

Gözde ÖZKAN



İSKENDERUN TEKNİK

ÜNİVERSİTESİ

MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**YÜKSEK
LİSANS
TEZİ**

**VİDEOLARDA SAKLANMIŞ 25. KARE
ETKİSİNİN EEG SİNYALLERİ
YARDIMI İLE TESPİT EDİLMESİ**

Gözde ÖZKAN

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI**

HAZİRAN 2019

HAZİRAN 2019



**VİDEOLARA SAKLANMIŞ 25. KARE ETKİSİNİN EEG SİNYALLERİ
YARDIMI İLE TESPİT EDİLMESİ**

Gözde ÖZKAN

**YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

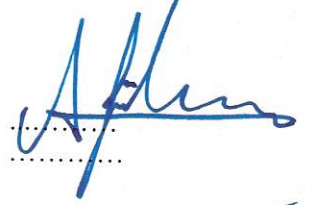
HAZİRAN 2019

Gözde ÖZKAN tarafından hazırlanan “VİDEOLARA SAKLANMIŞ 25. KARE ETKİSİNİN EEG SİNYALLERİ YARDIMI İLE TESPİT EDİLMESİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ / OY ÇOKLUĞU ile İskenderun Teknik Üniversitesi Elektrik-Elektronik Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Ahmet GÖKÇEN

Elektrik Elektronik Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

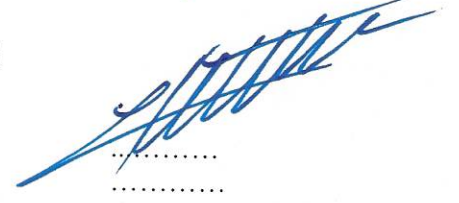
Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.



Başkan: Doç. Dr. Yakup KUTLU

Elektrik Elektronik Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.



Üye: Dr. Öğr. Üyesi Mustafa YENİAD


Bilgisayar Mühendisliği Anabilim Dalı, Ankara Yıldırım Beyazıt Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.



Tez Savunma Tarihi: 10/06/2019

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.


Prof. Dr. Tolga DEPCI
Mühendislik ve Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar karesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.



İmza
Gözde ÖZKAN

10/06/2019

VİDEOLARA SAKLANMIŞ 25. KARE ETKİSİNİN EEG SİNYALLERİ YARDIMI İLE
TESPİT EDİLMESİ
(Yüksek Lisans Tezi)

Gözde ÖZKAN

İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2019

ÖZET

Hayatımızın her yerinde karşımıza çıkan videolar, bir dizi resim dosyasının ardışık olarak dizilmesi sonucu ortaya çıkan görüntü kümesidir. Videonun her 1 saniyesinde görüntülenen resim sayısı Frame Per Second (Fps) olarak adlandırılır. 24 tane resim karesinin arka arkaya gelmesi ile videonun bir saniyesi oluşurken, bu karelerin içine gizlenen ve 25. kare efekti olarak adlandırılan resimler, videonun içinde insan gözü tarafından zor görülmektedir. Bu tezin amacı, beynin, insanların bilinçaltını etkilediği düşünülen videolardaki gizli resimleri (25. kare) algılayıp algılamayacağını belirlemektir. Bu amaçla, katılımcılara izletilmek amacıyla saf ve içerilerinde 25. kare efekti bulunan, hayvan, bitki ve doğa temalı 6 farklı video hazırlanmıştır. Bu videolar 50 adet katılımcıya izletilmiştir. Videolar izletilirken katılımcıların kafa derisi üzerine non-invaziv bir şekilde, ikisi referans olmak üzere 16 kanallı Elektroensefalogram (EEG) sinyallerini kaydeden, kablosuz başlık Emotiv EPOC+ cihazı kullanılmıştır.

Kaydı alınan EEG sinyalleri, Hızlı Fourier Dönüşümü (HFD) ve Hilbert Huang Dönüşümü (HHD) olmak üzere 2 farklı filtreleme yöntemi ile işlenmiştir. Elde edilen verilere istatistiksel öznitelik çıkarma algoritmaları (maksimum ve minimum değerlerin farkı, ortalama, medyan, standart sapma, güç, varyans, enerji, basıklık, çarpıklık, çeyrekler arası aralık) uygulanmıştır. Videoların saf hallerini izlerken oluşan sinyaller ile gizli resim eklenmiş videoları izlerken oluşan sinyalleri kıyaslamak için, K sınıflandırma yöntemlerinden biri en yakın komşu (KNN) sınıflandırıcısı ve doğrusal bir sınıflandırıcı olan Naive Bayes (NB) sınıflandırıcısı kullanılmıştır. K-parçalı çapraz doğrulama yöntemi uygulanarak eğitim sağlanmıştır. Sınıflandırma işlemi EEG sinyallerinin ham, HFD uygulanmış ve HHD uygulanmış halleri olmak üzere 3 farklı yöntem ile yapılmıştır. Elde edilen başarı oranları oldukça yüksektir.

Anahtar Kelimeler : Elektroensefalografik Sinyaller, Beyin Bilgisayar Ara yüzü, 25. Kare Efekti, Subliminal Mesajlar.

Sayfa Adedi : 56

Danışman : Dr. Öğr. Üyesi Ahmet GÖKÇEN

DETERMINATION OF THE 25th FRAME EFFECT STORED IN THE VIDEOS WITH THE
EEG SIGNALS

(M. Sc. Thesis)

Gözde ÖZKAN

ISKENDERUN TECHNICAL UNIVERSITY
ENGINEERING AND SCIENCE INSTITUTE

June 2019

ABSTRACT

The videos that come across every part of our life are a set of images resulting from sequential sequencing of a series of image files. The number of pictures displayed every 1 second of the video is called Frame Per Second (Fps). With 24 consecutive picture frame, one second of the video is formed, and the images that are hidden in these frames and called the 25th frame effect are seen difficult by the human eye in the video. The aim of this thesis is to determine whether the brain will detect hidden pictures (25th frame) in videos that are thought to affect people's subconscious. For this aim, 6 different videos with animal, plant and nature theme which each of them include 25th frame effect, and raw videos are prepared in order to be watched by participants. These videos were shown to 50 participants. While viewing the videos, wireless heading Emotiv EPOC+ device which record 16 channel Elektroansefalogram (EEG) signal, 2 of which are reference, was used with a non invasive way on the scalp of the participants.

The recorded EEG signals were processed by Fast Fourier Transform (FFT) and Hilbert Huang Transform (HHT) filtering methods. Statistical features extraction algorithms (maximum and minimum difference, mean, median, standard deviation, power, variance, energy, kurtosis, skewness, interquartile range) was applied to the obtained datas. In order to compare the signals generated while watching the raw picture of the videos and the videos that were recorded with hidden pictures, one of the K classification methods, nearest neighbor (KNN) classifier and the linear classifier Naive Bayes (NB) was used. Training was provided by applying K-part cross validation method. The classification was performed using three different methods: raw, HHT-applied and FFT-applied of EEG signals. Achievement rates which were obtained are very high.

Key Words : Electroencephalography Signals, Brain Computer Interface Systems, 25th Frame Effect, Subliminal Messages.

Page Number : 56

Supervisor : Dr. Öğr. Üyesi Ahmet GÖKÇEN

TEŐEKKÜR

Bu tez alıőmam sűresince her konuda, anlayıő ve desteęini esirgemeyen, danıőmanım Dr. Öğr. Üyesi Ahmet Göken'e, tez sűresince belirttięi görüőler ve önerilerle yardımcı olan Dr. Öğr. Üyesi Gökhan Altan'a, bu akademik yolculukta bana her konuda destek veren Do. Dr. Emin Ünal'a ve tüm hocalarıma ilgi ve yardımlarından dolayı teşekkürü bir bor bilirim. Ayrıca projenin en önemli kısmı olan sinyal alma işleme gönüllü olarak katılan İskenderun Teknik Üniversitesi öğrenci ve akademik personellerine gösterdikleri sabırdan dolayı teşekkür ederim. Sevgi ve özverileriyle bugünlere gelmemi sağlayan, hoşgörülerini ile her zaman yanımda olan sevgili annem Yeter Özkan'a, babam Ahmet Özkan'a, kardeşlerim Senem Özkan, Sadık Özkan, Süleyman Özkan'a ve tüm dostlarıma teşekkürlerimi sunarım.

İÇİNDEKİLER

	Sayfa
ÖZET.....	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER.....	vii
ÇİZELGELERİN LİSTESİ	ix
ŞEKİLLERİN LİSTESİ	x
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ	1
2. LİTERATÜR TARAMASI.....	5
3. MATERYAL VE YÖNTEMLER	14
3.1. Videoların Hazırlanması	14
3.2. Sinyallerin Alınması	15
3.2.1. Emotiv Epoc+ cihazı.....	17
4. SİNYAL İŞLEME	20
4.1. Fourier Dönüşümü	21
4.1.1. Ayırık Fourier dönüşümü	21
4.2. Hilbert Huang Dönüşümü	23
4.2.1. Ampirik kip ayrışımı	24
4.2.2. Hilbert dönüşümü.....	25
5. ÖZNİTELİK ÇIKARIMI	27
6. SINIFLANDIRMA.....	30
6.1. K-Parçalı Çapraz Doğrulama Yöntemi.....	30
6.1.1. K en yakın komşu	31

6.1.2. Naive Bayes Sınıflandırması	31
7. ARAŞTIRMA BULGULARI VE TARTIŞMA	33
7.1. EEG Sinyallerinin Ham Halleri Üzerine Uygulanan Sınıflandırma Sonuçları	33
7.2. HFD Uygulanan EEG Sinyallerine, İstatiksel Öznitelik Çıkarma Algoritmaları Uygulanarak Sınıflandırma Sonuçları	37
7.3. HHD Uygulanan EEG Sinyallerine, İstatiksel Öznitelik Çıkarma Algoritmaları Uygulanarak Sınıflandırma Sonuçları	40
8. SONUÇLAR VE ÖNERİLER	44
KAYNAKLAR	46
EKLER	53
ÖZGEÇMİŞ	54

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Kanalların konumu	18
Çizelge 5.1. Özniteliklerin formülleri	29
Çizelge 7.1. KNN sınıflandırıcısının tüm özniteliklerde performans başarısı	34
Çizelge 7.2. NB sınıflandırıcısının tüm özniteliklerde performans başarısı	34
Çizelge 7.3. KNN sınıflandırıcısını kullanan özniteliklerin başarısı	34
Çizelge 7.4. NB sınıflandırıcısını kullanan özniteliklerin başarısı	35
Çizelge 7.5. Kanalların KNN sınıflandırıcısındaki performans başarısı.....	36
Çizelge 7.6. Kanalların NB sınıflandırıcısındaki performans başarısı.....	36
Çizelge 7.7. KNN sınıflandırıcısının tüm özniteliklerde performans başarısı	37
Çizelge 7.8. NB sınıflandırıcısının tüm özniteliklerde performans başarısı	37
Çizelge 7.9. KNN sınıflandırıcısını kullanan özniteliklerin başarısı	38
Çizelge 7.10. NB sınıflandırıcısını kullanan özniteliklerin başarısı	38
Çizelge 7.11. Kanalların KNN sınıflandırıcısındaki performans başarısı.....	39
Çizelge 7.12. Kanalların NB sınıflandırıcısındaki performans başarısı.....	39
Çizelge 7.13. KNN sınıflandırıcısının tüm özniteliklerdeki başarı performansı	40
Çizelge 7.14. NB sınıflandırıcısının tüm özniteliklerdeki başarı performansı	40
Çizelge 7.15. KNN sınıflandırıcısını kullanan özniteliklerin performans başarısı	41
Çizelge 7.16. NB sınıflandırıcısını kullanan özniteliklerin performans başarısı	41
Çizelge 7.17. Kanalların KNN sınıflandırıcısındaki performans başarısı.....	42
Çizelge 7.18. Kanalların NB sınıflandırıcısındaki performans başarısı.....	43
Çizelge 8.1. KNN sınıflandırıcısı için uygulanan yöntemlerin başarı performansı.....	44
Çizelge 8.2. NB sınıflandırıcısı için uygulanan yöntemlerin başarı performansı.....	44

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Beyin yapısı.....	4
Şekil 3.1. Videonun karelere ayrılma işlemi	15
Şekil 3.2. Karelere gizli resmi ekleyip birleştirme işlemi	15
Şekil 3.3. Bir videonun 25. kare efekti içeren haline ait EEG sinyali.....	16
Şekil 3.4. Bir videonun saf haline ait EEG sinyali	16
Şekil 3.5. Emotiv EPOC+ sistemleri için EEG elektrotlarının sensör pozisyonu	17
Şekil 3.6. Elektrotların 10-20 sistemine göre organizasyonunu (Duarte, 2017)	18
Şekil 3.7. Emotiv EPOC+' ın EEG nöro-başlığı (Steemit, 2018).....	19

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Hz

Hertz

μ V

Microvolt

sn

Saniye

δ

Delta

θ

Teta

α

Alfa

β

Beta

γ

Gamma

Kısaltmalar

Açıklamalar

ADD

Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)

AFD

Ayrık Fourier Dönüşümü (Discrete Fourier Transform)

AKA

Ampirik Kip Ayrışımı (Empirical Mode Decomposition)

BBA

Beyin Bilgisayar Arayüzü (Brain Computer Interface)

EEG

Elektroensefalografi

EKG

Elektrokardiyografi

EMG

Elektromiyografi

EOG

Elektrookülografi

FD

Fourier Dönüşümü (Fourier Transform)

FPS

Frame Per Second (Saniyedeki Çerçeve Sayısı)

Kısaltmalar**Açıklamalar**

GSY	Güç Spektral Yoğunluğu(Power Spectral Density)
HD	Hilbert Dönüşümü(Hilbert Transform)
HFD	Hızlı Fourier Dönüşümü(Fast Fourier Transform)
HHD	Hilbert Huang Dönüşümü(Hilbert Huang Transform)
ICA	Bağımsız Bileşenler Analizi(Independent Component Analysis)
İMF	İçsel Mod Fonksiyonu(Intrinsic Mode Function)
KNN	K En Yakın Komşu(K-Nearest Neighbors)
LDA	Lineer Diskriminant Analizi(Linear Discriminant Analysis)
NB	Naive Bayes
SFD	Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform)

1. GİRİŞ

Bir dizi resim dosyasının ardışık olarak dizilmesi sonucu ortaya çıkan görüntü kümesine video denir. Bir videonun 1 saniyesinde görüntülenen resim sayısı frame per second (FPS) olarak adlandırılır (Baysal, Özcan ve Taşkın, 2015). İnsan gözünü yormayacak bir video yapılmak istenirse, videonun 1 saniyesinde en az 24 karenin kullanılması bir standart haline gelmiştir. Film şeritlerinde genellikle 24 kareden sonra ‘control-track’ denilen bir aralık bırakılır. Eğer bu aralık bir resim karesi ile doldurulursa 25. kare efekti denilen durum ortaya çıkmaktadır. Bir izleyici, bir saniyelik bir videonun 24 karesini birbirine benzeterek beyinde akıcı ve doğal bir görüntü oluşturabilirken; 25. kareyi bilinç düzeyinde algılayamayıp, bilinçaltında işlemektedir. Literatürde 25. kare efekti olarak adlandırılan bu durum genellikle reklam firmaları tarafından izleyiciyi subliminal mesaj verme yoluyla etkilemek amacıyla kullanılır (Küçükbezirci, 2013).

Ülkemizde televizyon yayımlarının kontrolünü sağlayan Radyo Televizyon Üst Kurulu (RTÜK), bu türde bilinçaltı reklamlarını; “Teknik cihazlar vasıtasıyla televizyon yayımlarında çok kısa süreli görüntüler kullanarak, izleyicilerin yalnızca bilinçaltıyla algılayabilecekleri ürün veya hizmetlerin tanıtılmasına ilişkin mesajlar içeren reklamlar” olarak tanımlamıştır. 3984 sayılı yasanın 20. maddesi ile bilinçaltı ile algılanan reklamlara izin verilmemesi gerektiği hükme bağlanmıştır. Bununla birlikte Radyo ve Televizyon Kuruluşları Reklam Yayın İlkeleri ve Usulleri İle Reklam Gelirleri Üst Kurul Paylarının Ödenmesi Hakkında Yönetmeliğin 11. Maddesinde çok kısa sürelerle imaj veren, fark edilemeyecek gizli reklamların kullanımının yasak olduğu belirtilmiştir (Baysal ve diğerleri, 2015).

İletim yolunda iken çeşitli modifikasyonlara uğrayan mesajlar, kişinin eylem mekanizmalarına sahip olmayan bir ortama girdiğinde bilinçaltı bölgesi, artık kontrol edilemez (Florea, 2016). Bilinç, insanda farkındalığın hüküm sürdüğü, algının açık olduğu, duyguların hissedildiği an olarak kabul edilen yetidir. Bilinçaltı ise, görülen bilinç durumlarının daha derininde, bilinç durumunda yapılan hareketlerden, düşüncelerden ve davranışlardan oluşan başka bir yapıdır. Bilinç durumunda yapılan hareketler bu yapıya bağlıdır. Avusturyalı nörolog Sigmund Freud’a göre “Bilinçli hayatlarımız buzdağının sadece görünen ucudur. Dolayısıyla insan, kendisini neyin motive ettiğini aslında tam anlamıyla asla bilemez”.

Reklam, insanların ihtiyalarını fark etmelerini saėlamak iin ideal bir imge yaratıp, rn ya da hizmetin tketimini arttırmak zere oluřturulan mesajdır. Ama, mesajın tketicinin dikkatini ekmesi, etkilemesi ve geniř kitlelere ulařmasıdır. Bilinaltı reklamcılık ise bu mesajı tketicide fark ettirmeden gerekleřtirmeyi hedeflemektedir. Algılaması g olan ve ancak dikkatli bakıldıėında/izlendiėinde fark edilen bu mesajların, tketiciler/izleyiciler tarafından algılanması kesin sonularla belirtilmemekle birlikte, bu mesajların reklam mesajının btnsel yapısı ierisinde nemli bir yeri olduėu gz ardı edilemez (Muter, 2002).

Farkında olmadan bilinaltında depolanan veriler, insanın ruh halini, psikolojisini, kararlarını, hedeflerini etkilemektedir. 1957 yılında Vance Packard'ın, Hidden Persuaders adlı gizli ikna yollarını ele aldıėı kitabında umut, korku, sululuk ve cinsellik zerine odaklanmış reklamlar kullanıldıėında insanların ihtiya duymadıkları rnleri dahi satın almaya ikna oldukları iddiasında bulunulmuřtur. Reklam uzmanı olan James Vicary, 1957 yılında yaptıėı sinema deneyinde bir saniyenin 1/3000 gibi kısa bir srede aılıp kapanan objektif kapaėı sayesinde mesajlar ve grntler yansıtan bir film projektr kullanarak, izleyicilere patlamıř mısır ve kola ierikli yazılar izletip, satıřların atıřı hakkında bir gzlemde bulunmuřtur. 2005 yılında Hollanda'da yapılan Johan C. Karremans'ın Lipton Ice Deneyi'ne gre; izletilen videoda 23 ms sre ile Lipton Ice subliminal mesajı verilen susamıř gnlllerin aynı oranda popler iki markadan %85 oranında Lipton Ice markasını tercih ettiėi ortaya ıkmıřtır (Karremans, Stroebe ve Claus, 2006). Bilinaltı mesajlarının temelini oluřturan bu deneyler ve arařtırmalar bizlere gsteriyor ki, řirketler avantaj saėlamak iin subliminal reklamcılık tekniklerinden faydalanmakta ve video grntlerine kare eklemeye dayanan 25. kare tekniėi de, kullanılan tekniklerin bařında gelmektedir.

