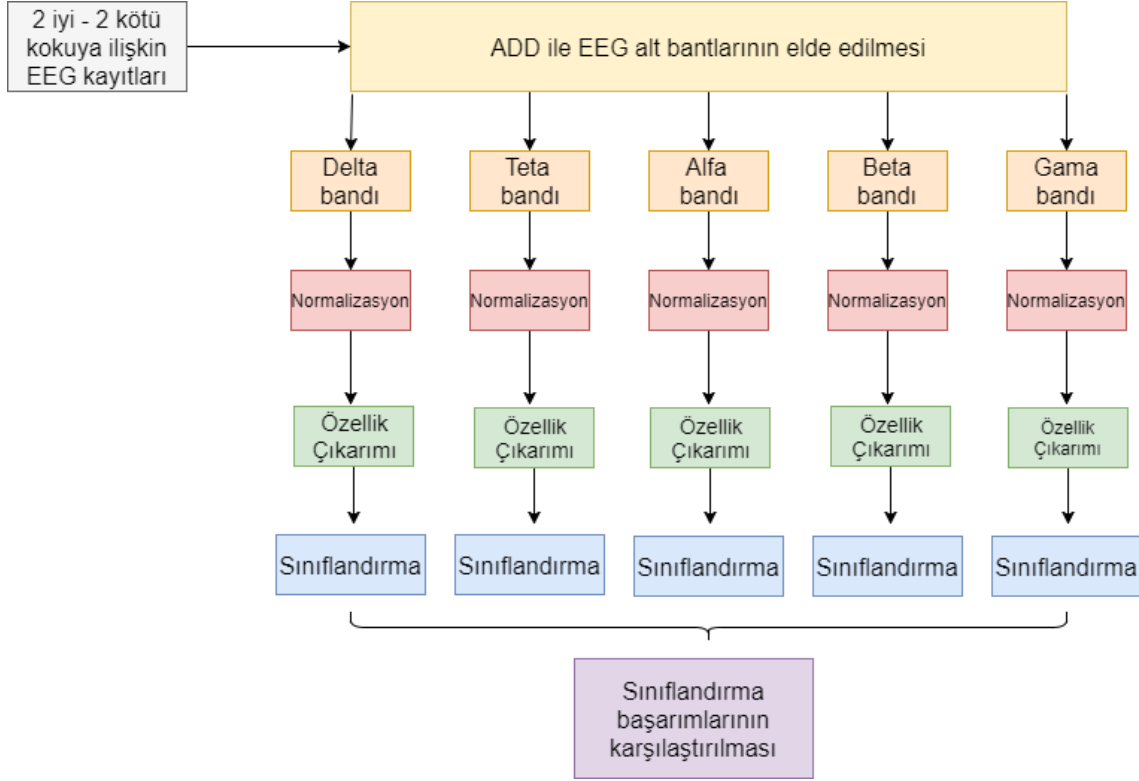
$x(n)$, $n= 1, 2, 3, \dots, N$ için;

$$M = \begin{cases} x_{(N+1)/2}, & N \text{ tek ise} \\ \frac{x_{N/2} + x_{(N/2)+1}}{2}, & N \text{ çift ise} \end{cases} \quad (4.7)$$

Kısa süreli zaman serilerine ait sınıflandırmada *SampEn* ve *ApEn* öznelikleri başarılı sonuçlar vermektedirler. Bu yöntemler bir işaretin düzgünlüğünü ve kestirebilirliğini niteler (Yentes ve ark. 2012). Çalışmada kullanılan kısa süreli koku verilerinden dolayı bu özneliklerin başarı oranını arttıracığı hedeflenmiştir. min ve max değerleri işarete ait zaman serisi içindeki minimum ve maksimum değerlerdir. Medyan değeri bu serinin ortasındaki değer, standart sapma seri içindeki değerlerin

4. ARAŞTIRMA BULGULARI

dağılımının düzgünlüğünün ölçüsüdür. Tüm kanallara ait iyi – kötü kokuların sınıflandırma aşamaları Şekil 4.20.'de gösterilmiştir.



Şekil 4.20. Tüm kanallara ait iyi – kötü kokuların sınıflandırma akış şeması

4.4. EEG Öznitelik Vektörlerinin WEKA ile Sınıflandırılması

EEG'ye ait öznitelik vektörleri, her bant için WEKA veri madenciliği programında bulunan 4 farklı algoritma ile sınıflandırılmıştır. Bunlar ÇKA, NB, k-NN ve RO algoritmalarıdır. Sınıflandırma 3 aşamada gerçekleştirilmiştir. Bunlar:

1. Her katılımcıya ait tüm bantları içeren sınıflandırma
2. Her katılımcı için en başarılı 2 bandın birleştirilmesi ve sınıflandırılması
3. Tüm katılımcılara ilişkin en yüksek başarıma sahip 2 bandın birleştirilmesi ve sınıflandırılması

4.4.1. ÇKA için WEKA’da kullanılan parametreler

The screenshot shows the WEKA GUI for the MultilayerPerceptron classifier. The window title is 'weka.gui.GenericObjectEditor'. The classifier name is 'weka.classifiers.functions.MultilayerPerceptron'. The settings are as follows:

Parameter	Value
GUI	False
autoBuild	True
batchSize	100
debug	False
decay	False
doNotCheckCapabilities	False
hiddenLayers	a
learningRate	0.3
momentum	0.2
nominalToBinaryFilter	True
normalizeAttributes	True
normalizeNumericClass	True
numDecimalPlaces	2
reset	True
seed	0
trainingTime	500
validationSetSize	0
validationThreshold	20