Bu tez alıřmasının amacı, insanların bilinaltını etkilediėi dřnlen videolardaki gizli resimlerin, beynin algılayıp/algılamadıėını tespit edilmesini saėlamaktır. Beynin sinirsel aktivitesi sonucu elde edilen biyoelektrik tabanlı iřaretler olan Elektroensefalografi (EEG) sinyallerini len, Emotiv EPOC+ adlı cihaz yardımı ile video izleyen katılımcılardan kayıtlar alınmıřtır. Birbirinden farklı bitki, hayvan ve doėa temalı 6 farklı video hazırlanmıřtır. Bu videoların saf ve 25. kare efekti bulunduran halleri 50 adet katılımcıya izletilerek kayıtlar alınmıřtır. Katılımcılardan veya evresel etkilerden dolayı oluřan hareketlerin neden olduėu dalgalanmalar ve gereksiz grltlerin temizlenmesi iin EEG sinyalleri, HFD ve HHD ile iřlenmiřtir. Her bir filtreleme ynteminden ıkan sonular ayrı ayrı maksimum ve minimum deėerlerin farkı, ortalama, medyan, standart sapma, g, g,

varyans, enerji, basıklık, çarpıklık, çeyrekler arası aralık gibi istatistiksel öznitelik çıkarma algoritmalarına tabi tutulmuştur. Videonun saf hali izlenirken oluşan sonuçlar ile 25. kare efekti bulunan videolar izlenirken elde edilen sonuçları karşılaştırmak amacı ile KNN ve NB sınıflandırıcıları uygulanmış ve performans başarıları analiz edilmiştir.


Bu tez sayesinde bireyin farkında olmadan beyninin istem dışı algıladığı bir durumun tespiti yapılmıştır. Bu tespit sayesinde ilgili durumun kişinin aleyhinde kullanımının engellenmesi sağlanabileceği gibi; bu durum kişinin lehine çevrilerek başarılı odaklanma vb. konularda psikolojik olarak rahatlama sağlanması amacıyla da kullanılabilir. Bu proje, bilim, teknoloji, eğitim ve hatta tıp alanına hem yeni bir bakış açısı hem de literatüre yeni bir veri tabanı sağlamıştır.

Beyin yüzeyinden elektrotlarla algılanabilen, düşük genlikli biyoelektrik işaretler olan EEG işaretleri; klinik tanılarda, nörolojik ve patolojik rahatsızlıkların çözümünde kullanılmaktadır. İnsan beyni, kişinin hem uyanık hem de uyku halinde, içinde bulunduğu duygu durumlarına bağlı olarak çok çeşitli frekans ve genlikte işaretler üretir. Bundan dolayıdır ki insanın 5 duyu organı, uyurken ya da uyanırken aktif bir şekilde veri toplamaktadır. EEG ise beyin dalgaları aktivitesinin elektriksel yöntemlerle incelenmesi ve yorumlanmasıdır. İnsan beyninden elde edilen bu işaretlerde çok miktarda bilgi saklandığı bilinmesine karşın beyin kompleks yapısı itibarı ile elde edilen EEG işaretlerinin düşük genlikli olması bu bilgilere ulaşılmasını zorlaştırmaktadır (Güler, Kıymık, Akin ve Alkan, 2001). EEG potansiyelleri invaziv olmayan bir şekilde, kafatasının altındaki serebral korteksin oldukça geniş bir bölgesinden gelen potansiyellerin toplamından oluşur. EEG işaretlerinin genliği 1 μ V-100 μ V, frekans bandı ise 0,5 Hz -100 Hz arasında değişir (Fidan ve Özkan, 2018).

Elektroensefalografinin tarihçesine bakıldığında, nörolog ve psikiyatrist olan Hans Berger, 1924 yıllarında beyinde lokalizasyon çalışmaları yapmış ve I. Dünya Savaşı'nda kafatası yaralanması olan insanlar üzerinde beyne yerleştirdiği elektrotlarla ilk elektroserebrogram kaydını gerçekleştirmiştir. Daha sonraki yıllarda elektroensefalogram kaydının yapılabileceğini, saçlı deriye yerleştirdiği elektrotlar ile de göstermiştir (Alkaç, 2009). İnsanda EEG çalışmalarının başlamasında en önemli role sahip olan Berger, çalışmalarını uyku EEG'si ve epileptik deşarjlar üzerine yoğunlaştırmış olsa da, dönemin siyasi yönetiminin araştırmalarını kendileri için gerçekleştirme isteklerinin oluşturduğu baskının

etkisi ile girdiği yoğun depresyon sonucunda, intihar etmiştir. 1940 yılından sonra birçok araştırmacı tarafından özel elektrotlar yardımıyla derin beyin bölgelerinden kayıt alınabilmiş ve frekans analizi yapılmaya başlanmıştır (Brazier, 1961).

Beyin, farklı roller oynayan alt bölgeler ve alanlara ayrılmıştır. İnsan vücudu faaliyetlerinin kontrolünde, bu alt alanların her biri çeşitli görevleri yapmaktan sorumludur. Sinyal alma ve işleme aşamasında bu lobların hangi duyguları temsil ettiğini bilmek daha verimli işlem yapmayı sağlamaktadır. Şekil 1.1’de beyin yapısı tasvir edilmiştir.



Şekil 1.1. Beyin yapısı (Duarte, 2017)

Her yarım kürenin üstünde, korteks denilen kalın bir gri madde tabakası vardır. Araştırmacılar beyni lob olarak adlandırılan dört bölgeye ayırırlar. Bunlar arka kafa (okspital), ön kafa (frontal), yan kafa (parietal) ve şakak (temporal) loblarıdır. Arka kafa lobu beynin arka ortasında yer alıp görsel algıdan, ön lob kafanın ön bölgesinde olup yaratıcılık, karar verme, problem çözme ve planlamadan, yan kafa lobu üst arka bölgede olup yüksek algılama ile dil işlevlerinden, şakak lobu kulakların çevresinde olup, duyma, hafıza, anlama ve dilden sorumludur (Avcı ve Yağbasan, 2008). Ayrıca lobların fonksiyonlarında bazı benzerlikler de bulunmaktadır.

Beyin Bilgisayar Arayüzü (BBA) sistemleri beyin ve makinalar arasında iletişim kuran yapılarıdır. Beyin korteksi, işlevlerin ve nörolojik yanıtların önemli bir bölümünü içerdiği için BBA büyük önem taşır. Beyne yapılacak olan invaziv işlemler ve cerrahi müdahaleler karmaşık ve riskli olduğundan cerrahi müdahale olmaksızın yapılan kafa derisi üzerine yerleştirilmiş sensörler tarafından ölçüm yapan EEG en ideal yaklaşımdır (Duarte, 2017).

2. LİTERATÜR TARAMASI

Günümüzde, EEG sinyallerinin analiz edilip bir makinaya ya da yapay zekâya öğretilmesi hakkında yapılan çalışmalar ivme kazanmıştır. Felçli, konuşma yetisini kaybetmiş, uzuvlarını yitirmiş veya beyinin motor fonksiyon bozukluğu yaşayan birçok hastanın EEG sinyallerini kullanarak hayatlarını kolaylaştırmak mümkün hale gelmiştir. Dünya Sağlık Örgütü'ne göre yaklaşık 500 bin insan her yıl omurilik yaralanmaları yaşamaktadır. Omurilik yaralanması, motor fonksiyon bozukluğunu etkilemektedir. BBA sistemleri, alternatif bir yol izleyerek bu hastaların yaşam kalitesini iyileştirmeyi ve nöral sinyalleri işleyerek beyin ile motor sistemi arasında bir bağ kurmayı amaçlar.

Yapılan bir çalışmada tipik invaziv olmayan BBA sistemlerinde, sinirsel aktiviteyi ölçmek için kullanıcının kafa derisine EEG cihazı yerleştirilmiştir. Elde edilen sinyal önceden tanımlanmış EEG modellerini tanımlamak için dijital olarak işlenmeden önce, gürültü bileşenlerini gidermek için filtrelenmiş, daha sonra tespit edilen sinyaller sınıflandırma için hazırlanmıştır. Hastalık veya yaralanmanın sonucu olarak motor fonksiyon bozukluğu olan engellilere yardımcı olmak amacıyla insan düşünce süreçlerini bulmak ve bir bilgisayar arasındaki iletişimi sağlamak için çalışmalar geliştirilmiştir (Ge ve diğerleri, 2017).

Aynı zamanda BBA sistemi, insanların motor sinir sistemlerini kullanmaksızın bir bilgisayarı, elektromekanik bir kolu ya da çeşitli nöroprotezleri kullanmalarını olanaklı hale getiren sistemlerdir. BBA, insan beyni ile bilgisayar arasında kurulan iletişime ışık tutmayı amaçlar. Yapılan bir çalışmada, EEG verilerinden sağ ve sol el hareketlerinin düşüncesini tespit edebilecek, taşınabilir bir EEG başlığı ve Destek Vektör Makinaları (DVM) kullanılarak, bir BBA sistemi tasarlanmıştır. Uygulanan BBA, tek olay bazında çalışarak yaklaşık olarak %80 doğrulukla, sağ/sol hareket düşüncesinin ayrılmasını sağlamıştır (Mishchenko, Murat ve Cömert, 2017).

Nitekim diğer bir çalışmada tekerlekli sandalyeye mahkûm insanların yaşamını kolaylaştırmak için EEG sinyalleri ile kontrol edilebilen tekerlekli sandalye geliştirilmiştir. Çalışmada, tekerlekli sandalye için sağa dönüş, ileri hareket, durma gibi çeşitli sinyaller üretmek için çok sayıda deneysel veri işlenmiştir (Samy, Rahman ve Khan, 2016). Yine benzer bir çalışmada gerçek zamanlı olarak sevinç, öfke, üzüntü ve zevk gibi duygulara

dayalı bir akülü tekerlekli sandalyeyi kontrol etmek için Fraktal Analiz Yöntemi ile BBA devresi geliştirilmiştir. Bu devreyi kullanarak, akülü bir tekerlekli sandalyenin hızı, duyguların yoğunluğu ile ayarlanabilmektedir (Kobayashi ve Nakagawa, 2015).

Günümüzde inme hastalığı araştırılırken, duyu tanımaya yönelik sol beyin hasarının ve sağ beyin hasarının etkisine odaklanarak çalışmalar yapılmıştır. Tekrarlayan inme atağını önlemek için hastanın duygusal durumunu tahmin etme imkânını görmek bir avantajdır. Yapılan bir çalışmada sol ve sağ beyin hasarı olan ve olmayan katılımcılardan EEG sinyalleri alınmıştır. Veri toplama sırasında, sesli görsel uyaranlar kullanılarak altı duyu (üzgün, tiksinti, korku, öfke, mutlu ve şaşkınlık) tetiklenmiştir. Sonuç olarak sağ beyin hasarı olan hastalıkların duyu tanımada daha fazla bozukluğa sahip olduğu bulunmuştur (Bong ve diğerleri, 2017).

BBA teknolojisi motor nöronlarının özelliğini kaybeden ve hareket kabiliyeti kısıtlanmış ALS ve felçli hastalar gibi birçok kişinin dış dünya ile iletişimini sağlamaya yönelik avantajlar sağlar. Yapılan çalışmanın, veri setinde sağ el ya da sol elin hareket ettirilme hayali esnasında 8 kişiden, 60 sağ ve 60 sol olmak üzere toplamda 120 adet yaklaşık 9 saniyelik motor hayal etme sinyali kayıt edilmiştir. Çalışmada, Lineer Diskriminant Analizi (LDA), KNN ve DVM ile sınıflandırma yapılmış, en iyi sınıflandırma performansının LDA sınıflandırma yöntemiyle elde edildiği gösterilmiştir (Altındış ve Yılmaz, 2016).

Çağımızın en yaygın zihinsel hastalıklardan biri olan ve duyu işleme sürecindeki değişikliklerle ilişkilendirilen depresyonun, kişilerdeki etkisi bir çalışmada incelenerek, EEG salınım dinamikleri üzerinde depresif belirtilerin etkisi incelenmiştir. Deney sırasında, kişilere sunulan öfkeli, tarafsız veya mutlu yüzlerin cinsiyetini kategorize etmeleri istenerek, o esnada EEG sinyalleri kaydedilmiştir. Spektral bozulmaların analizi ve dipollerin analizi EEGLAB araç kutusu kullanılarak EEG kayıtları üzerinde gerçekleştirilmiştir. Sonuçta, yüksek ve düşük depresyon grupları, cinsiyetin sınıflandırılması sırasında tepki süresi açısından farklılık göstermemiştir. Mutlu yüzler algısında yüksek depresyon, düşük depresyon grubundan daha yüksek teta senkronizasyonu oluşturmuştur (Bocharov, Knyazev ve Savostyanov, 2017).

EEG sinyalleri sinir sistemi rahatsızlıkları hakkında birçok bilinmeyeni açığa kavuşturabilme gücüne sahiptir. Sara olarak da bilinen epilepsi hastalığı, beyin içinde

bulunan sinir hücrelerinin olağan dışı bir elektrokimyasal boşalma yapması sonucu ortaya çıkan nörolojik bir rahatsızlıktır. EEG sinyallerinden epilepsi tespiti, hastalığın tedavi ve nöbetlerin önceden tahmin edilmesi açısından çok önemlidir. EEG sinyallerinde bulunan dik darbeler ancak uzman kişiler tarafından yorumlanabilir. Yapılan bir çalışmada sinyallerin, yoğunlaştığı frekans bantları karşılaştırılarak epilepsi hastalığının teşhisinin kolaylaştırılması amaçlanmıştır. EEG sinyallerinin frekans spektrumlarını elde edebilmek için HFD yöntemi, sinyaldeki zaman-frekans analizini ve geçici durumları çıkarmak için Sürekli Dalgacık Dönüşümü (SDD) kullanılmıştır. Sinyaller incelendiğinde delta, teta, alfa ve beta dalgalarına ait frekans bileşenlerinin tümü görülmesine rağmen epileptik sinyallerde yüksek genlikli frekans bileşenlerinin 0-10 Hz arasında yoğun olduğu görülmektedir (Gur, Kaya ve Turk, 2014). Yapılan benzer bir çalışmada epilepsi hastası olan ve olmayan kişilerden alınan biyoelektriksel kökenli işaretler yorumlanarak, EEG verilerinin ROC eğrileri ve hata matrisleri kullanılarak sınıflandırmanın başarısı tespit edilmiştir. Bu çalışmadaki amaç, normal ve epilepsi hastalarına ait verileri eğitim için kullanıp, yeni veri girişi durumunda sınıflandırma yapabildiğini sağlamaktır. Sonuç olarak doğru sınıflandırma yüzdesi % 96,1, yanlış sınıflandırma yüzdesi %3,9 olarak bulunmuştur (Kaya ve Mustafa, 2017).

BBA, aynı zamanda beyin ve bilgisayar arasındaki, beyin dalgası kontrollü bilgisayar oyunları için bulunan alternatif bir iletişim ve kontrol kanalıdır. Giriş sinyallerinin görsel ve işitsel biçimlerinin etkilerini karşılaştıran bir çalışma yapılmış ve kişinin hafıza ve dikkat düzeyini arttırmak amaçlanmıştır. Önerilen oyun, oyuncunun bir dizi nesneyi ezberlemesini ve daha sonra bunları farklı uyaranlar için ayrı ayrı, doğru bir şekilde seçmesi şeklindedir. Ayrıca oyuncunun dikkat tabanlı beyin sinyallerini kullanarak oyunu kontrol etmesi istenmiştir. Çalışma bir kişinin dikkatini ve hafızasını güçlendirmede ses uyaranlarının etkinliğini göstermeyi amaçlamıştır. Çalışma sonucunda kısa süreli sesli uyaranın kısa süreli görsel uyarandan daha iyi dikkat seviyesini geliştirdiği ortaya koyulmuştur (Chouhan, Panse, Smitha ve Vinod, 2015).

Bireylerin ruhsal ve bedensel sağlığı için meditasyon işleminin büyük bir önemi vardır. Bir çalışmada meditasyon eğitiminin BBA kullanıcılarının performansını iyileştirip iyileştiremeyeceğini araştırılmıştır. 12 haftalık çalışma ile 76 sağlıklı katılımcı, meditasyon grubu, müzik grubu ve kontrol grubu olmak üzere, rastgele 3 gruba ayrılmış, beynin motor fonksiyonları kullanılarak BBA sistemleri kontrol yetenekleri üzerinden dikkat ve

meditasyonun etkisi araştırmıştır. LDA sınıflandırıcısı oluşturularak, meditasyon eğitimi “nöral gürültüyü” azaltmaya yardımcı olabilir, sinyal-gürültü oranlarını artırabilir ve böylece BBA’lerin kullanımında daha hızlı öğrenmeyi kolaylaştırabilir kanısı ortaya çıkmıştır. Çalışmada müzik ve meditasyon durumunun birlikte beyin performansını geliştirdiği gözlenmiştir (Tan, Dienes, Jansari ve Goh, 2014).

Uzun yolda araç kullanırken veya benzer olası durumlarda oluşacak tehlikeler için bir avantaj sağlayan diğer bir çalışma ise BBA kullanıcılarının göz hareketlerini kaydetmesi üzerinedir. Gözün açık/kapalı halini izleyebilmesi için yerleştirilen bir kamera ile katılımcının EEG sinyalinden uyusukluğun tespit edilmesi amaçlanmıştır (Hasan, Ullah, Gupta ve Ahmad, 2016). Benzer bir çalışmada ise beynin sol frontal bölgesi EEG ile kayıt altına alınarak, gerçek zamanlı sürücü hataları üzerine araştırmalar yapılmış ve dikkat, rahatlama, yorulma ve uyku durumları ölçülmüştür. Ölçümler boyunca dikkat durumu için; kitap okuma ve problem çözme, rahatlama durumu için; yürüyüş, yorgunluk durumu için; öğle yemeği sonrası ve uyku durumu için; ise uykuya dalmadan önceki hali göz önünde bulundurulmuştur. 4 katılımcıdan alınan veriler KNN yakın komşuluk algoritması ile sınıflandırmış ve alınan ölçümlere dayanarak bir mobil uygulama geliştirilmiştir. Bu mobil uygulama sürücülerin yorgunluk durumlarındaki dikkat ve meditasyon seviyelerine göre kişinin GPS bilgilerini istenilen kişilerle paylaşmayı sağlayarak trafikte sürücü yorgunluğundan meydana gelen kazaların oranını azaltmak hedeflenmiştir (He, Liu, Wan, ve Hu, 2014).