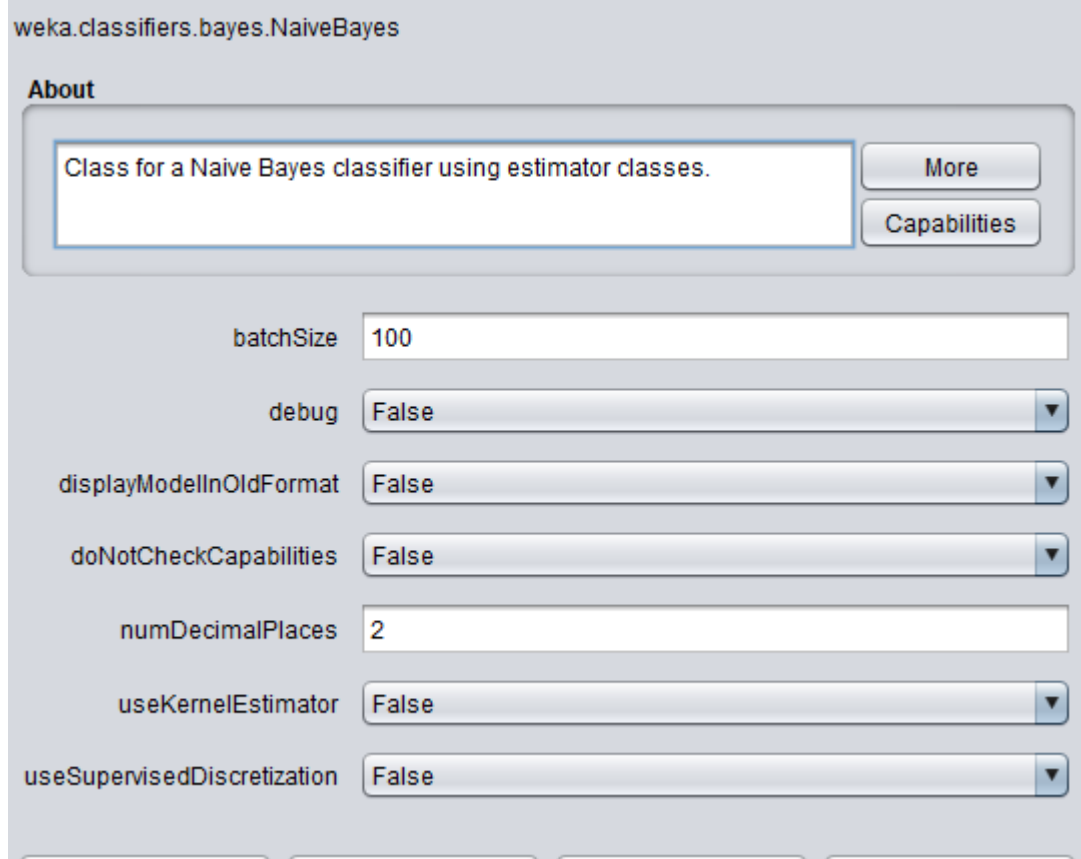
Şekil 4.21. WEKA ara yüzündeki ÇKA’ya ait parametreler

Şekil 4.21’de belirtildiği üzere öğrenme oranı (ağırlıkların güncellenme miktarı) 0.3, momentum (güncellenme sırasında ağırlıklara uygulanan değer) 0.2, eğitim için geçen epok sayısı 500, çaprazlama yüzdesi 0 (tüm sınıflandırıcılarda 10 çapraz doğrulama zaten kullanılmakta), gizli katman sayısı olarak ‘a’ değeri kullanılmıştır. a,

4. ARAŞTIRMA BULGULARI

öznitelik sayısı ile sınıf sayısının toplamının yarısı kadardır. Çalışmada 7 öznitelik, 2 de sınıf sayısı olduğundan bu değer 4 olarak seçilir. Çalışmada tek gizli katman tercih edilmiştir. Çok katmanlı sınıflandırma tercihleri için Şekil 4.21’de belirtilen ‘hiddenLayers’ kısmına ‘a, 1. katmandaki nöron sayısı, 2. Katmandaki nöron sayısı...’ yazılabilir.

4.4.2. NB için WEKA’da kullanılan parametreler



The image shows the WEKA interface for the Naive Bayes classifier. The title bar reads 'weka.classifiers.bayes.NaiveBayes'. Below the title bar, there is an 'About' section with a text box containing 'Class for a Naive Bayes classifier using estimator classes.' and two buttons: 'More' and 'Capabilities'. Below the 'About' section, there are several parameters with their values:

Parameter	Value
batchSize	100
debug	False
displayModelInOldFormat	False
doNotCheckCapabilities	False
numDecimalPlaces	2
useKernelEstimator	False
useSupervisedDiscretization	False

Şekil 4.22. WEKA ara yüzündeki NB’ye ait parametreler

NB algoritması için ‘default’ kabul edilen Şekil 4.22’deki değerler kullanılmıştır.

4.4.3. k-NN için WEKA’da kullanılan parametreler

weka.classifiers.lazy.IBk

About

K-nearest neighbours classifier.

KNN

batchSize

crossValidate

debug

distanceWeighting

doNotCheckCapabilities

meanSquared

nearestNeighbourSearchAlgorithm

numDecimalPlaces

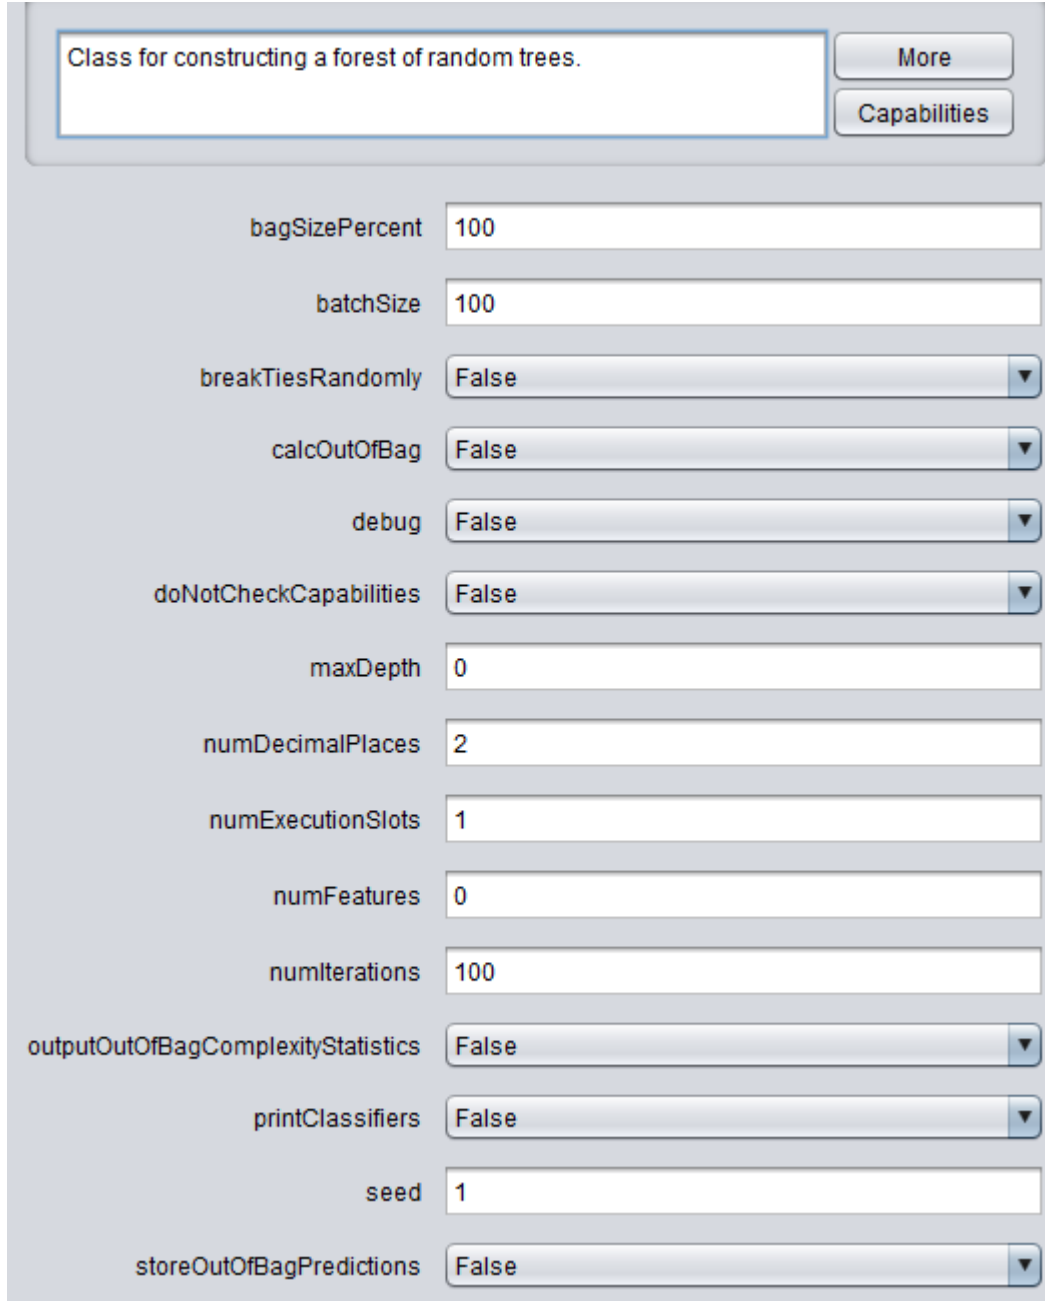
windowSize

Şekil 4.23. WEKA ara yüzündeki k-NN’e ait parametreler

k-NN algoritmasında Şekil 4.23’de görüldüğü üzere komşuluk sayısı 2, en yakın komşuyu seçen uzaklık ölçütü olarak öklid mesafesi kullanılmıştır.

4. ARAŞTIRMA BULGULARI

4.4.4. RO için WEKA’da kullanılan parametreler



The image shows a screenshot of the WEKA software interface for the Random Forest (RO) algorithm. At the top, there is a text box containing the class name "Class for constructing a forest of random trees." and two buttons: "More" and "Capabilities". Below this, a list of parameters is displayed, each with a label and a corresponding input field or dropdown menu. The parameters and their values are:

Parameter	Value
bagSizePercent	100
batchSize	100
breakTiesRandomly	False
calcOutOfBag	False
debug	False
doNotCheckCapabilities	False
maxDepth	0
numDecimalPlaces	2
numExecutionSlots	1
numFeatures	0
numIterations	100
outputOutOfBagComplexityStatistics	False
printClassifiers	False
seed	1
storeOutOfBagPredictions	False

Şekil 4.24. WEKA ara yüzündeki RO’ya ait parametreler

RO algoritması için kullanılan ‘default’ değerler Şekil 4.24’de görülmektedir.

Her üç aşama için elde edilen sonuçlar Çizelge 4.2.’de belirtilmiştir.

4. ARAŞTIRMA BULGULARI

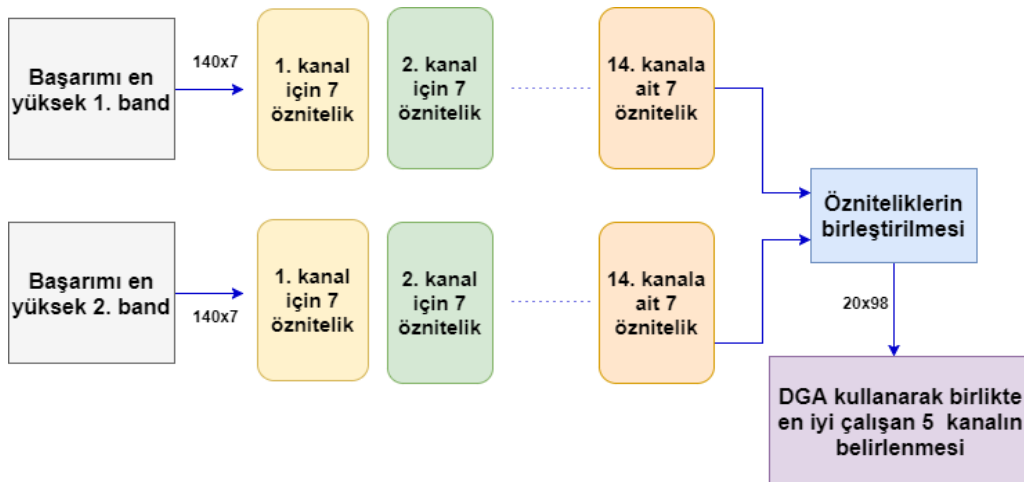
Çizelge 4.2.'de 6 katılımcıya ait 4 sınıflandırıcı için başarımlarını gösterilmiştir. Sınıflandırma algoritmaları öncesi veriler, $randperm((\text{satır sayısı}), :)$ MATLAB komutu ile karıştırılarak sınıflandırma işlemine tabi tutulmuştur. Sınıflandırma başarımlarını en yüksek alfa bandında gözlenmekle birlikte bunu daha düşük bir başarımla beta bandı izlemektedir. Bu gözlemler literatür tarafından desteklenmektedir [(Martin, 1998), (Kroupi ve ark. 2014), (Skoric ve ark. 2015), (Placidi ve ark. 2015)]. Sınıflandırma yapılırken k katlamalı çapraz doğrulama uygulanmıştır. Uygulamada için k defa yöntem çalıştırılır. Her adımda daha önce veri kümesinde test için kullanılmamış $1/k$ kadarlık kısım test için kullanılırken, geri kalan kısım eğitim için kullanılır. Bu işlem;

$$\text{sonuç} = \frac{\sum_{i=0}^K SF(t_i, VK-t_i)}{k} \quad (4.8)$$

şeklinde. $t_i \in VK$ olmak üzere, SF (eğitim, test) sınıflandırma fonksiyonunu, VK veri kümesini, k kaç parça katlama yapılacağı, t_i ise veri kümesi üzerinden seçilen test kümesini temsil eder. Sonuç olarak bütün sınıflandırma başarımları k'ya bölünüp ortalama alınır. Bu çalışmadaki sınıflandırma işlemlerinde k=10 olarak seçilmiştir.