İnsanlar iletişim halinde olduğu kişilerin duygularını anlamaktaki yeteneklerini makinalara öğretme çabaları 90’lı yılların ortasında başlamıştır. Yapılan bir çalışmada, EEG sinyalleri ve yüz ifadeleri kullanılarak farklı uyaran tipleri için duygu analizi ve sınıflandırma işlemi yapılmıştır. Farklı uyaran tipleri için beyin bölgeleri arasında oluşan etkileşim alfa, beta ve gama bantlarında faz kilitleme değeri kullanılarak incelenmiştir (Daşdemir ve Yıldırım, 2017). Duygular kelime ile sözlü olarak ifade edilebileceği gibi sözsüz ipuçları ile tonlama, ses, yüz ifadeleri, jest, mimik gibi hareketler ile de ifade edilir. Başka bir çalışmada katılımcılara müzik klipleri izletilerek videoyu beğenme / beğenmeme ve aşinalık düzeyleri derecelendirilmiş ve kullanıcının bedensel tepkileri duygulara çevrilmiştir. EEG sinyal frekansları ile katılımcıların derecelendirmeleri arasındaki korelasyonlar araştırılarak, uyarılma sınıflandırması için EEG’nin modalitörleri kullanılarak beğenme / beğenmeme durumları, multimedya içerik analizi yöntemleri ile incelenmiştir. Çalışma sonucunda;

katılımcıların deney sırasında verilen puanları analiz edilerek EEG frekansları ile katılımcı derecelendirmeleri arasında anlamlı korelasyon bulunmuştur (Koelstra ve diğerleri, 2012). Benzer bir çalışmada EEG işaretleri, görsel ve işitsel uyaranlar ile farklı duygu durumlarına ilişkin sınıflandırılmıştır. Katılımcılar, sunulan bu uyaranlara karşı beğenme/beğenmeme durumu açısından değerlendirme yapmışlardır. EEG işaretlerinden ADD kullanılarak öznitelik çıkarımı yapılmış, sınıflandırıcı olarak ise Yapay Sinir Ağları uygulanmıştır. Sınıflandırmada maksimum sınıflandırma doğruluğu %90 ve 20 katılımcı için ortalama sınıflandırma doğruluğu ise %76,25 olarak elde edilmiştir (Özerdem ve Polat, 2016a). Bu çalışmalara çok yakın bir yol izleyen başka bir çalışmada ise, katılımcılara hoş olmayan sesler dinletilip, EEG kayıtları alınmış ve sonuçta spontan mimik hareketlerinin arttığı gözlemlenmiştir. Spontan mimik hareketlerinden sonra, spektral teta ve beta gücünde önemli bir artış gözlenerek, spontan mimik hareketlerinin çalışma hafızası ve duygular alanındaki kortikal düzenleme işlemleriyle ilişkili olduğu savunulmuştur (Grunwald, Mueller, Rall ve Weiss, 2014). EEG sinyallerinden duygu tanıma amaçlı yapılan bir diğer çalışmada, EEG sinyallerinden duygu tanıma fraktal boyut değerleri ile dalgacık dönüşümünden elde edilen öznitelikler birleştirilerek yapılmıştır. KNN sınıflandırması yapılmış ve sonunda elde edilen duyarlılık-özgünlük değerleri, değerlik, uyarılma ve baskınlık için sırasıyla 0,684-0,656, 0,647-0,553 ve 0,602-0,555 olarak hesaplanmıştır (Atasoy, Kutlu, Yıldırım ve Yıldırım, 2014). Duygusal tabanlı bir paradigmada yer alan uyaranlara olan aşinalığın, EEG işaretleri üzerine olan etkilerini inceleyen bir çalışmada, katılımcılar kendilerine sunulan müzik videoları sonundaki duygu durumlarını ve müziğe olan aşinalıklarını sayısal olarak derecelendirmişlerdir. EEG işaretinin ADD yöntemi ile filtrelenmiş ve elde edilen bulgularda, farklı duyguları içeren hikâyelerin EEG üzerinde farklı yansımaların oluşuma neden olduğu görülmüştür. Çalışmanın hipotezi, sağlıklı bay ve bayanlarda genel olarak benzer yansımaların olabileceği, hasta (Alzheimer, bipolar, vb) kişilerde ise bu yansımaların farklı seviyelerde olabileceğidir (Özerdem ve Polat, 2016b).

Beyinde, konuşmayı anlama sırasında, milisaniyelik bir hızla gerçekleşen ses kimliğinin tanınması evresi üzerine yapılan bir çalışmada, sözcüklerin anlam değerinin işlenmesinin, konuşmacı kimliğiyle nasıl modüle edildiği araştırılmıştır. Katılımcıların EEG verileri kaydedilirken, önceden kaydedilmiş ses içinden kendi sesleri ve kendine ait olmayan sesler dinletilip, anlamsal değerlik çıkarılması istenmiştir. Sonuçta duygu ve konuşmacı kimliğinin, konuşmanın ve konuşmacı bilgilerinin gözlemlerine paralel olarak konuşma işlemi sırasında etkileşime girdiği ortaya koyulmuştur (Pinheiro ve diğerleri, 2016).

Sayısal ve sözel işlemler yapılırken beynin farklı kısımlarının çalıştığı bilinmektedir. Yapılan bir çalışmada sayısal ve sözel işlemler sırasında beyinde oluşan bu elektriksel sinyallerin sınıflandırmasında öznitelik seçimlerinin önemi araştırılmış, 18 katılımcıya, okuma parçaları ve dört işlemde oluşan aritmetik işlemler içeren 60 slayt gösterilmiştir. EEG işaretleri sessiz okuma ve kalem kâğıt kullanmaksızın akıldan çözülen aritmetik işlemler esnasında kaydedilmiştir. Kayıt edilen EEG sinyalleri HHD ile analiz edilerek özniteliklerine ayrılmış, Bayes Net algoritması ile sınıflandırılmıştır (Eraldemir, Arslan ve Yıldırım, 2017). Bu çalışmaya benzer nitelikte geliştirilen matematiksel işlemlerden toplama-çıkartma ve çarpma-bölme gruplarının birbirinden ayırt edilmesi hedeflenmiştir. Sinyal analizinde Fourier dönüşümü (FD) ve ADD yöntemleri kullanılırken, sınıflandırıcıda KNN kullanılmıştır. Ortalama doğru pozitif sonuçları 1,3,5 ve 10 en yakın komşuluk değerlerine göre sırası ile %79,3, %74,9, %72,4 ve %68,6 olarak elde edilmiştir (Eraldemir, Yıldırım ve Kutlu, 2014).

Son zamanlarda pazarlama dünyasında giderek daha sık duymaya başladığımız bir kavram olan nöropazarlama; nörolojik araştırmalarda elde edilen verilerin pazarlama disiplinine aktarılması anlamına gelmektedir. Nörobilim ve Pazarlama Bilimlerinin etkileşiminden doğan nöropazarlama, beyin görüntüleme araçları ile uzmanlık gerektiren istatistiksel analizler sonucunda elde edilen verilerin, pazarlama ve nörobilim uzmanlarıyla birlikte yorumlandığı bir araştırma alanı olarak literatürde yerini almıştır. Nöropazarlamada tüketicilerin satın alma kararını nasıl verdikleri ve hangi pazarlama araçlarından etkilendikleri anlamaya çalışılmaktadır.

EEG'den alınan, beyin sinyallerindeki değişiklik, delta, teta, alfa, beta ve gama ana bantları üzerinde oluşmakta ve bu bant aralıkları gözlemlenerek tüketicilerin bilişsel veya duygusal tepki süreci ortaya çıkmaktadır. Örneğin alfa dalgasındaki azalış sol frontal lobda aktivasyon artışını ima etmekte ve katılımcını hoşlandığı anlamına gelmektedir. EEG'nin birçok beyin görüntüleme tekniklerine göre daha az maliyetli olması ve kolay uygulanabilir olması nöropazarlama araştırmalarında da EEG cihazını daha sık kullanılabilir hale getirmiştir (Coşkun ve Yücel 2018; Tüzel, 2010).

Video reklamlarının kalitesi ve tüketicilere ilettikleri ürün bilgileri, reklam ajansları ve ürün reklam verenleri arasında tartışılan bir konu halindedir. Yapılan bir çalışmada, reklam anlatımının ve marka seçiminin beyne olan etkisini ortaya çıkarmak için video reklamları

izlerken EEG deneyleri gerçekleştirilmiştir. EEG spektral dinamikleri sol frontal ve oksipital bölgede daha yüksek teta gücü gösterdiği gözlemlenmiştir. EEG sonuçları, reklamın anlatı yapısının varlığının, bilişsel bütünleşmeden sorumlu bölgelerde beyin aktivitesinde farklılıklar oluşturduğunu göstermektedir. Çalışmada, anlatı yapısının varlığı/yokluğu, deneyde bağımsız değişken olarak seçilmiş ve dinleyicinin anlayış düzeyindeki farklılıkları araştırmak için kullanılmıştır. 15 katılımcı, içerisinde İngilizce, Fransızca, İtalyanca ve İspanyolca dillerinde diyaloglar ile anlatı yapısı ve marka içeren reklam videoları izlemişlerdir. Anlatıya dayalı video reklamları, sol frontal bölgede önemli bir teta gücü üretmiştir. Sol frontal bölgedeki teta gücünün hoş video reklamlarıyla ilişkili olduğunu ve aynı zamanda duygusal katılımı ilişkili olduğu kanısına varılmıştır. Oksipital bölgeden elde edilen sonuçlar, anlatısal olarak yapılandırılmış video reklamları sırasında üretilen hem teta hem de beta salınımlarının güçlerinin, anlatı dışı yapılandırılmış reklamlarda üretilenlerden daha yüksek olduğu sonucuna varılmıştır. HFD kullanılarak işlenen veriler yardımı ile sonuç olarak anlatıya göre yapılandırılmış video reklamlarının, tercih kararına ve bilişsel entegrasyona bağlı olarak yüksek düzeyde beyin aktivitesi üretebileceği savunulmaktadır (Wang, Chang ve Chuang, 2016).

Benzer bir çalışmada video reklamları değerlendirmek için katılımcılar 8 dakika boyunca uzay boşluğu hakkında tarafsız bir belgesel gözleminde bulunmuşlardır. Belgeselin ortasına, her biri için 30 saniyelik, Nick, CK ve Apple olmak üzere 3 standart uluslararası markadan oluşan 6 video reklamı yerleştirilmiştir. EEG verilerini, 16 kanallı bir sistemle kayıt alan çalışmaya ek olarak EKG verilerini kaydetmek için sol bilekte nabız pozisyonuna yerleştirilen EKG elektrotu da mevcuttur. EEG sinyalleri kaydolduktan hemen sonra katılımcılar ile bir röportaj yapıp hangi reklamları hatırlayabildikleri sorulmuştur. Daha sonra, hatırladıkları reklamlardaki ayrıntıların açıklanması istenmiştir. Teta bandındaki EEG salınımlarının, bellek performansına yansıdığı kanıtlanmıştır. Teta bandındaki güç senkronizasyonun ve alfa bandında güç dengesizliğinin, epizodik hafıza ve dikkatle ilişkili olduğu savunulmuştur. EEG sinyali ICA ile filtrelenmiştir ve her kanal için Güç Spektral Yoğunluğu(GSY) hesaplanmıştır. Sonuç olarak video reklamlardaki sahnenin EEG sinyalleri tarafından etkileyici olup olmadığını yorumlamak için bir araç olduğu düşünülmüştür (Kong, Zhao, Hu, Vecchiato ve Babiloni, 2013).

Başka çalışmada kullanıcı davranışını etkilemede ürün tasarımlarının önemini belirtmek için, Hyundai firması adına EEG prototipleri test edilmiştir. Beynin, farklı tasarım

özelliklerine verdiği tepkiler ölçülüp, hangi uyarıcının satın almaya daha çok neden olacağı araştırılmıştır. Bu araştırma, Hyundai marka arabaların dış tasarımının değişmesine neden olmuştur (Taş ve Şeker, 2017).

Reklamların beyinde nasıl algılandığını inceleyen bir diğer çalışmada özel şirketlerin nöropazarlamada yaptığı çalışmalar incelenmiştir. Deneyin paradigmasında 30 saniyelik 5 bloktan oluşan 6 farklı TV reklamı mevcuttur. Her bir video arasında 6 saniyelik siyah bir haç görüntüsü konulmuştur. EEG ile alınan kayıtlardan sonra katılımcıdan televizyon reklamlarında gördükleri markalardan hoşlanıp hoşlanmadıkları hakkında (1 - nefret, 2 - beğenmedim, 3 - kayıtsız, 4 - beğen, 5 – sevmek) bir anket yapılmıştır. Alınan sinyaller ICA ile filtrelenmiştir ve teta dalgalarının duygular ve limbik bölgelerle ilişkili olduğu düşünülmüştür. Beta dalgalarının, uyanıklık, odaklanma durumlarında dikkat çekici videolarda ortaya çıktığı gözlemlenmiştir. Ankette daha iyi puan alan reklamın, daha kötü puanlar alan reklamdaki daha fazla duygusal sinir devrelerine sahip olduğu ve EEG'nin reklam araştırmasında geçerli bir teknik olduğu sonucuna varılmıştır (Custdio, 2011).

Toplum sürekli değişime ayak uyduran, iyi ya da kötü durumlar karşısında etkilenen ve bunun sonucunda değişen bir olgudur. Günümüzde, toplumu bilgilendirme, bilinçlendirme ve davranış değişikliği oluşturmak amacıyla birçok araç kullanılmaktadır. Nitekim kamu spotları buna en güzel örnektir. Sigara karşıtı kamu spotlarında kullanılan müzik ve seslerin bireyler üzerindeki etkisini ortaya koymayı amaçlayan bir çalışmada, sigara içen ve içmeyen kişilerden oluşan gönüllülere, beş adet sigara karşıtı kamu spotu izletilmiştir. EEG sinyallerini ölçen bir cihaz yardımı ile katılımcıların beyin dalgaları ölçülerek, dikkat süreci işlenmiştir. Sağ frontal lobda elektriksel aktiviteler genellikle olumsuz duygularla ilişkili olduğu bilinmektedir (Marichamy ve Sathiyavathi, 2014). Bundan dolayı sağ ve sol beyin arasındaki farklılıklar analiz edilmiştir. Araştırma bulgularına göre sigara içen grubun, sigara içmeyen gruba göre beyin dalgalarında daha az aktivite olduğu görülmüştür. Aynı zamanda cinsiyet faktörüne bakıldığında erkeklerin ise kadınlara göre kamu spotlarında yer alan müzik ve sesler sırasında beyin dalgalarının daha az tepki verdiği, dolayısıyla kamu spotlarından daha az etkilendiği ifade edilebilir. Bu sonuca göre sigarayla bırakılma ya da sigaraya başlamanın önüne geçilmesi amacıyla özellikle sigara içen gruba yönelik yapılan kamu spotlarının yeterli düzeyde etkili olmadığı söylenebilmektedir (Özer ve Özüpek, 2018).

Bilinç, bireyin kendisinin ve çevresinin farkında olması durumu iken, bilinçaltı kavramı ise görüntü, ses, mesaj gibi uyarıların farkında olmadan, insan zihnine yerleşmesi olarak kabul edilmektedir (Küçükbezirci, 2013). Bütün bu çalışmalar gösteriyor ki düşünce ve duyguları makinalar tarafından algılanabiliyor kılmak insan yaşamını kolaylaştırmaktadır. Bilinç ve bilinçaltına yön verebilme merakı ancak insanlığın kara kutusu olan beyin üzerinde yapılan çalışmalarla giderilecektir.



3. MATERYAL VE YÖNTEMLER

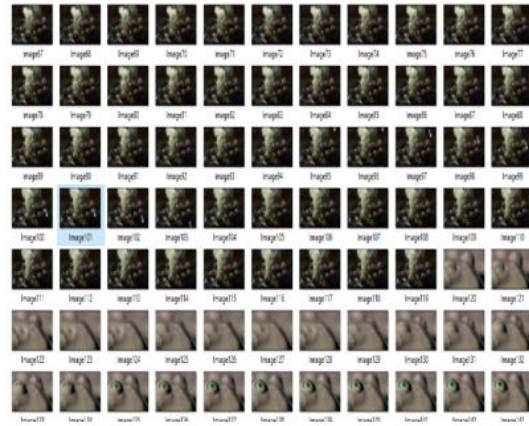

Tez çalışması kapsamında katılımcılara videoların saf ve 25. kare efekti bulunan halleri izletilirken EEG sinyalleri alınmış ve bu sinyallere bakılarak sinyaldeki değişiklikler analiz edilmiştir. Saf ve 25. kare efekti içeren videolara ait sinyallerin ayırt edici özellikleri ortaya koyulmuştur. Videolara gizlenmiş 25. kare tespitinde kullanılacak olan EEG sinyallerinden bir veri tabanı oluşturulup literatüre katkıda bulunmak amaçlanmıştır. Yapılan tez çalışmasında EEG cihazlarından olan 16 kanallı Emotiv EPOC+ cihazı kullanılmıştır.

3.1. Videoların Hazırlanması


Videodaki her bir birim zamandaki sürekli resimlerin sayısı, kare hızını temsil etmektedir. Akıcı bir hareketli görüntü elde etmek için en az 15 FPS hız olmalıdır. İnsan gözünü yormayan bir video yapılmak istenirse hızın 24 FPS olarak seçilmesi bir standart haline gelmiştir. Günümüzdeki kameralarda 120 ve daha fazla FPS hızı destekleme özelliği mevcuttur (Palancioğlu ve Kurban, 2008).

İnsandan insana değişmekle birlikte, insan gözü ve onunla bağlantılı olan beyin, birbirinden bağımsız olarak algılayabildiği saniyedeki 10 ila 12 görüntüyü işleyebilir. Çünkü her insanın görsel algılamasının eşiği değişkendir. Gözlemciler, farklı görsellerden oluşmuş ve kırılmamış bir görsel serisi içerisinde genellikle 13 milisaniye süreyle ekranda kalan bir nesneyi ya da kişiyi hatırlayabilirler. İlk zamanlardaki sessiz filmler 16 ila 24 FPS arasında bir hızdayken, kameralar el ile döndürüldüğünden bu hız havayı yakalamak için oluşacak sahneye göre değiştirilmekteydi. Thomas Edison, görsel korteks için kare sayısının artırılmasının gözü daha az yoracağını savunmuştur. 1927-1930 yılları arasında, çeşitli stüdyo çalışmalarından sonra, 24 FPS sesli film için standart hale gelmiştir.

Tez çalışmasında hazırlanan hayvan, bitki ve doğa temalı videolar karelere ayrılmıştır. Karelerin arasına rastgele konumlandırılmak üzere videolar ile alakasız birkaç resim(limon, ceylan avlayan leopar gibi) eklenmiştir. Daha sonra bu kareler tekrar birleştirilerek gizli resimler içeren yeni videolar oluşturulmuştur. Şekil 3.1 ve Şekil 3.2’de videoları karelere ayırma, gizli resmi ekleme ve birleştirme aşamaları gösterilmektedir.