4.5. DGA ile Kanal Seçimi ve Sınıflandırma İşlemlerinin Tekrarlanması

Bu çalışmada DGA kullanılarak birlikte en iyi çalışan 5 kanal her katılımcı için ayrı ayrı belirlenip sınıflandırma işlemleri yeniden yapılmıştır. Buradaki motivasyon Çizelge 4.2.'deki başarımlarını daha az kanal kullanarak yakalayabilmektir. En iyi 5 kanal seçilirken, Çizelge 4.2.'deki her kişi için belirlenmiş en başarılı 2 bant veri olarak kullanılmıştır. Kanal seçimi aşamaları Şekil 4.25.'de gösterilmiştir.



Şekil 4.25. Kanal seçimi aşamaları

MATLAB ortamında gerçekleştirilen kanal seçimi için mevcut komut satırı:

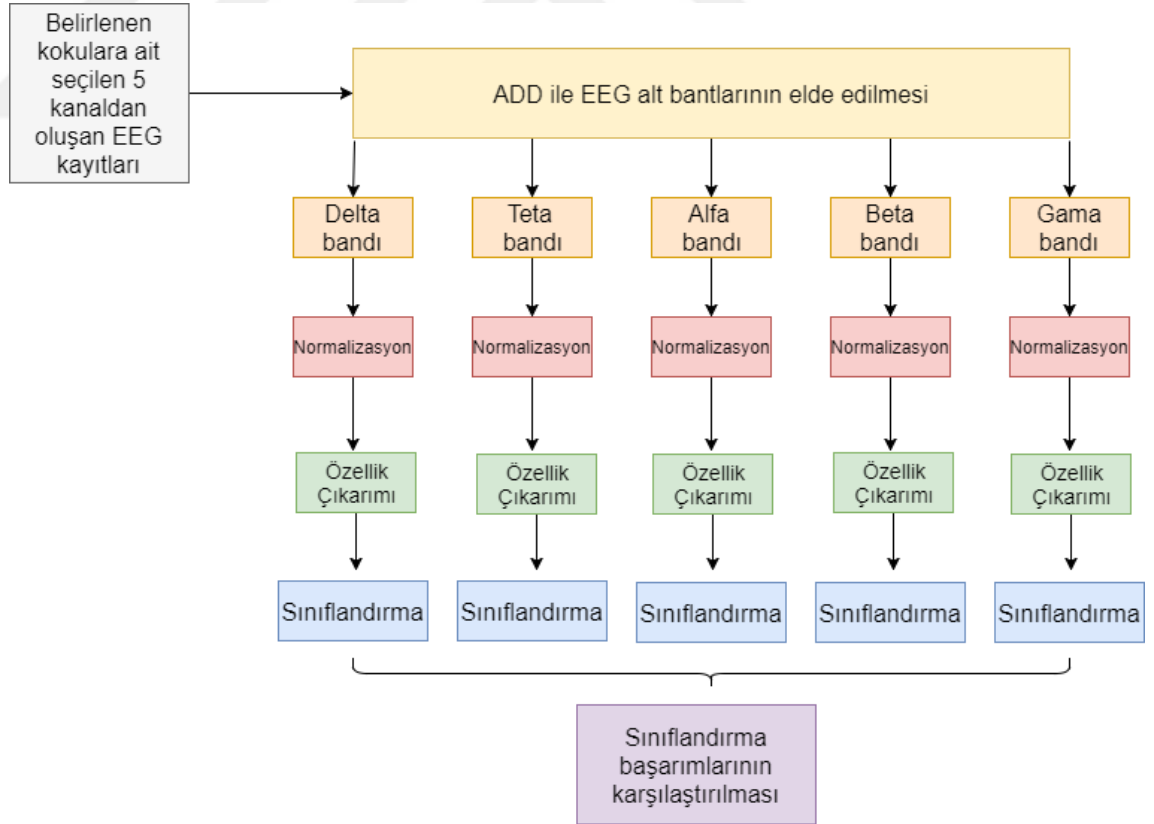
```
toplam_bant = [Etkin Bant Bant I ; Etkin Bant II] ;
```

```
toplam_bant = toplam_bant (randperm (sattır sayısı), :) ;
```

[Err,Subset] = DEFS_chs (eğitim data, test data, seçilmek istenen kanal sayısı, popülasyon boyutu, sınıflandırıcı seçimi, iterasyon sayısı, kullanılan öznitelik sayısı) ;
şeklindedir.

Burada eğitim verisi toplam_bant (1:2:end,:) ; test verisi toplam_bant (2:2:end,:) , seçilmek istenen kanal sayısı 5, popülasyon boyutu 50, sınıflandırıcı olarak 'LDA', iterasyon sayısı 150, kullanılan öznitelik sayısı 7 olarak seçilmiştir. Daha büyük popülasyon seçimi optimal çözümü bulmakta etkin olmakla birlikte algoritmanın bulma hızını yavaşlatır. Büyük veri kullanımında iterasyon sayısını arttırmak avantaj sağlamaktadır.

Kanal seçimi sonrası uygulama adımları Şekil 4.26.'de gösterilmiştir. Uygulama adımları Şekil 4.20.'de gösterilen tüm kanallar için yapılan sınıflandırma aşamalarına benzerdir. Sınıflandırma başarımları Çizelge 4.3.'de verilmiştir.



Şekil 4.26. Belirlenen en iyi 5 kanal ardına sınıflandırma işlemleri

Seçilen kanallar A kişisi için (T7, O1, T8, F4, AF4), B kişisi için (AF3, F7, FC5, T8, F4), C kişisi için (AF3, P7, P8, T8, F8), D kişisi için (F3, O1, O2, P8, T8), E kişisi için (F3, FC5, T8, F4, AF4) ve F kişisi için (F7, F3, O1, F4, F8) elektrotlarıdır. Elektrotlar incelendiğinde koku ile ilgili en etkin kanalların beynin frontal ve temporal bölgelerinde yoğunlaştığı görülmüştür. Bu veriler literatürü destekler niteliktedir [(Lorig 1990), (Sanders 2002), (Kroupi ve ark. 2014), (Kroupi ve ark. 2016)]. 5 kanal sonucu iyi – kötü kokular en iyi beta ve gama bandında ayrıştırılmıştır.





5. TARTIŞMA VE SONUÇ

Bu tez çalışmasının amacı, iyi kötü kokular ile ilişkili EMOTIV-EPOC tabanlı EEG kayıtlarının makine öğrenmesi yöntemleri ile sınıflandırılmasıdır. Ayrıca iyi – kötü kokuların EEG işaretlerindeki dalgalanmaları nasıl etkilediğini incelemek, beyin aktivitesi üzerinde nasıl değişimler oluşturduğunu gözlemlemektir. Kokuların beyin hangi frekans bandında ve bölgesinde daha etkin olduğunu irdelemek amacıyla bu kokulara ait EEG işaretlerinin makine öğrenmesi yöntemleri ile sınıflandırılması amaçlanmıştır. Mevcut yöntemin bazı nörolojik hastalıkların (Parkinson, Alzheimer, motor nöron rahatsızlıkları) erken teşhisinde kullanılabileceği öngörülmüştür. Kokunun literatürden ve yapılan çalışmadan sübjektif bir kavram olduğu, aynı kokunun her kişide her zaman aynı etkiyi göstermediği anlaşılmıştır.

Çalışma boyunca elde edilen bulgular aşağıda belirtildiği gibi yorumlanabilir:

1) Güç spektrum grafikleri: Bant gücündeki yoğunluk düşük frekans bandında (delta) birikmiştir. Genel anlamda iyi kokular yüksek bant gücünde salınım gösterirken, kötü kokular daha düşük seviyede salınım göstermişlerdir.

2) İyi kokuların uygulanması sonucu beyin sol yarım küresinde, kötü kokuların uygulanması sonucu ise sağ yarım küresinde aktivite artışı görülmektedir. Beynin birçok bölgesinde koku verilerine karşı asimetrik bir tepki söz konusudur.

3) Anket uygulaması ve koku seçimi: Katılımcıların anket değerlendirmesi ile güç spektrum grafikleri birbirine paralellik göstermektedir. Gül ve vanilya kokuları en baskın iyi kokular olarak seçilirken, soğan ve sarımsak kokuları ise en baskın kötü kokular olarak belirlenmiştir. Baskın karakteristiğe sahip kokuların seçilmesi ile sınıflandırma işlemlerinde ayrıştırma oranlarını arttırmak hedeflenmiştir.

4) Hesap yükünün azaltılması: Koku verilerine ilişkin EEG işaretlerine ADD uygulanarak dalgacık katsayıları elde edilmiştir. Öznitelik olarak kabul edilen bu katsayıların veri boyutu büyüktür. Öznitelik vektörlerine ait veri boyutları bazı istatistiksel işlemler (örnek entropi, yaklaşık entropi, mutlak değerce en büyük değer, mutlak değerce

5.TARTIŞMA VE SONUÇ

en küçük deęer, ortalama deęer, standart sapma ve medyan) kullanılarak azaltılmıřtır. Bylece alıřmada nerilen sınıflandırma algoritmalarının iřlem yk azaltılmıřtır.

5) Sınıflandırma bařarımları: alıřmada sınıflandırma iřlemleri 2 farklı kademe ile yapılmıřtır. Bunlar tm kanallar (14 kanal) iin sınıflandırma ve DGA kullanılarak seilen 5 kanal iin sınıflandırma olarak 2 eřitir. Her kademe kendi iinde 3 ana ařamadan oluřur. 1. ařamada EEG kayıtlarına ait 5 farklı banda, 2. ařamada sınıflandırma her kiřiye ait bařarımı en yksek iki bandın birleřimi ile oluřan veriye, 3. ařamada ise her kiřiden elde edilen en bařarılı iki bandın ortak bir havuza atılarak oluřan veriye sınıflandırma algoritmaları uygulanmıřtır. 1. ve 2. ařama kiřisel bazlı, 3. ařama ise genel bazlı sınıflandırmadır. Genel bazlı sınıflandırmanın amacı, kiřilerden baęımsız ıkarımların yapılabilmesidir. Sınıflandırma algoritmaları olarak Naive Bayes, kNN, ok katmanlı algılayıcı ve rastgele orman algoritması kullanılmıřtır. Tm kanalların kullanıldıęı ařamada, her katılımcıya ait en bařarılı 2 bandın birleřtirildięi sınıflandırma sonularına bakıldıęında NB % 70.93, kNN % 92.76, KA % 92.73 ve RO algoritması %99.19 bařarım oranları elde edilmiřtir. Seilen 5 kanalın kullanıldıęı ařamada sınıflandırma sonularına bakıldıęında NB % 68.45, kNN % 88.95, KA % 88.83 ve RO algoritması %97.58 bařarım oranları elde edilmiřtir. Sonular incelendięinde daha az kanal sayısıyla da bařarım oranının yksek olduęu grlmřtr. alıřmada en bařarılı sınıflandırma algoritmasının RO olması beklenen bir durumdur. Algoritmanın birok alıřmada st seviyede sınıflandırma bařarımları verdięi zaten bilinmektedir. En iyi 2 bandın ve tm en iyi bantların birleřtirilmesi ile yapılan sınıflandırma iřlemlerinde bařarımın yine yksek olduęu fakat nceki ařamalara gre dřtę gzlemlenmiřtir. Bu durum rnt boyutunun artması ile barındırılan ayrıntıların sınıflandırıcılar tarafından saptanamadıęı řeklinde yorumlanabilir.

5) Tm kanallar (izelge 4.2) ile yapılan sınıflandırmada genel ortalamaya bakıldıęında alfa bandı %98.10, beta bandı %95.46 ile en yksek bařarım oranlarına sahip bantlardır. Seilen kanallar (izelge 4.3) ile yapılan sınıflandırmada genel ortalamaya bakıldıęında ise beta bandı %98.68, gama bandı %96.6 ile en yksek bařarım oranlarına sahip bantlardır. Buradan bařarımın en yksek olduęu ortak bandın beta bandı olduęu grlmřtr. Bu yzden beta bandı, koku ile en ilgili frekans bilgisini ieren EEG alt bandı olarak nitelendirilebilirler. Ayrıca seilen 5 kanal arasında birok elektrodun

beynin frontal ve temporal bölgelerine ait olduğu görülmüştür. Frontal ve temporal bölgelerin diğerlerine oranla kokuların oluşturduğu uyarılara daha hassas olduğu söylenebilir. 5 kanal seçimi ile başarımlarının genel olarak tüm kanallara göre yükseldiği yorumlanabilir.