Şekil 3.1. Videonun karelere ayrılma işlemi




Şekil 3.2. Karelere gizli resmi ekleyip birleştirme işlemi


3.2. Sinyallerin Alınması

Dünya Tıp Birliği (WMA), insanlardan elde edilen veriler üzerinde yapılan araştırmalar için, gönüllülerin yer aldığı tıbbi araştırmalarda etik ilkeler olarak Helsinki Bildirgesi'ni ortaya çıkarmıştır (Gürkan, 2014). Proje kapsamında etiklik ilkelere uymak adına Mustafa Kemal Üniversitesi'nden etik raporu alınmıştır. İskenderun Teknik Üniversitesi öğrencileri ve akademik personelleri katılımcı olarak yer almıştır. Katılımcılar, yaş yada spesifik bir başka özelliğe bakılmaksızın gönüllüler arasından seçilmiş fakat EEG sinyallerini alan cihazın elektrotları uzun saçlı insanlarda az verimle çalıştığı için sadece erkek katılımcılardan sinyal alma mecburiyetinde kalmıştır. Katılımcıların yaş ortalamaları 23,20 iken, yaşlarının standart sapması 2,338672'dir. Katılımcılar deney öncesinde bilgilendirilmiş ve karar verme ehliyetine sahip kişilerin projeye katılımı gönüllülük esasına dayandırılmıştır. Katılımcılar deney öncesinde, bilgilendirildiklerini teyit edici bir form imzalamışlardır. Işık, ses, hareket

gibi beyin sinyallerini etkileyecek olan her durum göz önüne alınıp, karanlık ve sestten izole bir ortamda kayıtlar yapılmıştır. Katılımcıların kayıt esnasında konuşması, gülmesi, öksürmesi gibi faaliyetlerin beyin sinyallerini etkileyeceği gerekçesi ile bu faaliyetlerden kaçınılması istenmiştir. Videonun başlatılması ile başlatıldıktan sonra alınan kayıtlar arasında oluşabilecek senkronizasyon uyumsuzluğunu ortadan kaldırmak için EEG verilerinin ilk ve son saniyesinde elde edilen kısımlar kırılmıştır. Şekil 3.3 ve Şekil 3.4'te herhangi bir kişinin rastgele bir kanal çıkışından alınan EEG verileri gösterilmiştir.



Şekil 3.3. Bir videonun 25. kare efekti içeren haline ait EEG sinyali




Şekil 3.4. Bir videonun saf haline ait EEG sinyali

3.2.1. Emotiv EPOC+ cihazı

Emotiv EPOC+, kablosuz bir başlık üzerine monte edilen sensörleri ile katılımcıların kafa derisi üzerine non-invaziv bir şekilde takılarak, beyinden elektrot bilgisi almayı sağlayan cihazdır. Bilgisayara Wi-fi ya da bluetooth aracılığı ile bağlantı kuran bu cihazın, 16 kanalı mevcuttur. Bu 16 kanalın ikisi referans için ayrıldığı için 14 kanaldan bir akışı sağlanmaktadır. Emotiv EPOC+ adlı cihaz yardımı ile alınan kayıtların sinyali işleme kısmı açık kaynaklı yazılım ortamı olan EEGLAB ile gerçekleştirilmiştir. Her bir video 15 saniye olduğundan kanal başına toplanan örnek sayısı $128 \times 15 = 1920$ olmuştur.

Emotiv EPOC+ cihazı, EEG sinyalini bir kablosuz iletim sistemi tarafından tetiklenen bir elektrik darbesiyle işaretleyerek, her bir uyarının başlangıcına doğru kilitlemek üzere uyarlanmıştır (Thie, 2013). Cihazda yer alan sensörler üzerindeki elektrotların her biri iyon değeri yüksek olan lens solüsyonu tarafından ıslatılır. Bu işlem elektrik sinyalinin geçişine izin vererek elektrotlardan daha verimli sinyal almayı sağlamaktadır. Kanallar; AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8 FC6, F4, F8, AF4, CMS ve DRL olarak isimlendirilmiştir. CMS ve DRL referans noktaları olarak kabul edilmekte; CMS, diğer sensörlerin voltajını ölçmek için bir toprak referans noktası iken, DRL harici kaynaklardan elektriksel paraziti azaltmak için ileriye doğru bir referans noktasıdır (Badcock ve diğerleri, 2015). Şekil 3.5’de Emotiv EPOC+ sistemleri için EEG elektrotlarının sensör pozisyonu gösterilmiştir (Wang, Guan, Man ve Ting, 2014).



Şekil 3.5. Emotiv EPOC+ sistemleri için EEG elektrotlarının sensör pozisyonu


Sensör isimlerinin açılımları şu şekildedir; AF3-sol en ön frontal, F7- frontal, F3-frontal, FC5-sol arka frontal, T7-temporal, P7-pariental, O1-oksipital, O2-oksipital, P8-pariental,

T8-temporal, FC6-sağ arka frontal, F4-frontal, F8-frontal, AF4-sağ en ön frontal. Kanalların numarası her bir bölümü temsil etmektedir. Sensör numarasına bağlı kanal konumlandırması Çizelge 3.1’de verilmiştir. 1 ve 2 numaralı kanallar referans kanalı olup, diğerleri verilerin alındığı kanallardır.

Çizelge 3.1. Kanalların konumu

3	4	5	6	7	8	9	10	11	12	13	14	15	16
AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4

EEG sinyalleri, kafa derisine yerleştirilen elektrotlarla toplandığı için, her sensörün yerleştirildiği bölge, sinyallerin analizi için büyük önem taşır. Bu nedenle, elektrotları kritik ve önceden tanımlanmış olarak yerleştirmek için beynin bölgeleri, genellikle 10-20 sistem konumlandırması denilen bir sistem ile konumlandırılır. Çift sayılı elektrotlar sağ yarımküresinde, tek sayılı elektrotlar beynin sol yarımküresinde yer alır. Yüzdelikler, burnun üst kısmından ve başın arka arasındaki mesafeyi temsil eder. 10-20 sistemi EEG veri edinimi için kabul edilen standarttır (Duarte, 2017). Her elektrot ölçtüğü korteks bölgesine göre etiketlenir (örnek: O - Oksipital bölge). Şekil 3.6’da kafa derisi üzerindeki elektrotların 10-20 sistemine göre organizasyonunu gösterilmektedir.



Şekil 3.6. Elektrotların 10-20 sistemine göre organizasyonunu (Duarte, 2017)

Emotiv Systems, 2003 yılında kurulan bir şirket olup, BBA teknolojisinde öncü bir yaklaşımla yeni nesil insan-makine etkileşimi için bir arayüz geliştirmiştir. Bilinçli arayüz sınırlarının ötesinde, insan ve elektronik cihazlar arasındaki etkileşimi geliştirerek Emotiv EPOC+ tasarlanmıştır. Bu teknolojiler, uygulama geliştiricilerine ve dünya çapındaki diğer üçüncü taraflara lisanslı bir donanım ve yazılım platformu içermektedir. Beyin kontrollü

oyun kavramı, uzun süreler boyunca oyun endüstrisinin bir hayali ve hedefi olmuştur. Bu yüzden Emotiv EPOC+ yaratıcıları ilk olarak oyun sektörüne dikkat çekmeyi hedeflemiştir. Oyun severlerin düşünce ve duyguları ile oyun oynamasını kontrol etmelerini sağlayarak, video oyun endüstrisi için özel olarak tasarlanmış ilk uygun fiyatlı, giyilebilir, nöro-başlığı tasarlamıştır (Stytsenko, Jablonskis ve Prahm, 2011). Bahsedildiği gibi başlangıçta bilgisayar oyunları için tanıtılsa da araştırma baskısı daha fazla analiz için ham verilere erişim sağlamak olmuştur. Emotiv EPOC+'ın nispeten uygun fiyatlı kullanımı kolay, güvenilir olması, bilim adamlarının yeni deneyler yapmaları veya mevcut olanlara destek olmak amacı için çeşitli fırsatlar sunmuştur. Şekil 3.7'de Emotiv EPOC+ cihazı gösterilmiştir.



Şekil 3.7. Emotiv EPOC+'ın EEG nöro-başlığı (Steemit, 2018)

4. SİNYAL İŞLEME

Filtreler elektronik devrelerde, gürültüyü ve istenmeyen işaretleri süzmek, belirli frekansları birbirinden ayırmak, örnekleme işleminden önce sinyalleri sınırlamak gibi çeşitli amaçlarla kullanılmaktadırlar. İstenilen bileşenlerin süzülmesinde, gürültü azaltmada, rezonanstan kaçınmada ve işaret biçimlendirme işlemlerinde filtreler kullanılır (Özpolat, Karakaya ve Gülten, 2017).

Gürültü, sinyale ait zaman serisinde, sinyalin frekans aralığı dışında meydana gelen değişimlerdir. Gürültüyü azaltmak için filtreleme işlemleri yapılır. Bunun yanında sinyalleri birbirinden ayırtmak, sinyal kalitesini arttırmak ve bozulmuş sinyali tekrar elde etmek gibi avantajlarda sunar (Uçar, Bozkurt, Polat ve Bilgin, 2014). Kalp atışı, göz kırpmaları ve göz hareketlerinin yapay dokular olması, beyin sinyallerini kirleten etkenlerdir. Bu yüzden katılımcılardan veya çevresel etkilerden dolayı oluşan hareketlerin neden olduğu dalgalanmalar ve gereksiz sinyaller temizlenmelidir. EEG sinyalini bozan, istenmeden meydana gelen sinyaller birden fazla kaynaktan oluşabilmektedir. Bunların bir kaçı şöyledir:

Elektromiyografi (EMG): Kafa bölgesini çevreleyen boyun, yüz vb. gibi organların kasları tarafından üretilen elektriksel aktivitedir.

Elektrokülografi (EOG): Göz hareketi ve 60 Hz'lik frekansa sahip güç kaynağı hatları tarafından üretilen elektriksel aktivitedir.

Elektrokardiyografi (EKG): Kalp sinyalleri tarafından üretilen elektriksel aktivitedir.

Gürültü kaynakları, bu sebepler dışında doğası gereği de ortaya çıkabilir. Çevresel etkiler, kişinin fiziksel durumundan kaynaklanan sinyaller ve diğer gürültüler dönüşüm işlemleri ile ayrıştırılacaktır. Dönüşüm bir sinyalin, başka parametrelerle ifade edilmesi şeklinde tanımlanmaktadır. Bu tez çalışmasında, Fourier Dönüşümü (FD) ve Hilbert Huang Dönüşümü (HHD) kullanılmıştır.

4.1. Fourier Dönüşümü

EEG işaretleri, beyin fonksiyonlarıyla ilgili çok miktarda bilgi saklamaktadır. Spektral analiz yöntemleri bu bilgilerin bulunmasında frekans bileşenlerinden yararlanmayı mümkün kılmaktadır. En çok kullanılan spektral analiz yöntemi olan Fourier Dönüşümü (FD), sinyallerin, sinüzoidal bileşenlere ayrıştırılması temeline dayanan matematiksel bir tekniktir. FD yüksek genlikteki işaretlerin varlığı ile ilgilenerek, EEG işaretlerini frekans genlik bölgesinde incelemektedir. Gürültüye gömülmüş bir sinyalin frekans bileşenlerini bularak sinyali ayrıştırır ve hangi frekansta ne şiddette bir titreşim olduğunu gösterir. Zaman alanından frekans alanına geçerken FD kullanılır. Sinyali dönüştürürken frekans bölgesine taşınması, dönüşüm sırasında sinyalin zaman bilgisinin kaybolmasına neden olur ki, bu da bir dezavantajdır (Coşkun ve İstanbullu, 2012).

Matematikçi ve fizikçi Jean Baptise Joseph Fourier (1768-1830), FD hakkında ilk çalışma yapan kişi olmakla birlikte, onun isim babasıdır. 1807 yılında sıcaklığın dağılımında sinüzoidlerin kullanımını gösteren bir yayın çıkartarak, herhangi bir sürekli sinyalin düzgün seçilmiş sinüzoidlerin toplamı biçiminde gösterilebileceğini iddia etmiştir. Ancak teoreminde yanlışlıkları vardır, çünkü sinüzoidlerin toplamı asla köşeli bir sinyali ifade edemez fakat birbirlerine çok yakın bir değer çıkabilmektedir. Bu konu matematikte fourier serileri altında incelenmektedir (Aygün, 2006). Temelde FD, Ayrık Fourier Dönüşümü (AFD) ve Sürekli Fourier Dönüşümü (SFD) olmak üzere 2'ye ayrılır. Tez çalışmasında AFD'den ortaya çıkan algoritmalar serisi olan Hızlı Fourier Dönüşümü kullanılmıştır.

4.1.1. Ayrık Fourier dönüşümü

Sayısal işaretler için Fourier dönüşümünün kullanılması tam anlamı ile uygun değildir. Çünkü frekansın analog olarak gösterilmesi ve sonsuz sayıda örneğin gerekmesi, bu uygunsuzluğun temel nedenleridir. Bu güçlüklerden dolayı, FD'nin işaret işlemedeki önemi dikkate alındığında daha uygulanabilir bir dönüşüm olarak AFD ortaya çıkarılmıştır.

AFD mutlak toplanabilir diziler için frekans bölgesi gösterimini sağlamaktadır. AFD, ayrık zamanlı sinyal işleme algoritma ve sistemlerinin analizi ve tasarımı ile doğrusal filtreleme, korelasyon analizi ve spektrum analizi gibi sinyal işleme uygulamalarında önemli bir rol oynamaktadır. AFD'nin bu öneme sahip olmasının ardındaki temel neden AFD'yi

hesaplamakta kullanılan verimli algoritmaların varlığıdır. AFD, FD'nin eşit aralıklı frekanslardaki örneklerine özdeştir. Eş. 4.1'de, N noktalı AFD'nin hesaplanması için verimli bir algoritma sağlayan HFD yöntemi kullanılmıştır. Ayrık zamanlı periyodik bir işaretin AFD'si Eş. 4.1'deki gibi tanımlanmaktadır.

$$x_k = \sum_{n=0}^{N-1} x(n) e^{-\frac{i2\pi}{N} kn} \quad k = 0, \dots, N - 1 \quad (4.1)$$

x_k katsayıları AFD'nin k . katsayısını, zaman domeninin giriş işareti olan $x(n)$ ise, N örnekten oluşan bir zaman serisinin n . örneğini temsil etmektedir. N kare boyudur. Eş. 4.2'de, AFD katsayıları olan x_k sayılarının mutlak değerlerinin karelerinin logaritmaları alınmıştır. Bu işlemin amacı ise giriş işaretin frekans spektrumunu bulmak içindir (Güraksin, 2009).

$$P(k) = 10 \log |x_k|^2 \quad (4.2)$$

Hızlı fourier dönüşümü

Eş. 4.1'de dizi uzunluğu olan N 'nin büyük olması durumunda AFD sırasında çok fazla işlem yapılması gerekmektedir. N sayısı artarken yapılan işlem sayısı yüksek hızla artmaktadır. AFD için gerekli işlem miktarını azaltacak bir prosedür olarak Hızlı Fourier Dönüşümü (HFD) algoritmaları geliştirilmiştir. Bu algoritmalar ile AFD hesabı için gereken işlemlerin sayısı oldukça azaltılarak işlem kolaylığı sağlanmıştır. HFD, AFD hesaplanması için etkili ve kolay bir algoritmadır.

Sonlu uzunlukta olan bir EEG sinyaline HFD uygulamak için, mevcut sinyal, ikinin katları şeklinde 32, 64, 128 gibi karelenir ve her bir kareye karşılık düşen frekans spektrumu bulmak için pencereleme işlemi yapılır. Gerçekte olmayan frekans bileşenlerinin spektrumunda ortaya çıkması pencereleme sayesinde engellenir (Barışcı ve Müldür, 2003).

4.2. Hilbert Huang Dönüşümü

EEG işaretleri doğrusal ve durağan olmayan, gürültüden etkilenen elektriksel beyin faaliyetleridir. Amerika'da NASA bünyesindeki Goddard Uzay Uçuş Araştırma Merkezi'nde çalışan bilim adamı Norden E. Huang tarafından 1998 yılında önerilmiş olan Hilbert-Huang Dönüşümü (HHD) hem doğrusal hem de durağan olmayan işaretlerin analizine imkân veren adaptif ve etkili bir yöntemdir (Özdemir ve Yıldırım, 2012). HHD yöntemi zaman-frekans dönüşümüdür. Yöntem, lineer ve sabit olmayan sinyalleri Fourier dönüşümünün sınırlayamadığı daha esnek kırılmaları analiz edebilir (Zhang, Wu ve Zhi, 2009).

HHD doğrusal ve durağan olmayan, frekans ve genliği sürekli değişen işaretlerin analizine olanak sağlayan uyarlanabilir bir yöntemdir. Hilbert dönüşümü, uygulandığı işarete 90 derece faz farkı ile karmaşık bir bileşen ekleyerek, işaretin faz bilgisinin kestirilmesini sağlamaktadır (Elbi, 2013). Tek bileşenli işaretler, belirli bir zaman aralığında sadece bir frekans içeriğine sahip olduğu için, Hilbert dönüşümü bu işaretlere doğrudan uygulanabilir. Fakat EEG gibi çok bileşenli işaretler için bu mümkün olamamaktadır. Dar bant sinyalini elde etmek için Hilbert dönüşümü ile Huang dönüşümü birleştirilerek bu sorun ortadan kaldırılmıştır (Coşkun ve İstanbullu, 2012).

HHD, yöntemi iki aşamalı bir yöntemdir. İlk aşamada, Ampirik Kip Ayrışımı (AKA) ile İçsel Mod Fonksiyonları (İMF) elde edilir. İkinci aşamada ise Hilbert Dönüşümü (HD) ile anlık frekans ve genlik değerleri zaman frekans uzayında elde edilir. AKA, İMF'leri ayıklayarak genlik ve zaman alanı analizi gerçekleştirir. Her İMF, giriş zaman serilerinin farklı bir frekans modülasyonudur. HD ise, zaman-frekans alanındaki her bir İMF'den anlık genlik değerlerinin analitik fonksiyonunu yaratır (Altan ve Kutlu, 2018).

İlk olarak AKA ile sürece ilişkin sinyalin, her biri frekans modülasyonlu birer işaret olan İMF çıkartılır, sinyale ait İMF'ler verilen durma değerlerine göre değişiklik gösterebilir. Bu yöntem ile EEG işareti olarak kullanılan giriş sinyali, farklı salınım özellikleri barındıran İMF'ler cinsinden ifade edilmektedir (Onay ve Köse, 2014). Elde edilen her bir İMF'ten Hilbert Dönüşümü ile anlık frekans ve genlik değerleri zaman-frekans alanında elde edilir. İlk İMF genellikle yüksek frekanslı bileşenleri vermektedir. HHD doğrusal ve durağan

olmayan süreçlerin zaman-frekans-enerji gösterimlerinde, diğer yöntemlerden daha keskin, ayırt edici ve net sonuçlar verir (Altan, Yayık, Kutlu, Yıldırım ve Yıldırım, 2014).

4.2.1. Ampirik kip ayrışımı

AKA yöntemi ile sinyaller farklı frekanslardaki bileşenlerine ayrılmaktadır (Oweis ve Abdulhay, 2011). Filtreleme avantajının zaman ölçeği, doğrusal ve durağan olmayan sinyalin kendine özgü özelliklerini tamamen korumak için sonuçları filtrelemek anlamına gelir. Gürültü bilgisini, farklı sinyallerin farklı zaman ölçeklerinde elde edebilmeyi sağlayan AKA yöntemi EEG'yi ayrıştırmak için kullanılmaktadır (Zhang, Wu ve Zhi, 2009). AKA, bir sinyalin, farklı sinyallerin birleşiminden meydana geldiği varsayımından hareketle geliştirilmiştir. AKA metodu kullanılarak bir sinyal veri tabanı sonlu küçük sayıda salınım modunu simgeleyen ve aşağıdaki özellikleri sağlayan İMF'lere ayrıştırılmaktadır.