6) Kokuların beyindeki etkisi kişiden kişiye değişmektedir. Dolayısıyla elde edilen öznelikler farklı değer aralıklarında olabilmektedir. Bu da sınıflandırma başarımlarının düşmesine etki eden bir faktör olarak ele alınabilir.

7) Çalışmada veri alınan katılımcı sayısının artırılması ve yeni özneliklerin eklenmesi ile yukarıda belirtilen çıkarımların daha netlik kazanacağı öngörülmektedir.

Çalışmanın bundan sonra yapılacak benzer çalışmalara ışık tutacağı düşünülmektedir.

6. KAYNAKLAR

- Alkan A., Yılmaz S. A. 2007. Kapasitör Anahtarlama Sonucu Oluşan Geçici Salınımların Frekans ve Zaman Frekans Domeninde Analizi. Elektrik-Elektronik-Bilgisayar Mühendisliği 12. Ulusal Kongresi Ve Fuarı Bildirileri.
- Barresi, M., Cuirleo, R., Giacoppo, S., Foti Cuzzola, V., Celi, D., Bramanti, P., Marino, S. 2012. Evaluation of olfactory dysfunction in neurodegenerative diseases. *Journal of the Neurological Sciences*, 323(1–2), pp.16–24. Erişim[: <http://dx.doi.org/10.1016/j.jns.2012.08.028>], Erişim Tarihi: 09.02.2017.
- Başçıl, M.S., 2015. Beyinde üretilen yöne bağlı eeg sinyallerinin öznitelik çıkarımı yardımıyla sınıflandırılması. Doktora Tezi, Fen Bilimleri Enstitüsü, Sakarya, 129.
- Bensafi, M., Pierson, A., Rouby, C., Farget, V., Bertrand, B., Vigoroux, V., Jouvent, R., Holley, A. 2002. Modulation of visual event-related potentials by emotional olfactory stimuli. *Neurophysiologie Clinique*, 32(6), pp.335–342.
- Bensafi, M., 2012. The role of the piriform cortex in human olfactory perception: Insights from functional neuroimaging studies. *Chemosensory Perception*, 5(1), pp.4–10.
- Berlin, H.A., Stern, E.A., Ng, J., Zhang, S., Rosenthal, D., Trutzky, R., Tang, C., Goodman, W. 2017. Altered olfactory processing and increased insula activity in patients with obsessive-compulsive disorder: An fMRI study. *Psychiatry Research: Neuroimaging*, 262(January), pp.15–24. Erişim: [<http://dx.doi.org/10.1016/j.pscychresns>], Erişim Tarihi: 12.01.2017.
- Breiman, L., 2001. RANDOM FORESTS. University of California Berkeley.
- Bronzino, J.D., 2000. Principles of electroencephalography. In *The Biomedical Engineering Handbook: Second Edition*. pp. 358–362.
- Bulsing, P.J., Smeets, M. A. M., Hummel, T., van den Hout, M.A. 2007. Influence of chemosensory pain-expectancy on olfactory event-related potentials. *NeuroImage*, 38(1), pp.164–170.
- Büyükyılmaz, İ.S., 2012. Biyomedikal İşaretlerin Sınıflandırılması. Doktora Tezi, Fen Bilimleri Enstitüsü, Tekirdağ, 104.

6. KAYNAKLAR

Cerf-Ducastel, B., Murphy, C. 2006. Neural substrates of cross-modal olfactory recognition memory: An fMRI study. *NeuroImage*, 31(1), pp.386–396. Erişim: [<http://linkinghub.elsevier.com/retrieve/pii/S1053811905024717>], Erişim Tarihi: 08. 02.2017.

Cerf-Ducastel, B., Murphy, C. 2009. Age-related differences in the neural substrates of cross-modal olfactory recognition memory: An fMRI investigation. *Brain Research*, 1285(2003), pp.88–98. Erişim: [<http://dx.doi.org/10.1016/j.brainres.2009.05.086>], Erişim Tarihi: 17.02.2017.

Chavan, A., Kolte, M. 2013. Optimal Mother Wavelet for EEG Signal Processing. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, pp.5959–5963.

Covington, J.W., Geisler, M.W., Polich, J., Murphy, C. 1999. Normal aging and odor intensity effects on the olfactory event-related potential. *International Journal of Psychophysiology*, 32(3), pp.205–214.

Daniels, C., Gottwald B., Pause, B.M., Sojka, B., Mehdorn, H.M., Ferstl, R. 2001. Olfactory event-related potentials in patients with brain tumors. *Clinical Neurophysiology*, 112(8), pp.1523–1530. Erişim: [<http://www.ncbi.nlm.nih.gov/pubmed/11459693>], Erişim Tarihi: 16. 03.2017.

Demir, Ö., 2008. EEG Dalgalarının Wavelet (Dalgacık) Dönüşümü İle Değerlendirilmesi. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Kütahya.

Eraldedemir, S.G., 2014. EEG Verileri Kullanılarak Metinsel Okuma ve Matematiksel İşlemlerin Analizi. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Hatay.

Evans, W.J., Cui, L. & Starr, A. 1995. Olfactory event-related potentials in normal human subjects: effects of age and gender. *Electroencephalography and clinical neurophysiology*, 95(4), pp.293–301.

Fonaryova Key, A.P., Dove, G.O., Maguire, M.J. 2013. ERPs Peak Review. *Journal of Chemical Information and Modeling*, 53(9), pp.1689–1699.

Gandhi, T., Panigrahi, B.K., Anand, S. 2011. A comparative study of wavelet families for EEG signal classification. *Neurocomputing*, 74(17), pp.3051–3057.

Harada, H., Rikimaru, F., Mori, T., Tanaka, M. 2002. Electroencephalographic Changes During Intravenous Olfactory Stimulation in Humans. *Clinical EEG (electroencephalography)*, 33(4), pp.189–192.

Harada, H., Shiraishi, K., Kato, T., Soda, T.1996. Coherence analysis of EEG changes during odour stimulation in humans. *The Journal of laryngology and otology*, 110(7), pp.652–6. Erişim:[<http://www.ncbi.nlm.nih.gov/pubmed/8759539>], Erişim Tarihi: 19. 02.2017.

Jurcak, V., Tsuzuki, D., Dan, I. 2007. 10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems. *NeuroImage*, 34(4), pp.1600–1611.

Keskintürk, T., 2006. Diferansiyel Gelişim Algoritması. İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, 9, pp.85–99.

Khushaba, R.N., Al-Ani, A., Al-Jumaily, A. 2011. Feature subset selection using differential evolution and a statistical repair mechanism. *Expert Systems with Applications*, 38(9), pp.11515–11526. Erişim:[<http://dx.doi.org/10.1016/j.eswa.2011.03.028>], Erişim Tarihi: 20.04. 2017.

Klemm, W.R., Lutes, S. D., Hendrix, D.W., Warrenburg, S. 1992. Topographical EEG maps of human response to odors. *Chemical Senses*, 17(3), pp.347–361.

Krbot Skorić, M., Adamec, I., Jerbic, A. B., Gabelic, T., Hajnesek, S., Habek, M. 2015. Electroencephalographic Response to Different Odors in Healthy Individuals: A Promising Tool for Objective Assessment of Olfactory Disorders. *Clinical EEG and neuroscience*, 46(4), pp.370–6. Erişim:[<http://eeg.sagepub.com/content/early/2014/11/17/1550059414545649.abstract>], Erişim Tarihi: 11.02.2017.

Kroupi, E., Vesin, J.M., Ebrahimi, T. 2016. Subject-Independent Odor Pleasantness Classification Using Brain and Peripheral Signals. *IEEE Transactions on Affective Computing*, 7(4), pp.422–434.

Kroupi, E., Sopic, D., Ebrahimi, T. 2014. Non-linear EEG features for odor pleasantness recognition. 2014 6th International Workshop on Quality of Multimedia Experience, QoMEX 2014, pp.147–152.

Kroupi, E., Yazdani, A., Vesin, J.M., Ebrahimi, T. 2012. Multivariate spectral analysis for identifying the brain activations during olfactory perception. In *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*. pp. 6172–6175.

6. KAYNAKLAR

Kroupi, E., Yazdani, A., Vesin, J.M., Ebrahimi, T. 2014. EEG Correlates of Pleasant and Unpleasant Odor Perception. *ACM Transactions on Multimedia Computing, Communications, and Applications*, 11(1s), pp.1–17. Eriřim:[<http://dl.acm.org/citation.cfm?id=2675060.2637287>]. Eriřim Tarihi: 23.04.2017.

Lanata, A., Guidi, A., Greco, A., Valenza, G., Di Francesco, F., Scilingo, E. P. 2016. Automatic recognition of pleasant content of odours through ElectroEncephaloGraphic activity analysis. In 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, pp. 4519–4522. Eriřim:[<http://www.ncbi.nlm.nih.gov/pubmed/28269281>], Eriřim Tarihi: 13.03.2017.

Liaw A., Wiener M. 2002. Classification And Regression By Random Forest. *R News*, Vol.2/3.

Lorig, T.S., Herman, K.B., Schwartz, G. E., Cain, W.S. 1990. EEG activity during administration of low-concentration odors. *Bulletin of the Psychonomic Society*, 28(5), pp.405–408. Eriřim:[<http://link.springer.com/10.3758/BF03334051>], Eriřim Tarihi: 12.04.2017.

Martin, G.N. 1998. Human electroencephalographic (EEG) response to olfactory stimulation: Two experiments using the aroma of food. *International Journal of Psychophysiology*, 30(3), pp.287–302.

Masaoka, Y., Harding, I.H. 2014. The neural cascade of olfactory processing: A combined fMRI-EEG study. *Respiratory Physiology and Neurobiology*, 204, pp.71–77. Eriřim:[<http://dx.doi.org/10.1016/j.resp.2014.06.008>], Eriřim Tarihi: 15.02.2017

Maurage, P., Callot, C., Rombaux, P. 2011. Chemosensory event-related potentials in alcoholism: A specific impairment for olfactory function. *Biological Psychology*, 88(1), pp.28–36. Eriřim: [<http://dx.doi.org/10.1016/j.biopsycho.2011.06.004>].

Min, B.C., Jin, S.H., Sakamoto, K. 2003. Analysis of mutual information content for EEG responses to odor stimulation for subjects classified by occupation. *Chemical Senses*, 28(9), pp.741–74. Eriřim:[<https://academic.oup.com/chemse/article-lookup/doi/10.1093/chemse/bjg066>], Eriřim Tarihi: 14.03.2017.

Muralı, S., Vladimir, K. V. 2007. Analysis of Fractal and Fast Fourier Transform Spectra of Human Electroencephalograms Induced By Odors. *International Journal of Neuroscience*, 117(10), pp.1383–1401. Eriřim:[<http://www.tandfonline.com/doi/full/10.1080/00207450600941130>]. Eriřim Tarihi: 12.03.2017.

Musson, J., Li, J. 2010. A Comparative Survey of PSD Estimation Methods for EEG Signal Analysis. In Student Capstone Conference Proceedings. pp. 1–6. Erişim: [http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=2909037&tool=pmcentrez&rendertype=abstr], Erişim Tarihi: 12.02.2017.

Namazi, H., Akrami, A., Kulish, V. V. 2016. The Analysis of the Influence of Odorant ' s Complexity on Fractal Dynamics of Human Respiration. Nature Publishing Group, Mayıs,2016, pp.1–8. Erişim[: <http://dx.doi.org/10.1038/srep26948>], Erişim Tarihi: 20.04.2017.

Nturos,K. D., Gitas, I. Z., Silleos, G. N. 2009, Mapping Agricultural Crops With Eo-L Hyperion Data. 978-1-4244- 4687-2/09/\$25.00 ©2009 IEEE

Olofsson, J.K., Broman, D.A., Wulf, M. 2005. Olfactory and chemosomatosensory function in pregnant women assessed with event-related potentials. *Physiology and Behavior*, 86(1–2), pp.252–257.

Özdarıcı, A., Akar, Ö., Güngör, O., 2011. Classification of crops in agricultural lands using random forest classification method. ODTÜ, Jeodazi ve Coğrafi Bilgi Teknolojileri.

Pinto, R.J.C., Xavier, I.P.P.P. 2014. Analysis of the human reaction to odors using electroencephalography responses. In *Lecture Notes in Engineering and Computer Science*.

Placidi, G. et al., 2015. Classification strategies for a single-trial binary Brain Computer Interface based on remembering unpleasant odors. In *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*. pp. 7019–7022.

Placidi, G., Petracca, A. 2015. Basis for the implementation of an EEG-based single-trial binary brain computer interface through the disgust produced by remembering unpleasant odors. *Neurocomputing*, 160, pp.308–318. Erişim[: <http://dx.doi.org/10.1016/j.neucom.2015.02.034>], Erişim Tarihi: 09.04.2017.

Royet, J.P., Plailly, J., Segebarth, J. 2003. fMRI of emotional responses to odors: Influence of hedonic valence and judgment, handedness, and gender. *NeuroImage*, 20(2), pp.713–728.