1. Sinyalin birbirine karşılık gelen yerel en yüksek ve en düşük noktalarının genlikleri hesaplanır. Yerel ekstremum (sinyalin işaret değiştirdiği yerler) değerleri kullanılarak ara değerlendirme elde edilir.
2. Yerel en yüksek ve en düşük verilerin (üst ve alt zarflar) ortalamalarını hesaplanır.
3. Giriş sinyalden ortalama değerleri çıkarılır.
4. Elde edilen sinyalin İMF olma koşulu sorgulanır.

Koşul 1; tüm veri tabanında, uç değer sayısı ile 0 (sıfır) geçişi sayısı arasındaki fark en fazla 1 olabilir. Koşul 2; herhangi bir noktada, yerel minimum değer ve yerel maksimum değer tarafından tanımlanan zarfın ortalama değerleri sıfır olmalıdır.

Bu iki koşul İMF üzerinde anlık frekans ve genlik hesaplaması için gereklidir. İMF değerinin hesaplanması için yukarıdaki 4 adım sonunda İMF olma şartı oluşan kadar döngü tekrarlanır (Gürsoy, Yılmaz ve Üstün, 2017; Yayık, Altan, Kutlu, Yıldırım ve Yıldırım, 2014). Giriş sinyali olan $x(t)$ 'nin tüm yerel uç değerleri bulunmaktadır. Yerel ortalama zaman dilimi $m(t)$ aşağıdaki Eş. 4.3 ile açıklanmaktadır. $elow(t)$ yerel maksimum zarflarını $eup(t)$ ise yerel minimum zarflarını temsil etmektedir.

$$m(t) = \frac{[elow(t) + eup(t)]}{2} \quad (4.3)$$

Osilasyon modu olan $r(t)$ ise Eş. 4.4'de gösterilmektedir (Yu ve diğerleri, 2018).

$$r(t) = x(t) - m(t) \quad (4.4)$$

Giriş sinyali $x(t)$ 'nin öncelikle tepe noktaların belirlenmesi yardımıyla yerel maksimum ve minimumları elde edilmiştir. Ardından üst ve alt zarflar elde edilmiştir. Bu zarfların ortalama değerleri $m(t)$, hesaplanmış ve sinyal ile bu ortalama arasındaki fark olan $r(t)$ bulunmuştur. $r(t)$ yeni bir sinyal olarak belirlenmiştir. Bu yeni sinyal, İMF şartlarını sağlıyor ise giriş sinyalinin ilk öz kipi olarak kabul edilir. Bir öz kip elde edildiğinde, bu sinyal $x(t)$ sinyalinden çıkarılır. Kalan sinyal olan $r(t)$, diğer öz kiplerin elde edilmesi için yeni sinyal olarak değerlendirilir. İşlem, kalan değer monoton bir sinyal oluncaya kadar devam ettirilir (Kotan ve Akan, 2018). Standart AKA algoritması Eş. 4.5'de gösterilmiştir. Eş. 4.5'de N , iç mod işlevlerinin sayısıdır.

$$x(t) = \sum_{i=1}^N IMF_i(t) + r(t) \quad (4.5)$$

4.2.2. Hilbert dönüşümü

İşaretin İMF'lerine ayrılmasından sonra, çözülmüş İMF'lere Hilbert dönüşümü uygulanır. Hilbert spektrumu olarak bilinen enerji –frekans- zaman dağılımı elde edilir (Eraldemir ve diğerleri, 2017). Bu yöntemle düşük frekanslı bölgede bazı istenmeyen düşük genlikli İMF'ler üretilir ve istenmeyen bazı frekans bileşenleri kaldırılır. Her bir İMF için HD dönüşümü alınarak analitik bir ifade elde edilir. HD yönteminde, her bir İMF genlik veya frekans modülasyonuna uğratılmış işaretlerdir. İMF ayrıştırma işlemi, FD'nin aksine, değişken genlik ve frekans ölçeklerine sahip bir dönüşümdür (Onay ve Köse, 2014). Eş. 4.6'da verilen Hilbert dönüşümü uygulanarak anlık frekans ve anlık genlik değerleri bulunarak durağanlık ifade edilmiştir. Bu EEG sinyallerinin işlenmesi için ilk adımdır.

$$y(t) = H(x(t)) = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (4.6)$$

P değeri, integralin Cauchy ana değerini göstermektedir. $x(t)$ gerçek işaret fonksiyonunun, Hilbert dönüşümü ile $y(t)$ sanal işaretin, analitik fonksiyonu elde edilmektedir. Eş. 4.7'de gerçek işaret ile sanal işaretin toplamı ile özgün analitik bir sinyal elde edilmiştir. Eş. 4.8'de, Hilbert Huang genel denklemi verilmiştir.

$$z(t) = x(t) + i \cdot y(t) = a(t)e^{i\theta(t)} \quad (4.7)$$

$$x(t) = R \left\{ \sum_{j=1}^n a_j(t) e^{i w_j(t) dt} \right\} \quad (4.8)$$

Burada a anlık genlik ve θ ani faz fonksiyonudur. Elde edilen anlık frekans sadece en küçük zaman biriminde tek frekans içeriğine sahip tek bileşenli işaretler için anlamlıdır (Huang ve Wu, 2008). Bu yüzden analizin uygulanabilir olması için, EEG verileri gibi çok bileşenli işaretlerin her biri, öncesinde, tek bileşenli olmak üzere İMF'lere ayrılmıştır. Yöntemin zamanla değişen özelliği, durağan olmayan EEG verilerini daha yüksek seviyeli kasımlara yerleştirmemizi sağlar (Li, Yingle, Gu ve Qinye, 2009).

5. ÖZNETELİK ÇIKARIMI

Özellik çıkarımı aşamasında; maksimum ve minimum değerlerin farkı, ortalama, medyan, standart sapma, güç, varyans, enerji, basıklık, çarpıklık, çeyrekler arası aralık olmak üzere 10 farklı istatistiksel öznitelik kullanılmıştır. Bu özniteliklerin tanım ve açıklamaları aşağıda yer almaktadır.

Maksimum Minimum Değerlerin Farkı (Max-Min) : Sinyallerin tepe noktaları ile en alt değerlerinin bulunup farkının alınma işlemidir.

Ortalama (Ort) : Sinyallerin her bir kanalı için zaman eksenini boyunca ortalamasının alınma işlemidir.

Medyan (M) : Sinyaller artan düzende sıralandığında veriyi tam ortadan ayıran noktaya medyan denir. Sinyallerin her bir kanalı için ortanca değerinin bulunma işlemidir. Medyan, merkeze yığılma ölçüsü olarak ifade edilir.

Standart Sapma(SS) : Veri değerlerinin yayılımının özetlenmesi için kullanılan bir ölçüdür. Standart sapma ile verilerin ne kadarının ortalamaya yakın olduğu bulur. Eğer standart sapma küçükse veriler ortalamaya yakın yerlerde dağılmışlar demektir.

Güç(G) : Güç, birim zaman başına tüketilen enerji miktarı olarak tanımlanır. Bu miktara, sinyalin enerjisinin sonsuzluğa gittiği veya sinyalin karesel olarak toplanmadığı durumlarda bakılır.

Enerji(E) : Sinyal alanı üzerindeki iki nokta arasındaki mesafenin makul bir ölçüsünün sağlandığı varsayımına sinyal işleme açısından enerji denir.

Varyans (V) : Varyans, sinyallerin dağılımının merkezle olan uzaklığını ölçerek sinyalin yuvarlaklığı hakkında bilgi sahibi olmamızı sağlar. Varyans kavramı dağılıma ait her bir değer, dağılımın ortalamasından ne kadar uzak olduğuyla ilgilidir. Varyans söz konusu sapmaların ortalama değerini ölçmektedir.

Çarpıklık (C) : Sinyalde merkezi bir nokta seçip, bu noktanın sağında ve solundaki sinyallerin aynı olup olmadığını kontrol eden işlemdir. Eğer aynı ise verinin simetrik olduğu sonucuna varılır. Çarpıklık, rassal değişkenin olasılık dağılımının simetrik olamayışının ölçülmesidir.

Basıklık (B) : Verinin düzgünlük dağılımını ifade etmektedir. Verilerde gözlemlenen değişken değerlerinin grafiksel dağılımının basık veya sivri olması ile ilgili bir kavramdır. Normal dağılıma sahip değişkenlerin istatistiksel açıdan basıklık değeri sıfır olur. Değişkenin basıklık değeri pozitif bir değer ise, dağılım sivri bir görünüme sahip olmuş olur. Eğer negatif bir değer ise, dağılım düz/basık bir görünümde olur.

Çeyrekler arası aralık (CAA) : Quartiles, dört eşit parçada bir dizi gözlemi ayıran üç noktadır. Birinci Q noktası, birinci çeyrek veya alt çeyrek olarak adlandırılmakta ve Q_1 ile temsil edilmektedir. İkinci Q nokta, ikinci çeyrek veya medyan olarak adlandırılmakta ve Q_2 ile gösterilmektedir. Üçüncü nokta ise üçüncü çeyrek ya da üst çeyrek olarak adlandırılmakta ve Q_3 ile gösterilmektedir. Veriler artan düzende düzenlenerek ikinci çeyrek denilen medyan bulunur ve ortancadan önce gelen değerler ilk bölüm kümesi, ortancadan sonra gelen değerler ise son bölüm kümesidir. Daha sonra ilk ve son bölümlerin ayrı ayrı medyanı bulunarak ilk bölümün medyanına ilk çeyreklik, son bölümün medyanına üçüncü çeyreklik denir. İlk çeyrek ile üçüncü çeyrek arasındaki fark CAA olarak ifade edilir (Alpaslan, Kara, Zencir ve Hanbay, 2015; Şen, Peker, Çavuşoğlu ve Çelebi, 2014; Gürbüz ve Şahin, 2015). Özniteliklerin formülleri Çizelge 5.1'de gösterilmiştir. Burada, $x_n = 1,2,3 \dots n$ bir zaman serisi, N verilerin sayısı, th serinin sıra sayısıdır.

Çizelge 5.1. Özniteliklerin formülleri

Öznitelikler	Formüller	Öznitelikler	Formüller
Maksimum Minimum Değerlerin Farkı(Max,Min)	$\begin{aligned} MaxV &= \max[x_n] \\ MinV &= \min[x_n] \\ max[x_n] - min[x_n] \end{aligned}$	Varyans (V)	$V = \frac{\sum_{n=1}^N (x_n - Ort)^2}{N - 1}$
Ortalama(Ort)	$Ort = \frac{1}{N} \sum_{n=1}^N x_n$	Çarpıklık (Ç)	$\Ç = \frac{\sum_{n=1}^N (x_n - Ort)^3}{(N - 1)SS^3}$
Medyan(M)	$M = \left(\frac{N + 1}{2}\right)^{th}$	Basıklık (B)	$B = \frac{\sum_{n=1}^N (x_n - Ort)^4}{(N - 1)SS^4}$
Standart Sapma(SS)	$SS = \sqrt{\frac{\sum_{n=1}^N x_n - Ort^2}{N - 1}}$	Güç(G)	$G = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{n=0}^{n=N-1} x_n^2 $
Çeyrekler Arası Aralık(ÇAA)	$\begin{aligned} \ÇAA &= Q_3 - Q_1 \\ Q_1 &= \left(\frac{N + 1}{4}\right)^{th} \\ Q_3 &= \left(\frac{3(N + 1)}{4}\right)^{th} \end{aligned}$	Enerji(E)	$E = \int_{-\infty}^{\infty} x_n ^2$

6. SINIFLANDIRMA

Sınıflandırma aşamasında, 25. kare efekti sonucu oluşan sinyaller ile saf videolar izletirken oluşan sinyaller sınıflandırılmıştır. Elde edilen öznitelik vektörlerine, k sınıflandırma yöntemlerinden biri en yakın komşu (KNN) ve doğrusal bir sınıflandırıcı olan Naive Bayes (NB) sınıflandırıcı uygulanmıştır.

Doğrudan eğitim setinden mesafe ölçümlerinin hesaplanmasındaki bir dezavantaj, değişkenlerin farklı ölçüm ölçeklerine sahip olmasıdır. Bu yüzden verilere sınıflandırma işlemi uygulamadan önce değerler standardize edilmiştir. Böylece tüm değerler birbirlerine yakın değerler haline gelmiştir. Standardizasyon işlemi Eş. 6.1'de gösterilmiştir.

$$x_s = \sum_{i=1}^N \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (6.1)$$

Standardizasyon işlemi, herhangi bir x_s değerinin içinde bulunduğu veri setindeki öznitelikler içinden en büyük ve en küçük değerler ile ifade edilir.

6.1. K-Parçalı Çapraz Doğrulama Yöntemi

Çapraz doğrulama yönteminde veri seti, iki gruba ayrılır. Bunlardan birincisi (eğitim seti) sınıflandırıcının model parametrelerinin belirlenmesinde kullanılırken diğeri (test seti) ise eğitilen sınıflandırıcının başarımlarını ölçmek için kullanılır (Duda, Hart ve Stork 2012).

K-parçalı doğrulama yönteminde, toplam n adet örneğin bulunduğu bir veri seti, k adet ayrık parçaya ayrılır. Farklı bir veri seti kümesi, test için ayrılarak kalan diğeri $k - 1$ veri seti eğitim için kullanılır. Her defasında test kümesi değiştirilerek sınıflandırıcı k defa eğitilir ve sınıflandırıcı performansı tahmin edilir (Narin, İşler ve Özer, 2014; Altan, Kutlu ve Yeniad, 2019; İşçimen, Kutlu, Reyhaniye ve Turan, 2014). Ayrıca verilerin eğitim ve test bölümlerine ayrılmasında çeşitlilik sağlanmış olur. Tez çalışmasında 5 parçalı çapraz doğrulama yöntemi kullanılmıştır.

6.1.1. K en yakın komşu

Önemli bir sınıflandırma algoritması olan KNN yönteminin temeli, çoğunluğunun bulunduğu sınıfa yeni sınıflandırılmamış örnekler vererek, sınıf sayısının ikiden büyük olduğu problemlerle kolayca baş edebilmesidir. KNN'nin amacı, yeni bir veri geldiğinde, onun en yakın k komşusuna bakarak, yeni verinin sınıfına karar vermektir (Yıldız, Yıldırım ve Altılar, 2008). KNN sınıflandırıcısı, özellik alanındaki en yakın eğitim örneklerine dayanarak nesnelere veya gerilemeyi sınıflandırmak için denetlenen bir öğrenme algoritmasıdır (Bahari ve Janghorbani, 2013).

KNN algoritmasında öncelikli olarak en yakın kaç değere bakılması gerektiğini ifade eden, bir k değeri belirlenir. Veri kümesine yeni dâhil olan eleman, eski sınıflandırılmış veriler içerisinde kendisine en yakın k tane veriyi seçer. Bu seçilen k tane veri hangi sınıfa ait ise, yeni dâhil olan veri o sınıfın elemanı olur (Yağanoğlu, Bozkurt ve Günay, 2014; Piotrowski ve Szymulska, 2017). En yakın k komşu algoritmasında test edilen veriler ile eğitim verileri arasındaki mesafe hesaplanırken Öklid uzaklık bulma yöntemi kullanılmaktadır. (Atasoy ve diğerleri, 2014). Öklid yöntemi, sınıflandırma ve kümeleme algoritmalarında en sık kullanılan uzaklık ölçütüdür. Eş. 6.2'de Öklid yöntemi gösterilmiştir. Bu tez çalışmasında 3,5,7 ve 9 en yakın komşuluk değerlerinin her biri için analiz yapılmıştır.

$$d = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (6.2)$$

x sınıflandırılan veri girişini, y eğitim seti verilerini, n veri setinin sayısını temsil etmektedir. Öklid ölçütü, uzayda iki nokta arasındaki $C = (x_1, x_2, x_3 \dots x_n)$ ve $D = (y_1, y_2, y_3 \dots y_n)$ doğrusal uzaklığı ölçmek için hesaplanır (Kresse ve Danko, 2012).

6.1.2. Naive Bayes Sınıflandırması

Bu sınıflandırıcı Bayes teoremine dayandığından, adını teoremin öncüsü olan Thomas Bayes'ten almıştır. Naive Bayes (NB), örneklerin hangi sınıfa hangi olasılıkla ait

olabileceğini tahmin eder. NB sınıflandırıcıları, sınıf üyeliği olasılıklarını öngören istatistiksel sınıflandırıcılardır (Bhattacharyya, Khasnobish, Konar, Tibarewala ve Nagar, 2011). NB, her özneliğin aynı öneme sahip olduğunu ve özneliklerin birbirlerini etkilemediği fikrini savunur (Kutlu ve Köse 2014). Belirli bir sınıfın her bir özneliğinin varsayımlarıyla hareket eden NB sınıflandırıcısında, sınıflandırma işlemi yapılırken diğer sınıflandırıcılara göre daha az eğitim verisi yeterlidir (Sharma, 2017). NB sınıflandırıcısı, bir sınıfın belirli bir özelliğinin varlığının, başka bir özelliğinin varlığı ile ilişkili olmadığını varsaydığı için olasılık modelinin kesin doğasına bağlı olarak, denetimli bir öğrenme ortamında çok verimli bir şekilde eğitilebilir (Wang ve Zhang, 2016).

Eş. 6.3'de n adet öznelik ile temsil edilmiş c_j sınıfının d örneğini üretme olasılığı gösterilmiştir. Bayes teoremi Eş. 6.4'de verilmiştir.

$$p(d|c_j) = p(d_1|c_j) * p(d_2|c_j) * ... * p(d_n|c_j) \quad (6.3)$$

$$p(c_j|d) = \frac{p(d|c_j)p(c_j)}{p(d)} \quad (6.4)$$

7. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu tez çalışmasının amacı, insanların bilinçaltını etkilediği düşünülen videolardaki gizli resimleri, beynin algılayıp/algılamadığının tespit edilmesidir. Beyin sinyalleri, Emotiv EPOC+ cihazı ile katılımcıların kafa derisi üzerine non-invaziv bir şekilde takılarak alınmıştır. Tez çalışması kapsamında, 50 adet katılımcıya 6 farklı videonun saf ve 25. kare efekti bulunduran halleri izletilmiştir. Videoları izlerken oluşan EEG sinyalleri üzerinde filtreleme, istatistiksel öznitelik çıkarımı ve sınıflandırma işlemleri yapılarak sistemin performansı ortaya çıkarılmıştır. Sonuç aşamasında 3 farklı durum incelenmiştir. Bunlar;

1. EEG sinyallerinin ham halleri üzerine istatistiksel öznitelik çıkarma algoritmaları uygulanarak sınıflandırma işlemleri yapılmıştır.
2. HFD uygulanan EEG sinyallerine, istatistiksel öznitelik çıkarma algoritmaları uygulanarak sınıflandırma işlemleri yapılmıştır.
3. HHD uygulanan EEG sinyallerine, istatistiksel öznitelik çıkarma algoritmaları uygulanarak sınıflandırma işlemleri yapılmıştır.