Sanders, C., Diego, M., Fernandez, M. 2002. Eeg Asymmetry Responses To Lavender and Rosemary Aromas in Adults and Infants. *International Journal of Neuroscience*, 7454(September).

6. KAYNAKLAR

Schriever, V.A., Schuster, B., Hummel, T. 2014. Olfactory event-related potentials in infants. *Journal of Pediatrics*, 165(2).

Sowndhararajan, K., Cho, H., Yu, B. 2015. Effect of olfactory stimulation of isomeric aroma compounds, (+)-limonene and terpinolene on human electroencephalographic activity. *European Journal of Integrative Medicine*, 7(6), pp.561–566. Eriřim[: <http://dx.doi.org/10.1016/j.eujim.2015.08.006>], Eriřim Tarihi: 11.01.2017.

Teplan, M., 2002. Fundamentals of EEG measurement. *Measurement Science Review*, 2(2), pp.1–11.

Wang, J., Eslinger, P.J., Doty, R.L. 2010. Olfactory deficit detected by fMRI in early Alzheimer's disease. *Brain Research*, 1357, pp.184–194. Eriřim[: <http://dx.doi.org/10.1016/j.brainres.2010.08.018>]. Eriřim Tarihi: 18. 04.2017.

Wetter, S., Murphy, C. 2003. A paradigm for measuring the olfactory event-related potential in the clinic. *International Journal of Psychophysiology*, 49(1), pp.57–65.

Wetter, S., Murphy, C. 1999. Individuals with Down's syndrome demonstrate abnormal olfactory event-related potentials. *Clinical Neurophysiology*, 110(9), pp.1563–1569.

Xu, H., Kroupi, E., Ebrahimi, T. 2015. Functional connectivity from EEG signals during perceiving pleasant and unpleasant odors. In 2015 International Conference on Affective Computing and Intelligent Interaction, ACII 2015. pp. 911–916.

Yavuz, E., Aydemir, Ö. 2016. Olfaction Recognition by EEG Analysis Using Wavelet Transform Features. In IEEE Transactions. pp. 1–4.

YAVUZ, E., AYDEMİR, Ö. 2016. Nilüfer Çiçeęi ve Kediotu Kokularını Koklama Anında Kaydedilmiş EEG İşaretlerinin Sınıflandırılması. *SDÜ Fen Bilimleri Enstitüsü Dergisi*, 0(0), p.10. Eriřim:[<http://dergipark.ulakbim.gov.tr/sdufenbed/article/view/5000191286>], Eriřim Tarihi: 25.02.2017.

Yentes, J.M., Hunt, N., Schemid, K.K. 2013. The appropriate use of approximate entropy and sample entropy with short data sets. *Annals of Biomedical Engineering*, 41(2), pp.349–365.

Yıldız, A. 2011. EEG ve EKG İşaretlerinden Örüntü Tanıma Uygulamaları ve Karşılaştırılması. Doktora Tezi, Fen Bilimleri Enstitüsü, Diyarbakır.



ÖZGEÇMİŞ

Kişisel Bilgiler:

Adı – Soyadı: Mesut ŞEKER

Doğum Yeri: Şanlıurfa

Doğum Tarihi: 20/08/1990

Yabancı Dil: İngilizce

İletişim Bilgileri: e mail: mesut.seker@dicle.edu.tr Tel: 0(507)9348580

Yurtdışı Tecrübeleri:

Dil Eğitimi: University of North Texas (UNT) , TX, US, Haziran – Ağustos 2011

Work & Travel: Maine, US, Haziran – Ağustos 2011

Tez Araştırması: Katalonya Teknik Üniversitesi, Barcelona, İspanya, 15 – 30 Ağustos 2015

Projeleri:

7. His: İşitme engelliler için titreşim modunda çalışan bir kol bandı. Saat ve uyandırma alarmı moduna sahip cihaz ile kapı zili, telefon çağrısı ve yangın alarmını bildirimini hem titreşim hem de ekrana yazı olarak ileten bir cihaz.

3 Boyutlu Yazıcı: CAD çıktısı çizimleri filament maddesini eriterek 3 boyutlu nesnelere üretmeye dayalı, Prusa Mendel Tabanlı baskı cihazı

Yayınları:

1. Şeker, Mesut ve Özerdem, M. S. “EEG Veri Setlerinin Hilbert Dönüşümü ile Sınıflandırılması”. 24. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 2016.

2. Türk, Ö; Şeker, M; Akpolat, V. ve Özerdem, M. S. “Mental Aktivitelere İlişkin EEG Kayıtlarının Hjort Parametreleri ile Sınıflandırılması”. 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 2017.

3. Şeker, Mesut ve Özerdem, M. S. “İyi – Kötü Koku Uyarılarının EEG Aktivitesine Etkisi”. ODTÜ Sinirbilim Günleri, 2017.



T.C.
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI İNTİHAL RAPORU FORMU

ÖĞRENCİ BİLGİLERİ

ADI VE SOYADI	Mesut ŞEKER
ÖĞRENCİ NO	14805006
EĞİTİM – ÖĞRETİM YILI	2016-2017
YARIYIL	<input type="checkbox"/> Güz <input checked="" type="checkbox"/> Bahar
ANABİLİM DALI	Elektrik Elektronik
PROGRAM	Yüksek Lisans
TEZ KONUSU	İyi-Kötü Kokular İle İlişkili EMOTIV-EPOC Tabanlı EEG Kayıtlarının Makina Öğrenmesi Yöntemleri İle Sınıflandırılması

İNTİHAL RAPORU BİLGİLERİ

RAPOR TÜRÜ	Tez Savunma Sınavı Sonrası
SAYFA SAYISI	82
BENZERLİK ORANI	%4
RAPORLAMA TARİHİ	07/07/ 2017

Yukarıda başlığı/konusu gösterilen tez çalışmamın kapak sayfası, giriş, ana bölümler, sonuç ve tartışma kısımlarından oluşan toplam 82 sayfalık kısmına ilişkin, 07/07/2017 tarihinde şahsım/tez danışmanım tarafından *Turnitin* adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı % 4 'tür.

Uygulanan filtrelemeler:

- Kabul/Onay sayfaları hariç,
- Kaynakça hariç
- Alıntılar hariç/dâhil
- Diğer


Dicle Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Programlarda Tez Çalışması İntihal Raporu Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.


(İmza)
Arş. Gör. Mesut ŞEKER


(İmza)
07/07/2017

Doç.Dr. Mehmet Siraç ÖZERDEM
Tez Danışmanı

(İmza)
07/07/2017

Prof.Dr. İbrahim KAYA Y.
Anabilim Dalı Başkanı