Videoların saf hallerini izlerken oluşan sinyaller ile gizli resim eklenmiş videoları izlerken oluşan sinyalleri kıyaslamak için sınıflandırma yöntemlerinden olan KNN ve NB sınıflandırıcıları kullanılmıştır. K-parçalı çapraz doğrulama yöntemi uygulanarak eğitim sağlanmıştır. KNN sınıflandırıcısının öğrenme örneği sayısı (k) 3,5,7 ve 9 olmak üzere en yakın komşuluk değerleridir. Öğrenme örneği sayıları arasında k=1 değerinin alınmamasının sebebi, EEG gibi karmaşık sinyallerde çok fazla gürültünün olmasından ötürü verinin en yakındaki ilk değerinin gürültü verisi olma ihtimalinin yüksek olmasıdır. Çapraz doğrulama parçası 5 olacak şekilde işlem yapılmıştır. Tezde 10 farklı istatistiksel öznitelik çıkarma algoritması uygulanarak, özniteliklerin tek başlarına ve bir araya gelerek sistemin başarısını hangi düzeyde yükselttiği bulunmuştur.

7.1. EEG Sinyallerinin Ham Halleri Üzerine Uygulanan Sınıflandırma Sonuçları

EEG sinyallerinin ham halleri üzerine uygulanan sınıflandırma yönteminde, sinyallere filtreleme işlemi yapılmadan sınıflandırma uygulanmıştır. Amaç, filtreleme işlemi sırasında gürültü temizlenirken bazı anlamlı bilgilerin beraberinde yok olabilme ihtimaline karşı bir yöntem denemektir. Ham sinyalin üzerine istatistiksel öznitelik çıkarma algoritmaları

uygulanarak sınıflandırma işlemi yapılmıştır. Hangi özneliğin, daha başarılı olduğunu bulmak için, özneliklerin her birine KNN ve NB sınıflandırıcıları uygulanmıştır. Çizelge 7.1’de KNN sınıflandırıcısının EEG sinyallerinin ham halleri üzerindeki genel başarısı, Çizelge 7.2’de ise NB sınıflandırıcısının EEG sinyallerinin ham halleri üzerindeki genel başarısı gösterilmektedir.

Çizelge 7.1. KNN sınıflandırıcısının tüm özneliklerde performans başarısı

Performans Ölçüleri	Öğrenme Örneği Sayısı				Başarı Ortalaması
	k= 3	k=5	k=7	k=9	
Doğruluk	%81,80	%81,60	%81,55	%81,10	%81,51
Duyarlılık	%81,80	%81,60	%81,59	%81,05	%81,51
F1 Değer	%81,80	%81,60	%81,60	%81,10	%81,53
Kesinlik	%81,80	%81,62	%81,60	%81,11	%81,53

Çizelge 7.2. NB sınıflandırıcısının tüm özneliklerde performans başarısı

Performans Ölçüleri	Başarı Oranları
Doğruluk	%62,21
Duyarlılık	%62,20
F1 Değer	%62,70
Kesinlik	%62,90

KNN ve NB sınıflandırıcılarının özneliklerinin tek başlarına elde ettiği başarılar, hesaplanmıştır. Çizelge 7.3 KNN sınıflandırıcısını kullanan EEG sinyallerinin ham hallerindeki özneliklerinin tek başlarına elde ettikleri başarı oranlarını, Çizelge 7.4 ise NB sınıflandırıcısını kullanan EEG sinyallerinin ham hallerindeki özneliklerinin tek başlarına elde ettikleri başarı oranlarını göstermektedir.

Çizelge 7.3. KNN sınıflandırıcısını kullanan özneliklerin başarısı

Öznelikler	Öğrenme Örneği Sayısı				Başarı Ortalaması
	k= 3	k=5	k=7	k=9	
Maksimum Minimum Değerlerin Farkı	%53,39	%51,83	%50,94	%51,04	%51,80
Ortalama	%58,82	%59,08	%60,00	%60,11	%59,50
Medyan	%71,85	%68,78	%67,61	%66,46	%68,68
Standart Sapma	%51,83	%51,53	%50,98	%50,73	%51,27
Güç	%56,20	%57,77	%57,50	%58,01	%57,37
Varyans	%52,83	%53,28	%53,57	%53,73	%53,35
Enerji	%56,02	%57,75	%57,61	%57,80	%57,30
Basıklık	%52,51	%52,08	%52,96	%52,94	%52,62
Çarpıklık	%53,84	%54,10	%53,75	%53,61	%53,83
Çeyrekler Arası Aralık	%61,33	%58,75	%58,61	%57,51	%59,05

Çizelge 7.4. NB sınıflandırıcısını kullanan özneliklerin başarısı

Öznelikler	Başarı Oranları
Maksimum Minimum Değerlerin Farkı	%51,05
Ortalama	%64,03
Medyan	%65,45
Standart Sapma	%50,45
Güç	%58,86
Varyans	%50,45
Enerji	%58,85
Basıklık	%50,91
Çarpıklık	%52,89
Çeyrekler Arası Aralık	%54,53

KNN sınıflandırıcısında medyan, ortalama ve çeyrekler arası aralık özelliklerinin tek başlarına daha yüksek başarımlara ulaştığı görülmüştür. EEG sinyalleri gibi değişkene yönelik verilerin dağılımı değerlendirilirken veri kümesindeki sapma veya uç noktaların etkisinin ön plana çıktığı dağılımlarda medyan dikkate alınır. 25. kare efektini içeren videoların EEG sinyallerinin ortalama değerleri, saf videoların EEG sinyallerinden daha yüksek çıkmıştır. Bu nedenle, ortalama değer özneliğinin sınıflandırıcı için ayırt edici öznelik olduğu gözlenmiştir. Çeyrekler arası aralık ise, veri kümesinin ilk %50'lik kısmının ortancası ile sonraki %50'lik kısmının ortancasının farkıdır. Çeyrekler arası aralık, sıralanmış veriler içinde aşırı küçük veya aşırı büyük aykırı değerlerden etkilenmeyerek, bir veri setindeki yayılımı ölçmektedir. EEG sinyalleri gibi normal dağılıma sahip olmayan verilerde tercih edilir. (Pullon, McCabe, Gaskell ve Sleight, 2019; Anderson ve diğerleri, 2011). EEG verileri değişken bir yapıya sahip olduğu için yayılımının karakteristik özellikleri diğer çalışmalar gibi bu tez çalışmasında da anlamlı bir öznelik kümesi olarak göze çarpmaktadır. NB sınıflandırıcısında da aynı şekilde, KNN sınıflandırıcısında yüksek çıkan medyan ve ortalama özelliklerinin tek başlarına daha yüksek başarımlara ulaştığı görülmüştür.

Her bir kanaldan alınan EEG bilgileri buldukları konum itibari ile birçok anlamlı bilgi taşımaktadır. Kanallardan alınan EEG sinyalleri KNN ve NB sınıflandırıcıları ile analiz edilerek, hangi kanalın daha başarılı bir performans sergilediği gösterilmiştir. 1 ve 2 numaralı kanallar referans kanalları olduğu için veri çıkışı sağlanmamaktadır. Bu gerekçe ile 1 ve 2 numaralı kanallar çizelgelerde yer almamaktadır. Çizelge 7.5'de ham EEG sinyal

kanallarının, KNN sınıflandırıcısındaki performans başarısı, Çizelge 7.6'da ise ham EEG sinyal kanallarının, NB sınıflandırıcısındaki performans başarısı gösterilmektedir.

Çizelge 7.5. Kanalların KNN sınıflandırıcısındaki performans başarısı

Kanallar	Öğrenme Örneği Sayısı				Başarı Ortalaması
	k= 3	k=5	k=7	k=9	
Kanal 3	%77,83	%76,50	%77,33	%77,50	%77,29
Kanal 4	%83,16	%81,33	%80,50	%81,50	%81,62
Kanal 5	%83,83	%81,33	%81,33	%80,00	%81,62
Kanal 6	%86,50	%86,50	%84,50	%85,33	%85,71
Kanal 7	%76,83	%76,33	%73,83	%76,33	%75,83
Kanal 8	%83,83	%81,33	%81,33	%80,00	%81,62
Kanal 9	%84,83	%84,16	%84,00	%81,00	%83,50
Kanal 10	%77,50	%76,33	%76,33	%75,50	%76,42
Kanal 11	%84,00	%82,66	%81,50	%80,66	%82,21
Kanal 12	%84,33	%84,50	%83,16	%81,83	%83,46
Kanal 13	%86,50	%84,33	%85,83	%84,50	%85,29
Kanal 14	%80,33	%80,33	%80,16	%79,50	%80,08
Kanal 15	%83,66	%82,83	%80,50	%80,33	%81,83
Kanal 16	%82,66	%84,83	%83,83	%81,00	%83,08

Çizelge 7.6. Kanalların NB sınıflandırıcısındaki performans başarısı

Kanallar	Başarı Oranları
Kanal 3	%60,20
Kanal 4	%67,80
Kanal 5	%67,20
Kanal 6	%63,70
Kanal 7	%68,00
Kanal 8	%67,20
Kanal 9	%70,50
Kanal 10	%57,50
Kanal 11	%67,30
Kanal 12	%64,30
Kanal 13	%63,50
Kanal 14	%66,80
Kanal 15	%64,80
Kanal 16	%68,80

Ham EEG sinyallerinin KNN sınıflandırıcısı uygulandığında en yüksek başarı gösteren kanalları 6 ve 13 numaralı kanalları olmuştur. Çizelge 3.1'deki kanal konumlandırma görselinden yola çıkarak bu kanalların FC5, FC6 isimindeki kanallar olduğu bilinmektedir. Bu iki kanal frontal lobu temsil etmekte ve yaratıcılık, problem çözme, karar verme ve planlama görevi üstlenmektedir.

NB sınıflandırıcısı uygulandığında ise 9 ve 16 numaralı kanallar yüksek başarı vermiştir. Bu kanalların isimleri ise sırayla O1 ve AF4 olmaktadır. O1 kanalı görsel algıdan sorumlu olan oksipital lobu temsil ederken, AF4 kanalı ise karar verme ve planlamadan sorumlu olan frontal bölgeyi temsil etmektedir.

7.2. HFD Uygulanan EEG Sinyallerine, İstatistiksel Öznitelik Çıkarma Algoritmaları Uygulanarak Sınıflandırma Sonuçları

EEG sinyallerine HFD uygulanarak, gürültüye gömülmüş bir sinyalin frekans bileşenleri bulunmaktadır. Frekanslarda ne şiddette bir titreşim olduğu bilgisine ulaşılarak, frekansları belirginleştirmektedir. HFD uygulanan EEG sinyalleri, istatistiksel öznitelik çıkarma algoritmalarına tabi tutularak, çıkan sonuçlar KNN ve NB ile sınıflandırılmıştır. Çizelge 7.7’de HFD uygulanan EEG sinyallerinin KNN sınıflandırıcısındaki genel başarısı, Çizelge 7.8’de ise HFD uygulanan EEG sinyallerinin NB sınıflandırıcısındaki genel başarısı gösterilmektedir.

Çizelge 7.7. KNN sınıflandırıcısının tüm özniteliklerde performans başarısı

Performans Ölçüleri	Öğrenme Örneği Sayısı				Başarı Ortalaması
	k=3	k=5	k=7	k=9	
Doğruluk	%62,45	%68,76	%63,28	%64,75	%64,81
Duyarlılık	%62,50	%68,70	%63,30	%64,80	%64,83
F1 Değer	%62,40	%68,70	%63,20	%64,70	%64,75
Kesinlik	%62,60	%63,40	%63,40	%64,80	%63,55

Çizelge 7.8. NB sınıflandırıcısının tüm özniteliklerde performans başarısı

Performans Ölçüleri	Başarı Oranları
Doğruluk	%54,57
Duyarlılık	%54,60
F1 Değer	%53,10
Kesinlik	%55,20

KNN ve NB sınıflandırıcılarının özniteliklerinin tek başlarına elde ettiği başarılar, hesaplanmıştır. Çizelge 7.9 KNN sınıflandırıcısını kullanan HFD uygulanmış EEG sinyallerinin özniteliklerinin tek başlarına elde ettikleri başarı oranlarını, Çizelge 7.10 ise NB sınıflandırıcısını kullanan HFD uygulanmış EEG sinyallerinin özniteliklerinin tek başlarına elde ettikleri başarı oranlarını göstermektedir.

Çizelge 7.9. KNN sınıflandırıcısını kullanan özniteliklerin başarısı

Öznitelikler	Öğrenme Örneği Sayısı				Başarı Ortalaması
	k=3	k=5	k=7	k=9	
Maksimum Minimum Değerlerin Farkı	%57,20	%62,89	%57,82	%58,82	%59,18
Ortalama	%57,90	%63,40	%57,71	%59,08	%59,52
Medyan	%56,46	%62,51	%57,48	%58,89	%58,84
Standart Sapma	%58,27	%62,72	%59,40	%59,47	%59,97
Güç	%59,27	%63,22	%58,84	%60,01	%60,34
Varyans	%59,54	%62,86	%60,15	%59,26	%60,45
Enerji	%59,28	%63,21	%58,85	%60,01	%60,34
Basıklık	%56,83	%61,64	%57,44	%58,97	%58,72
Çarpıklık	%57,41	%60,55	%57,51	%58,17	%58,41
Çeyrekler Arası Aralık	%56,97	%62,20	%57,13	%58,65	%58,74

Çizelge 7.10. NB sınıflandırıcısını kullanan özniteliklerin başarısı

Öznitelikler	Başarı Oranları
Maksimum Minimum Değerlerin Farkı	%51,19
Ortalama	%51,96
Medyan	%49,32
Standart Sapma	%54,22
Güç	%52,10
Varyans	%52,47
Enerji	%52,09
Basıklık	%50,59
Çarpıklık	%49,75
Çeyrekler Arası Aralık	%54,07

KNN sınıflandırıcısında standart sapma, güç, varyans, enerji özelliklerinin tek başlarına daha yüksek başarımlara ulaştığı görülmüştür. Standart sapma, veri değerlerinin yayılımının özetlenmesi için kullanılan ve verilerin ne ölçüde ortalamaya yakın olduğunu bulan istatistiksel ölçümdür. Veriler ortalamaya, yakın yerlere dağılmış ise standart sapma değeri küçük, uzak yerlere dağılmışlarsa standart sapma değeri büyük sonuç vermektedir. Matematiksel olarak standart sapmanın karesi ise varyans değerine karşılık gelmektedir. Varyans kavramı, dağılıma ait her bir değerinin, dağılımın ortalamasından ne kadar uzakta olduğu ile ilgilidir. Bu özniteliklerin ayırt edici bir özellik göstermesinin nedeni HFD yöntemi ile sinyallerin frekanslarının daha belirgin hale gelmesidir. Güç ve enerji birbirleri ile ilişki içinde olan yapılarıdır. Güç birim zaman başına tüketilen enerji miktarı olarak tanımlanmaktadır. Sinyalin enerjisi sonsuzluğa giderse veya sinyal “karesel olarak toplanmıyorsa” güç kavramına bakılmaktadır. Karmaşık yapıdaki EEG sinyallerinin KNN

sınıflandırıcısı için güç ve enerji öznitelikleri yüksek başarı vermiştir. NB sınıflandırıcı için ise standart sapma ve çeyrekler arası aralık öznitelik değerleri yüksek başarı sağlamıştır.

Çizelge 7.11’de HFD uygulanmış EEG sinyal kanallarının, KNN sınıflandırıcısındaki performans başarısı, Çizelge 7.12’de ise HFD uygulanmış EEG sinyal kanallarının, NB sınıflandırıcısındaki performans başarısı gösterilmektedir.

Çizelge 7.11. Kanalların KNN sınıflandırıcısındaki performans başarısı

Kanallar	Öğrenme Örneği Sayısı				Başarı Ortalaması
	k=3	k=5	k=7	k=9	
Kanal 3	%65,83	%62,16	%61,66	%62,33	%63,00
Kanal 4	%51,00	%50,50	%49,83	%52,33	%50,92
Kanal 5	%56,83	%60,33	%60,00	%60,33	%59,37
Kanal 6	%58,00	%59,16	%59,16	%57,83	%58,54
Kanal 7	%56,66	%55,66	%57,16	%56,00	%56,37
Kanal 8	%59,33	%60,00	%9,16	%59,33	%46,96
Kanal 9	%56,33	%52,50	%52,83	%56,00	%54,42
Kanal 10	%65,33	%64,16	%61,50	%61,83	%63,21
Kanal 11	%52,16	%54,83	%54,66	%53,83	%53,87
Kanal 12	%56,66	%59,50	%59,66	%59,00	%58,71
Kanal 13	%55,83	%56,66	%56,33	%56,50	%56,33
Kanal 14	%54,83	%56,33	%56,50	%57,00	%56,17
Kanal 15	%59,33	%60,50	%61,16	%62,83	%60,96
Kanal 16	%52,83	%55,33	%55,33	%55,33	%54,71

Çizelge 7.12. Kanalların NB sınıflandırıcısındaki performans başarısı

Kanallar	Başarı Oranları
Kanal 3	%58,66
Kanal 4	%53,66
Kanal 5	%53,00
Kanal 6	%47,83
Kanal 7	%51,83
Kanal 8	%51,83
Kanal 9	%53,33
Kanal 10	%59,33
Kanal 11	%52,00
Kanal 12	%50,50
Kanal 13	%49,66
Kanal 14	%49,66
Kanal 15	%51,83
Kanal 16	%54,16

KNN ve NB sınıflandırıcılarının her ikisi içinde yüksek başarı gösteren kanallar 3 ve 10 numaralı kanallar olmuştur. Bu kanalların isimleri ise sırasıyla AF3 ve O2 olmakta, ilk kanal frontal lobu, diğer kanal ise oksipital lobu temsil etmektedir.

7.3. HHD Uygulanan EEG Sinyallerine, İstatistiksel Öznitelik Çıkarma Algoritmaları Uygulanarak Sınıflandırma Sonuçları

HHD, EEG sinyallerinin anlık frekans ve anlık genlik bilgilerine ulaşılmasını sağlayarak sinyallerin frekans bileşenlerini İMF cinsinden sunmaktadır. Genellikle ilk İMF yüksek frekanslı bileşenleri vermektedir. Tez çalışmasında HHD dönüşümü sırasında, her bir kanal için elde edilen İMF sayısı 11'dir. Çizelge 7.13'de HHD uygulanan EEG sinyallerinin KNN sınıflandırıcısı için genel başarısı, Çizelge 7.14'de ise NB sınıflandırıcısının genel başarısı gösterilmiştir.

Çizelge 7.13. KNN sınıflandırıcısının tüm özniteliklerdeki başarı performansı

Performans Ölçüleri	Öğrenme Örneği Sayısı				Başarı Ortalaması
	k=3	k=5	k=7	k=9	
Doğruluk	%97,40	%75,33	%68,68	%70,49	%77,98
Duyarlılık	%97,40	%75,30	%68,70	%70,50	%77,98
F1 Değer	%97,40	%75,30	%68,60	%70,50	%77,95
Kesinlik	%97,40	%75,40	%68,90	%70,60	%78,08

Çizelge 7.14. NB sınıflandırıcısının tüm özniteliklerdeki başarı performansı

Performans Ölçüleri	Başarı Oranları
Doğruluk	%51,34
Duyarlılık	%51,30
F1 Değer	%47,30
Kesinlik	%51,90

HHD uygulanmış EEG verilerindeki özniteliklerin tek başlarına göstermiş olduğu başarı performansını tespit etmek için her bir özniteliğe KNN ve NB sınıflandırıcıları uygulanmıştır. Çizelge 7.15'de KNN sınıflandırıcısını kullanan özniteliklerin tek başlarına göstermiş olduğu başarı performansı, Çizelge 7.16'da ise NB sınıflandırıcısını kullanan özniteliklerin tek başlarına göstermiş olduğu başarı performansı gösterilmiştir.

Çizelge 7.15. KNN sınıflandırıcısını kullanan özniteliklerin performans başarıları

Öznitelikler	Öğrenme Örneği Sayısı				Başarı Ortalaması
	k= 3	k=5	k=7	k=9	
Maksimum Minimum Değerlerin Farkı	%78,02	%69,76	%66,84	%66,94	%70,39
Ortalama	%92,77	%72,67	%66,26	%67,67	%74,84
Medyan	%92,00	%73,22	%67,19	%68,32	%75,18
Standart Sapma	%80,36	%70,43	%67,12	%67,59	%71,38
Güç	%84,66	%71,38	%67,09	%67,94	%72,77
Varyans	%84,79	%71,50	%67,13	%67,99	%72,85
Enerji	%84,37	%71,29	%67,06	%67,76	%72,62
Basıklık	%84,96	%72,08	%67,86	%68,77	%73,42
Çarpıklık	%82,74	%70,54	%66,71	%67,47	%71,87
Çeyrekler Arası Aralık	%94,46	%72,79	%66,01	%67,69	%75,24

Çizelge 7.16. NB sınıflandırıcısını kullanan özniteliklerin performans başarıları

Öznitelikler	Başarı Oranları
Maksimum Minimum Değerlerin Farkı	%49,79
Ortalama	%51,02
Medyan	%49,88
Standart Sapma	%49,64
Güç	%49,85
Varyans	%49,85
Enerji	%49,85
Basıklık	%50,47
Çarpıklık	%50,70
Çeyrekler Arası Aralık	%50,09

HHD uygulanan EEG sinyallerinin KNN sınıflandırıcısında medyan, ortalama ve çeyrekler arası aralık özelliklerinin tek başlarına daha yüksek başarımlara ulaştığı görülmüştür. EEG sinyallerinin ham halleri üzerine uygulanan KNN sınıflandırıcısında da aynı özniteliklerin yüksek başarı verdiği önceki kısımlarda tespit edilmişti. HHD uygulanan EEG sinyallerinin NB sınıflandırıcısında ise ortalama, basıklık ve çarpıklık özniteliklerinin yüksek başarı verdiği gözlemlenmiştir. Önceki kısımlarda yorumlanmayan basıklık ve çarpıklık öznitelikleri açıklanacak olursa, basıklık rastgele değişkenlerin doruk dağılımlarını ölçmekte, verinin düzgünlük dağılımını ifade etmektedir. Verilerde gözlemlenen değişken değerlerinin grafiksel dağılımının basık veya sivri olması ile ilgili bir kavramdır. Normal dağılıma sahip değişkenlerin istatistiksel açıdan basıklık değeri sıfırdır. Değişkenin basıklık değeri pozitif bir değer ise, dağılım sivri bir görünüme, negatif bir değer ise, dağılım düz/basık bir görünüme sahip olur. EEG bileşenlerin dağılımı çok hassas olduğu için, basıklık bu bileşenleri tespit etmemize yardımcı olmaktadır (Ikeda ve diğerleri, 2019;

Mahajan ve Morshed, 2015; Greco, Mammone, Morabito ve Versaci, 2016). Gürültü oluşabilecek sinyallerin bileşenleri tespit etmek için basıklıktan yararlanılabilir. EEG verilerinin de normal bir dağılıma sahip olmaması bu özneliği önemli kılar. Çarpıklık ise rassal değişkenin olasılık dağılımının simetrik olamayışının ölçülmesidir. Dolayısı ile EEG sinyallerinin değerlerinin simetrik olmayışı bu öznelik için yüksek değerler vermiştir. 25. kare efektini içeren videoların EEG sinyallerinin ortalama değerleri, saf videoların EEG sinyallerinden daha yüksek çıkmıştır. Bu nedenle, ortalama değer özneliğinin sınıflandırıcı için ayırt edici bir öznelik olduğu gözlenmiştir.

Çizelge 7.17’de HHD uygulanmış EEG sinyal kanallarının, KNN sınıflandırıcısındaki performans başarısı, Çizelge 7.18’de ise HHD uygulanmış EEG sinyal kanallarının, NB sınıflandırıcısındaki performans başarısı gösterilmektedir.

Çizelge 7.17. Kanalların KNN sınıflandırıcısındaki performans başarısı

Kanallar	Öğrenme Örneği Sayısı				Başarı Ortalaması
	k= 3	k=5	k=7	k=9	
Kanal 3	%97,25	%71,16	%63,07	%64,60	%74,02
Kanal 4	%97,69	%71,53	%63,75	%66,56	%74,88
Kanal 5	%97,72	%72,19	%64,75	%66,04	%75,18
Kanal 6	%97,57	%73,48	%65,03	%67,42	%75,88
Kanal 7	%96,96	%72,22	%64,77	%66,36	%75,08
Kanal 8	%96,77	%70,93	%63,21	%65,07	%74,00
Kanal 9	%97,31	%74,74	%67,06	%68,57	%76,92
Kanal 10	%97,80	%74,50	%67,48	%69,12	%77,23
Kanal 11	%97,39	%72,50	%65,42	%66,95	%75,57
Kanal 12	%97,18	%73,04	%64,80	%66,60	%75,41
Kanal 13	%97,33	%73,37	%65,98,	%67,78	%79,49
Kanal 14	%97,66	%73,03	%64,72	%67,78	%75,80
Kanal 15	%97,36	%72,84	%65,84	%68,28	%76,08
Kanal 16	%97,69	%75,01	%67,84	%69,71	%77,56

Çizelge 7.18. Kanalların NB sınıflandırıcısındaki performans başarıları

Kanallar	Başarı Oranları
Kanal 3	%50,07
Kanal 4	%51,37
Kanal 5	%50,46
Kanal 6	%50,34
Kanal 7	%49,66
Kanal 8	%51,75
Kanal 9	%51,37
Kanal 10	%52,89
Kanal 11	%50,81
Kanal 12	%51,01
Kanal 13	%51,59
Kanal 14	%50,59
Kanal 15	%51,34
Kanal 16	%51,33

HHD uygulanan EEG sinyallerinin sınıflandırma sonuçlarına göre, KNN sınıflandırıcısında kanal 13 ve 16 numaralı kanallar yüksek başarı göstermiştir. Sırasıyla bu kanalların isimleri FC6 ve AF4 olup frontal lobu temsil etmektedirler. NB sınıflandırıcısında ise kanal 10 ve 13 numaralı kanalların daha yüksek başarı gösterdiği tespit edilmiştir. Bu kanalların isimleri ise O2 ve FC6 olup, sırayla oksipital ve frontal bölgeyi temsil etmektedir.

8. SONUÇLAR VE ÖNERİLER

EEG sinyali üzerine uygulanan farklı yöntemlerin KNN ve NB sınıflandırıcıları için gösterdikleri genel başarı performansları tek bir çizelgede toplanacak olursa, Çizelge 8.1’de KNN sınıflandırıcısının, her bir yöntem için elde ettiği genel başarı performansları, Çizelge 8.2’de NB sınıflandırıcısının, her bir yöntem için elde ettiği genel başarı performansları gösterilmektedir.

Çizelge 8.1. KNN sınıflandırıcısı için uygulanan yöntemlerin başarı performansı

KNN Sınıflandırıcı İçin Performans Ölçüleri	KNN Sınıflandırıcısı İçin Uygulanan Yöntemler		
	EEG sinyallerinin Ham Halleri Üzerine	HFD Uygulanan EEG Sinyalleri Üzerine	HHD Uygulanan EEG Sinyallerine Üzerine
Doğruluk	%81,51	%64,81	%77,98
Duyarlılık	%81,51	%64,83	%77,98
F1 Değer	%81,53	%64,75	%77,95
Kesinlik	%81,53	%63,55	%78,08

Çizelge 8.2. NB sınıflandırıcısı için uygulanan yöntemlerin başarı performansı

NB Sınıflandırıcı İçin Performans Ölçüleri	NB Sınıflandırıcısı İçin Uygulanan Yöntemler		
	EEG sinyallerinin Ham Halleri Üzerine	HFD Uygulanan EEG Sinyalleri Üzerine	HHD Uygulanan EEG Sinyallerine Üzerine
Doğruluk	%62,21	%54,57	%51,34
Duyarlılık	%62,20	%54,60	%51,30
F1 Değer	%62,70	%53,10	%47,30
Kesinlik	%62,90	%55,20	%51,90

KNN ve NB sınıflandırıcıları yorumlanacak olursa, KNN sınıflandırıcısının genelde daha yüksek başarı gösterdiği gözlenmiştir. Yöntemler kıyaslandığında, KNN ve NB sınıflandırıcılarının her ikisinde de ham EEG sinyalleri üzerine yapılan sınıflandırmanın başarı oranları daha yüksek tespit edilmiştir.

KNN sınıflandırıcısındaki yakın komşuluk değeri olan ‘k’ değerlerini yorumlamak gerekirse, genel başarılar, özneliklerin tek başlarına gösterdikleri başarılar ve kanalların başarıları için oluşturulan sınıflandırmalarda, genellikle $k=3$ ve $k=5$ değerlerinin başarıyı arttırdığı gözlemlenmiştir. Öğrenme örneği sayılarının $k=3$ ’den başlamasının sebebi, 3’den küçük alınan değerlerin EEG içerisindeki gürültüyü öğrenme olasılığının bulunmasıdır. HHD uygulanan EEG sinyallerinin her bir kanal için oluşturduğu 11 adet İMF, verisetinin örnek sayısını oldukça arttırmıştır. Sınıflandırma sonuçlarında elde edilen başarı doğruluğu ile örnek sayısı doğru orantılıdır. Bu yüzden HHD yöntemi uygulanan EEG sinyallerinden

elde edilen sınıflandırma başarılarının doğruluğu daha yüksektir. Eğitim aşamasında kullanılan çapraz doğrulama yöntemindeki parça sayısı arttıkça sınıflandırıcı performansının azaldığı gözlemlenmiştir. Bunun sebebi ise daha fazla kombinasyon ile test verilerinin oluşturulmasıdır. Kanalların yüksek başarı gösterdiği loblar frontal ve oksipital bölge üzerinde yoğunlukta olmuştur. Tez çalışmasında video izletilerek oluşturulan veriseti için görsel algı ve yaratıcılıktan sorumlu olan lobların daha aktif olması beklenen bir durum olmuştur. Eğitim setinden mesafe ölçümü yaparken, değişkenlerin farklı ölçüm ölçeklerine sahip olması verimli sınıflandırma sonuçları oluşturmamaktadır. Bundan dolayı tez çalışmasında verilere sınıflandırma işlemi uygulamadan önce değerlerin standardize edilmesi önerilmiştir.

25. kare efektini içeren videoların EEG sinyalleri ile saf videoların EEG sinyalleri arasında farklılık olduğu tespit edilmiştir. İzlediğimiz videolardaki bazı görüntüler gözümüzün algılayamadığı hızda geçip giderken, farkında olmadan gördüğümüz çerçevelerin bilinçaltımıza etki ettiği gözlemlenmiştir. Yapılan tez çalışmasının sonuçları, videolardaki 25. kare efektinin, videoları izleyen katılımcıların EEG sinyallerine bakılarak tespit edilebilme fikrini desteklemektedir. Tez çalışmasının gelecekteki işi, farklı sinyal işleme ve sınıflandırma yöntemleri denenerek geliştirilmesidir.

KAYNAKLAR

- Alkaç, U. (2009). Beyin Araştırmaları Tarihinde Bir Gezinti: Elektronörofizyoloji. *Klinik Gelişim*, 3, 14-19.
- Alpaslan, N., Kara, A., Zencir, B., & Hanbay, D. (2015). Classification of breast masses in mammogram images using KNN. *23rd Signal Processing and Communications Applications Conference (SIU)*, 1469-1472. IEEE.
- Altan, G., & Kutlu, Y.(2018). Generative Autoencoder Kernels on Deep Learning for Brain Activity Analysis. *Natural and Engineering Sciences*, 3(3), 311-322.
- Altan, G., Kutlu, Y., & Yeniad, M. (2019). ECG based human identification using Second Order Difference Plots. *Computer methods and programs in biomedicine*, 170, 81-93.
- Altan, G., Yayık, A., Kutlu, Y., Yıldırım, S., & Yıldırım, E. (2014). Konjektif Kalp Yetmezliğinin Hilbert-Huang Dönüşümü ile Analizi. *İzmir Akıllı Sistemlerde Yenilikler ve Uygulamaları Konferansı*.
- Altındış, F., & Yılmaz, B. (2016). Feature Extraction and Classification in a Two-State Brain-Computer Interface. *Medical Technologies National Congress (TIPEKNO)*, 1-4. IEEE.
- Anderson, E. W., Potter, K. C., Matzen, L. E., Shepherd, J. F., Preston, G. A., & Silva, C. T. (2011, June). A user study of visualization effectiveness using EEG and cognitive load. *Computer graphics forum*, 30(3), 791-800.
- Atasoy, H., Kutlu, Y., Yıldırım, E., Yıldırım, S. (2014). Eeg Sinyallerinden Fraktal Boyut Ve Dalgacık Dönüşümü Kullanılarak Duygu Tanıma. *Bursa Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu*.
- Avcı, D. E., & Yağbasan, R. (2008). Beyin yarı kürelerinin baskın olarak kullanılmasına yönelik öğretim stratejileri. *Gazi Üniversitesi Gazi Eğitim Fakültesi Dergisi*, 28(2).
- Aygün, O. (2006). Konuşmacı tanıma sistemlerinde dalgacık dönüşümü, Doktora Tezi *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya.
- Badcock, N. A., Preece, K. A., de Wit, B., Glenn, K., Fieder, N., Thie, J., & McArthur, G. (2015). Validation of the Emotiv EPOC EEG system for research quality auditory event-related potentials in children. *PeerJ*, 3, e907.
- Bahari, F., & Janghorbani, A. (2013). Eeg-based emotion recognition using recurrence plot analysis and k nearest neighbor classifier. *20th Iranian Conference on Biomedical Engineering (ICBME)*, 228-233. IEEE.
- Barışçı, N., & Müldür, S. (2003). Epileptik Eeg Sinyallerinin Sinirsel-Bulanık Sistem ile Sınıflandırılması. *Politeknik Dergisi*, 6(2).

- Baysal, K., Özcan, M.O., & Taşkın, D. (2015). Video Görüntülerindeki Subliminal Çerçevelerin Tespiti Üzerine Bir Yöntem Önerisi. *Ejovoc (Electronic Journal of Vocational Colleges)*, 5(4), 94-103.
- Bhattacharyya, S., Khasnobish, A., Konar, A., Tibarewala, D. N., & Nagar, A. K. (2011, April). Performance analysis of left/right hand movement classification from EEG signal by intelligent algorithms. *IEEE Symposium on Computational Intelligence, Cognitive Algorithms, Mind, and Brain (CCMB)*, 1-8. IEEE.
- Bocharov, A. V., Knyazev, G. G., & Savostyanov, A. N. (2017). Depression and implicit emotion processing: an EEG study. *Neurophysiologie Clinique/Clinical Neurophysiology*, 47(3), 225-230.
- Bong, S. Z., Wan, K., Murugappan, M., Ibrahim, N. M., Rajamanickam, Y., & Mohamad, K. (2017). Implementation of wavelet packet transform and non linear analysis for emotion classification in stroke patient using brain signals. *Biomedical Signal Processing and Control*, 36, 102-112.
- Brazier, M. A. (1961). *A history of the electrical activity of the brain: the first half-century*. Oxford, İngiltere: Macmillan.
- Chouhan, T., Panse, A., Smitha, K. G., & Vinod, A. P. (2015, October). A comparative study on the effect of audio and visual stimuli for enhancing attention and memory in brain computer interface system. *Systems, Man, and Cybernetics (SMC), IEEE International Conference on*, 3104-3109. IEEE.
- Coşkun, M., & İstanbullu, A. (2012). EEG İşaretlerinin FFT ve dalgacık dönüşümü ile analizi. *XIV. Akademik Bilişim Konferansı*, 1-3.
- Custdio, P. (2011). Use of EEG as a Neuroscientific Approach to Advertising Research, Doctoral dissertation, *Instituto Superior Técnico, Departamento de Física*, Lisboa Portugal.
- Daşdemir, Y., & Yıldırım, S. (2017). Farklı Kaynaklardan Elde Edilen Veriler ile Duygu Tanıma için Çok-Kanallı Sistem Tasarımı. *Kocaeli 2st International Congress on Engineering Architecture and Design*, 2.
- Duarte, R. M. (2017). Low Cost Brain Computer Interface System for AR.Drone Control, Dissertação de Mestrado, *Universidade Federal de Santa Catarina*, Portugal.
- Duda, R. O., Hart, P. E., & Stork, D. G. (2012). *Pattern Classification*. New York, USA: John Wiley & Sons.
- Elbi, M. D. (2013). Hilbert-Huang dönüşümü ile zaman serilerindeki gürültü bileşenlerinin ayrıştırılması, Yüksek Lisans Tezi, *Pamukkale Üniversitesi Fen Bilimleri Enstitüsü*, Denizli.
- Eraldemir, S. G., Arslan, M. T., & Yıldırım, E. (2017). The Effect of Feature Selection Algorithms in EEG Signal Analysis. *International Advanced Researches & Engineering Congress*.

- Eraldemir, S. G., Yıldırım, E., & Kutlu, Y. (2014). Classification of Mathematical Tasks from EEG Signals Using k-NN Algorithm. *Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu Eleco*, Bursa.
- Fidan, U., & Özkan, N. (2018). Controlling attention & meditation with active EMDR software. *Journal of the Faculty of Engineering and Architecture of Gazi University*.
- Florea, M. (2016). History of the 25th Frame. The Subliminal Message. *International Journal of Communication Research*, 6(3), 261.
- Ge, S., Yang, Q., Wang, R., Lin, P., Gao, J., Leng, Y., & Wang, H. (2017). A brain-computer interface based on a few-channel EEG-fNIRS bimodal system. *IEEE Access*, 5, 208-218.
- Greco, A., Mammone, N., Morabito, F. C., & Versaci, M. (2006). Kurtosis, Renyi's entropy and independent component scalp maps for the automatic artifact rejection from EEG data. *International Journal of Signal Processing*, 2(4), 240-244.
- Grunwald, M., Mueller, S., Rall, L., Weiss, T. (2014). Eeg Changes Caused By Spontaneous Facial Self-Touch May Represent Emotion Regulating Processes And Working Memory Maintenance. *Brain Research*, 1557, 111-126.
- Gur, D., Kaya, T., & Turk, M. (2014). Analysis of normal and epileptic EEG signals with filtering methods. *22nd Signal Processing and Communications Applications Conference (SIU)*, 1877-1880. IEEE.
- Güler, I., Kiyimik, M. K., Akin, M., & Alkan, A. (2001). AR spectral analysis of EEG signals by using maximum likelihood estimation. *Computers in biology and medicine*, 31(6), 441-450.
- Güraksin, G. E. (2009). Normal ve Normal Olmayan Kalp Seslerinin Yapay Sinir Ağları ile Sınıflandırılması. *Engineering Sciences*, 4(4), 559-570
- Gürbüz, S., & Şahin, F. (2014). *Sosyal bilimlerde araştırma yöntemleri*. Ankara: Seçkin Yayıncılık, 271.
- Gürkan, M. (2014). Helsinki Bildirgesi'nin 2013 sürümündeki değişiklikler. *Türkiye Biyoetik Dergisi*, 1(2), 100-104.
- Gürsoy, M. İ., Yılmaz, A. S., & Üstün, S. V. (2017). Güç kalitesi bozulmalarının hilbert huang dönüşümü ve gabor dönüşümü kullanarak sınıflandırılması. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*.
- Hasan, M. K., Ullah, S. H., Gupta, S. S., & Ahmad, M. (2016, September). Drowsiness detection for the perfection of brain computer interface using Viola-jones algorithm. *3rd International Conference on Electrical Engineering and Information Communication Technology (ICEEICT)*, 1-5. IEEE.
- He, J., Liu, D., Wan, Z., & Hu, C. (2014). A noninvasive real-time driving fatigue detection technology based on left prefrontal Attention and Meditation EEG. *Multisensor*

Fusion and Information Integration for Intelligent Systems (MFI), 2014 International Conference on, 1-6. IEEE.

- Huang, N. E., & Wu, Z. (2008). A review on Hilbert-Huang transform: Method and its applications to geophysical studies. *Reviews of geophysics*, 46(2).
- Ikeda, S., Ishii, R., Pascual-Marqui, R. D., Canuet, L., Yoshimura, M., Nishida, K., & Kinoshita, T. (2019). Automated Source Estimation of Scalp EEG Epileptic Activity Using eLORETA Kurtosis Analysis. *Neuropsychobiology*, 77(2), 101-110.
- İnternet: Steemit (2018), Epoc+ - Cheapest and Most Effective EEG Mobile Headset on the Market, URL:<https://steemit.com/steemhunt/@playitforward/epoc-cheapest-and-most-effective-eeeg-mobile-headset-on-the-market>, Son Erişim Tarihi:20.05.2019.
- İşçimen, B., Kutlu, Y., Reyhaniye, A. N., & Turan, C. (2014, April). Image analysis methods on fish recognition. *22nd Signal Processing and Communications Applications Conference (SIU)*, 1411-1414. IEEE.
- Karremans, J. C., Stroebe, W., & Claus, J. (2006). Beyond Vicary's fantasies: the impact of subliminal priming and brand choice. *Journal of Experimental Social Psychology*, 42(6), 792-798.
- Kaya, D., Mustafa, T. (2017). Biyoelektriksel Kökenli İşaretlerde Rahatsızlık Teşhisinin Yorumlanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 29(1).
- Kobayashi, N., Nakagawa, M. (2015). Bcı-Based Control Of Electric Wheelchair. *Consumer Electronics (Gcce)*, 429 - 430.
- Koelstra, S., Muhl, C., Soleymani, M., Lee, J. S., Yazdani, A., Ebrahimi, T., & Patras, I. (2012). Deap: a database for emotion analysis; using physiological signals. *IEEE transactions on affective computing*, 3(1), 18-31.
- Kong, W., Zhao, X., Hu, S., Vecchiato, G., & Babiloni, F. (2013). Electronic evaluation for video commercials by impression index. *Cognitive neurodynamics*, 7(6), 531-535.
- Kotan, S., & Akan, A. (2018, November). A New Intrinsic Mode Function Selection Method Based on Power Spectral Density. *Medical Technologies National Congress (TIPTEKNO)*, 1-4. IEEE.
- Kresse, W., & Danko, D. M. (Eds.). (2012). Springer handbook of geographic information. *Springer Science & Business Media*.
- Kurşunet, D. D. K., & Sazak, N. (2018). Tetha, Alpha, Smr, Beyin Dalgalarının Müzik Türleriyle Olan Etkileşimi: Bir Nexus-10 EEG Çalışması. *Sciences*, 3(1), 149-165.
- Kutlu, F., & Köse, C. (2014, April). Detection of epileptic seizure from EEG signals by using recurrence quantification analysis. *22nd Signal Processing and Communications Applications Conference (SIU)*, 1387-1390. IEEE.

- Küçükbezi, Y. (2013). Bilinçaltı Mesaj Gönderme Teknikleri ve Bilinçaltı Mesajların Toplum Etkileri. *Electronic Turkish Studies*, 8(9).
- Li, Y., Yingle, F., Gu, L., & Qinye, T. (2009). Sleep stage classification based on EEG Hilbert-Huang transform. *4th IEEE Conference on Industrial Electronics and Applications*, 3676-3681. IEEE.
- Mahajan, R., & Morshed, B. I. (2015). Unsupervised eye blink artifact denoising of EEG data with modified multiscale sample entropy, kurtosis, and Wavelet-ICA. *IEEE journal of Biomedical and Health Informatics*, 19(1), 158-165.
- Marichamy, K., & Sathiyavathi, K. (2014). Neuromarketing: The New Science Of Consumer Behavior. *Tactful Management Research Journal*, 2(6).
- Mishchenko, Y., Murat, K., & Cömert, M. (2017). Beyin Bilgisayar Arayüzü için Dvm Makine Öğrenme Yöntemi Kullanılarak Eeg Verilerinden Sağ ve Sol El Hareket Düşüncelerinin Tespiti. *Tübav Bilim Dergisi*, 10(3), 1-20.
- Muter, C. (2002). Bilinçaltı Reklamcılık: Bilinçaltı Reklam Mesajlarının Tüketiciler Üzerindeki Etkileri, Yüksek Lisans Tezi, *Ege Üniversitesi Sosyal Bilimler Enstitüsü Halkla İlişkiler Ve Tanıtım Anabilim Dalı*, İzmir, 24-43.
- Narin, A., İşler, Y., & Özer M. (2014). Konjestif Kalp Yetmezliği Teşhisinde Kullanılan Çapraz Doğrulama Yöntemlerinin Sınıflandırıcı Performanslarının Belirlenmesine Olan Etkilerinin Karşılaştırılması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 16(48), 1-8.
- Onay, F. K., & Köse, C. (2014). İçsel Mod Fonksiyonlarının Tekrarlılık Grafiği Kullanılarak EEG Sinyallerinde Epileptik Nöbetin Algılanması. *Elektrik –Elektronik. Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu*.
- Oweis, R. J., & Abdulhay, E. W. (2011). Seizure classification in EEG signals utilizing Hilbert-Huang transform. *Biomedical engineering online*, 10(1), 38.
- Özdemir, N., & Yıldırım, E. (2012, April). Epileptic seizureprediction based on Hilbert Huang Transform and Artificial Neural Networks. *20th Signal Processing and Communications Applications Conference (SIU)*, 1-4. IEEE.
- Özer, D., & Özüpek, M. N. (2016). Sigara Karşıtı Kamu Spotlarının Bireyler Üzerindeki Etkisinin Nöro-görüntüleme Yöntemiyle Tespit Edilmesi. *OPUS Uluslararası Toplum Araştırmaları Dergisi*, 9(16), 183-215.
- Özerdem, M. S., Polat, H. (2016a). Görsel-İşitsel Uyarılar Kaynaklı Oluşan Duyguların EEG İşaretleri ile Sınıflandırılması. *Dicle Üniversitesi Mühendislik Dergisi*, 7(1), 33-40.
- Özerdem, M. S., Polat, H. (2016b). Duygusal Uyarana Olan Aşinalığın Eeg İşaretleri Üzerine Etkisi. *Medical Technologies National Congress (TIPTEKNO)*, 1-4.
- Özpolat, E., Karakaya, B., & Gülten, A. (2017). FIR Filtre Tasarımı ve FPGA Ortamında Gerçeklenmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 29(2).

- Palancıoğlu M. H. & Kurban T. (2008). Video Ve Gps Tabanlı Navigasyon. 2. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu*, Kayseri.
- Pinheiro, A. P., Rezaii, N., Nestor, P. G., Rauber, A., Spencer, K. M., & Niznikiewicz, M. (2016). Did you or I say pretty, rude or brief? An ERP study of the effects of speaker's identity on emotional word processing. *Brain and language*, 153, 38-49.
- Piotrowski, Z., & Szypulska, M. (2017). Classification of falling asleep states using HRV analysis. *Biocybernetics and biomedical engineering*, 37(2), 290-301.
- Pullon, R. M., McCabe, S., Gaskell, A., & Sleight, J. W. (2019). Non-sinusoidal waves in the EEG and their simulated effect on anaesthetic quantitative EEG monitors. *Journal of clinical monitoring and computing*, 1-8.
- Samy, M. A. A., Rahman, M. M., & Khan, T. A. (2016, September). Extracting and discriminating selective brain signals in non-invasive manner and using them for controlling a device: A cost-efficient approach to brain computer interface (BCI). *3rd International Conference on Electrical Engineering and Information Communication Technology (ICEEICT)*, 1-5. IEEE.
- Sharma, R. K. (2017, May). DWT based epileptic seizure detection from EEG signal using k-NN classifier. *International Conference on Trends in Electronics and Informatics (ICEI)*, 762-765. IEEE.
- Stytsenko, K., Jablonskis, E., & Prahm, C. (2011). Evaluation of consumer EEG device Emotiv EPOC. *MEi: CogSci Conference*, Ljubljana.
- Sürmeli, T. (2010). *Beynin iyileştirme gücü*. Türkiye: Nobel Tıp Kitabevleri.
- Şen, B., Peker, M., Çavuşoğlu, A., & Çelebi, F. V. (2014). A comparative study on classification of sleep stage based on EEG signals using feature selection and classification algorithms. *Journal of medical systems*, 38(3), 18.
- Tan, L. F., Dienes, Z., Jansari, A., & Goh, S. Y. (2014). Effect of mindfulness meditation on brain-computer interface performance. *Consciousness and cognition*, 23, 12-21.
- Taş, B., & Şeker, Ş. E. (2017). *Nöropazarlama ve Yönetim Bilişim Sistemler*. Türkiye: YBS Ansiklopedi, 4(2), 12-17.
- Thie, J. (2013). A wireless marker system to enable evoked potential recordings using a wireless EEG system (EPOC) and a portable computer. *PeerJ PrePrints*.
- Tüzel, N. (2010). Tüketicilerin Zihnini Okumak: Nöropazarlama ve Reklam. *Marmara İletişim Dergisi*, (16).
- Uçar, M. K., Bozkurt, M. R., Polat, K., & Bilgin, C. (2014). EEG Effect of Digital Filtering to Sleep Stage Classification Using EEG Signals. *Elektrik- Elektronik, Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu (Eleco)*, Bursa.

- Wang, H., & Zhang, Y. (2016). Detection of motor imagery EEG signals employing Naive Bayes based learning process. *Measurement*, 86, 148-158.
- Wang, R. W., Chang, Y. C., & Chuang, S. W. (2016). EEG spectral dynamics of video commercials: impact of the narrative on the branding product preference. *Scientific reports*, 6, 36487.
- Wang, T., Guan, S. U., Man, K. L., & Ting, T. O. (2014). EEG eye state identification using incremental attribute learning with time-series classification. *Mathematical Problems in Engineering*, 2014.
- Yağanoğlu, M., Bozkurt, F., & Günay, F. B. (2014). EEG tabanlı beyin-bilgisayar arayüzü sistemlerinde öznitelik çıkarma yöntemleri. *Mühendislik Bilimleri ve Tasarım Dergisi*, 2(3), 313-318.
- Yayık, A., Altan, G., Kutlu, Y., Yıldırım, S., & Yıldırım, E. (2014). Görgül Mod Fonksiyonların Eliptik Analizi ile Kongestif Kalp Yetmezliği Teşhisi. *Elektrik-Elektronik, Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu*.
- Yıldız, T., Yıldırım, S., Altılar, T., (2008). İstenmeyen İletilerin Paralelleştirilmiş KNN Algoritması ile Tespiti. *Akademik Bilişim*, Çanakkale.
- Yu, H., Li, F., Wu, T., Li, R., Yao, L., Wang, C., & Wu, X. (2018). Functional brain abnormalities in major depressive disorder using the Hilbert-Huang transform. *Brain imaging and behavior*, 1-13.
- Yücel, A., & Coşkun, P. (2018). Nöropazarlama Literatür İncelemesi. *Fırat Üniversitesi Sosyal Bilimler Dergisi*, 28(2), 157-177.
- Zhang, L., Wu, D., & Zhi, L. (2009, December). Method of removing noise from EEG signals based on HHT method. *Information Science and Engineering (ICISE), 1st International Conference*, 596-599. IEEE.

EKLER

Tez çalışması kapsamında, sinyal alma işlemi sırasında EEG sinyalleri alınmadan önce katılımcılardan EK-1’ de verilen gönüllülük formunu okumaları ve eğer onaylıyor iseler bu formu imzalamaları istenmiştir.

EK-1. Gönüllülük formu

T.C.
MUSTAFA KEMAL ÜNİVERSİTESİ
TAYFUR ATA SÖKMEN TIP FAKÜLTESİ
TIBBİ ETİK KURULU
Gönüllülerin Bilgilendirilmiş Olur / (Rıza) Formu

Araştırmanın Konusu	: Videolara Saklanmış 25. Karenin EEG Sinyalleri Yardımı ile Tespit Edilmesi
Araştırmanın Amacı	: EEG verilerinden sinyallerin analizi ve sınıflandırılarak gruplandırılması.
Araştırmaya Katılma Süresi	: 15-20 dk.
Araştırmaya Katılacak Yaklaşık Gönüllü Sayısı:	100

Sayın Gönüllü;

Bu çalışmada Beyin-Bilgisayar Arayüzü Tabanlı bir çalışma yapılacaktır. Bunun için alınacak olan EEG sinyalleri Emotiv Epoc cihazı ile elde edilecektir. İnsan sağlığına hiç bir zararı olmayan bu cihaz o anda beyninizin hangi kısımlarının aktif olduğunu bilgisayar ekranında görebilme imkânı sunmaktadır.

Bir masaüstü bilgisayar karşısında izlettirilecek olan videoyu, izlerken Emotiv Epoc marka EEG cihazı ile kafa deriniz üzerinden EEG sinyallerinizi toplayacağız. Bu videolar sizin görebileceğiniz kadar uzaklıkta olacak ve sizin rahat ve oturur pozisyonda izlemeniz sağlanacaktır.

EEG kaydı öncesinde ve kayıt sırasında şu kurallara dikkat etmeniz gerekmektedir;

- a-) Saçlarınızın temiz olması, jöle gibi saç şekillendiricilerinin olmaması ve saçların kısa olması gerekmektedir.
- b-) Çekimden önce herhangi bir ilaç kullanmamanız gerekmektedir.
- c-) Çekim sırasında el, kol, kafa, bacak ve göz gibi organlarını oynatmamaları gerekmektedir.


Yukarıdaki, araştırmadan önce gönüllüye verilmesi gereken bilgileri içeren metni okudum. Bana, tanık huzurunda aşağıda konusu belirtilen araştırmayla ilgili yazılı ve sözlü açıklama yaptım. Araştırmaya gönüllü olarak katıldığımı ve katılmama hakkımın olduğunu, araştırma başladıktan sonra devam etmeyi istememe hakkına sahip olduğum gibi kendi isteğime bakılmaksızın araştırmacı tarafından araştırma dışı bırakılabileceğimi biliyorum. Bu koşullarda söz konusu araştırmaya, hiçbir baskı ve zorlama olmaksızın, kendi rızam ile katılmayı kabul ediyorum.

GÖNÜLLÜ	
Adı Soyadı:	Telefon : (0)
Adresi:	Faks : (0)
Bilgi Verebilecek Kişi:	İmza

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : ÖZKAN, Gözde
 Uyuğu : T.C.
 Doğum tarihi ve yeri : 19.08.1994, Amasya
 Medeni hali : Bekâr
 e-mail : gozdeozkan.mfbe16@iste.edu.tr



Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek lisans	İskenderun Teknik Üniversitesi / Bilgisayar Mühendisliği	Devam Ediyor.
Lisans	İskenderun Teknik Üniversitesi / Bilgisayar Mühendisliği	2016
Lise	Ankara Güzelkent Anadolu Lisesi	2012

İş Deneyimi

Yıl	Yer	Görev
2017-2018	İskenderun Teknik Üniversitesi - Dörtüol Meslek Yüksekokulu	Yarı Zamanlı Öğretim Görevlisi

Yabancı Dil

İngilizce

Yayınlar

Özkan, G., & Gökçen, A.(2019). Determination of the 25th Frame with the EEG Signals Stored in the Videos. *Natural and Engineering Sciences*, Volume 4, No: 2, 92-106.

Özkan, G., & Gökçen, A.(2019). Using the Naive bayes classifier, detecting the effect of the 25th frame in the videos with fast fourier transformed EEG signals. *2nd International Mersin Symposium* (Basımda).

Özkan, G., & Gökçen, A. (2019). Detection of the subliminal messages in videos from the EEG signals using Fast Fourier Transform. *VI. International Symposium on Academic Studies in Science, Engineering and Architecture Studies* (Basımda).

Hobiler

Kitap Okuma, Yüzme, Film İzleme.



DİZİN

A

AKA · xi, 23, 24, 25

B

basıklık · iv, 3, 27, 28, 41

BBA · xi, 4, 5, 6, 7, 8, 18

Ç

çarpıklık · iv, 3, 27, 35, 41

çeyrekler arası aralık · iv, 3, 27

E

EEG · 1, 2, iv, v, x, xi, 2, 3, 4, 5,
6, 8, 9, 10, 11, 12, 14, 15, 16,
17, 18, 19, 20, 21, 22, 23, 24,
25, 26, 33, 34, 35, 36, 37, 38,
40, 41, 42, 43, 44, 45, 46, 47,
48, 49, 50, 51, 52, 53, 54, 55

Elektroensefalografi · xi, 2

Emotiv EPOC+ · iv, v, x, 2, 14,
17, 18, 19, 33

F

FPS · xi, 1, 14

frontal · 4, 8, 10, 11, 12, 17, 36

H

HFD · iv, xii, 2, 7, 11, 22, 33, 37,
44

HHD · iv, xii, 2, 10, 20, 23, 33,
40, 43, 44

Hızlı Fourier Dönüşümü · iv, xii,
21, 22

Hilbert Huang Dönüşümü · iv,
xii, 20, 23

İ

İMF · xii, 23, 24, 25, 26, 40

invaziv · iv, 3, 4, 5, 17, 33

K

kare · iv, x, 1, 2, 14, 16, 22, 30,
33, 35, 42, 45

KNN · iv, v, xii, 3, 6, 8, 9, 10, 30,
31, 33, 34, 35, 36, 37, 38, 39,
40, 41, 42, 43, 44, 46, 52

M

medyan · iv, 2, 27, 28, 35, 41

N

NB · iv, v, xii, 3, 30, 31, 33, 34,
35, 37, 38, 40, 43, 44

O

okspital · 4, 11, 17, 37

S

standart sapma · iv, 2, 27
subliminal mesaj · 1

T

temporal · 4, 17

V

varyans · iv, 3, 27



TEKNOVERSİTE



teknoversite **AYRICALIĞINDASINIZ**

İSTE

