T.C.
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GÖRSEL – İŞİTSEL UYARANLAR KAYNAKLI OLUŞAN DUYGULARIN EEG İŞARETLERİ İLE SINIFLANDIRILMASI

Hasan POLAT

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DİYARBAKIR
Ocak - 2016

T.C.
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GÖRSEL – İŞİTSEL UYARANLAR KAYNAKLI OLUŞAN DUYGULARIN EEG İŞARETLERİ İLE SINIFLANDIRILMASI

Hasan POLAT

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DİYARBAKIR
Ocak - 2016

T.C. DİCLE ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ

DİYARBAKIR

Hasan POLAT tarafından yapılan "Görsel- İşitsel Uyaranlar Kaynaklı Oluşan Duyguların EEG İşaretleri ile Sınıflandırılması" konulu bu çalışma , jürimiz tarafından Elektrik-Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir

Jüri Üyeleri

Başkan : Doç. Dr. Mehmet Siraç ÖZERDEM

Üye : Yrd. Doç. Dr. Abdulnasır YILDIZ

Üye : Yrd. Doç. Dr. Ömer Faruk ERTUĞRUL

Tez Savunma Sınavı Tarihi: 28/01/2016

Yukarıdaki bilgilerin doğruluğunu onaylarım.

.../...../2016

Doç. Dr. Mehmet YILDIRIM

ENSTİTÜ MÜDÜRÜ

TEŞEKKÜR

Bu tez çalışması boyunca yardımlarını esirgemeyen değerli danışmanım Doç. Dr. Mehmet Siraç ÖZERDEM' e teşekkür ederim.

Tezin hazırlanması sırasında her konuda fedakârlık gösteren ve bu günlere gelmemde büyük pay sahibi olan aileme teşekkürlerimi sunarım.

Bu çalışma, Dicle Üniversitesi DÜBAB 12:FF:109 numaralı proje kapsamında desteklenmiştir. Desteklerinden ötürü DÜ Bilimsel Araştırma Projeleri Koordinatörlüğüne teşekkür ederim.

İÇİNDEKİLER

		Sayfa
TEŞEKKÜR……		I
İÇİNDEKİLER…….....		II
ÖZET…….....		IV
ABSTRACT…….....		V
ÇİZELGE LİSTESİ…….....		VI
ŞEKİL LİSTESİ…….....		VII
KISALTMA VE SİMGELER……		IX
1.	**GİRİŞ**…….....	1
1.1.	EEG İşaretleri, Alt Bantları ve Ölçümü……...	1
1.2.	Duygu Olgusu ve EEG Ölçümleri ile Duyguların Ayrıştırılmasında İzlenen Temel Yaklaşım……...	6
2.	**KAYNAK ÖZETLERİ**……..	9
3.	**MATERYAL VE METOT**……	15
3.1.	Kullanılan Veri Seti……..	15
3.1.1.	Kullanılan EEG İşaretlerinin Özellikleri……..	17
3.1.2.	Kullanılan Görsel-İşitsel Uyarıcıların Değerlendirilmesi……	19
3.2.	Özellik Çıkarımı İçin Dalgacık Dönüşümü……..	21
3.2.1.	Dalgacık……...	23
3.2.2.	Sık Kullanılan Ana Dalgacıklar……...	23
3.2.3.	Sürekli Dalgacık Dönüşümü……	26
3.2.4.	Ayrık Dalgacık Dönüşümü……..	27
3.3.	Sınıflandırıcı Olarak Yapay Sinir Ağları…….	29
3.3.1.	Biyolojik Sinir Ağları ve Hücresi……	30
3.3.2.	Yapay Sinir Hücresi…….	31
3.3.3.	Yapılarına Göre Yapay Sinir Ağları……	34
3.3.4.	Öğrenme Algoritmalarına göre YSA'ların Sınıflandırılması……...	36
3.3.5.	Tez Kapsamında Kullanılan YSA Mimarisi ve Öğrenme Algoritması……...	38

3.4. Sınıflandırıcı Olarak K-En Yakın Komşu Algoritması…… 39
3.4.1. kNN Algoritmasında Kullanılan Uzaklık Ölçütleri……... 41
3.4.2. kNN Algoritmasında İzlenen İşlem Aşamaları…….. 42
4. ARAŞTIRMA BULGULARI……..... 45
4.1. EEG Ölçümleri için Önişleme……...…….. 46
4.2. ADD Kullanılarak EEG İşaretlerinden Öznitelik Çıkarımı……. 48
4.3. Öznitelik Vektör Boyutunun Düşürülmesi ve Kanal Seçimi……..……. 50
4.4. EEG Öznitelik Vektörleri ile Kanal Seçimi…….. 52
4.5. EEG Öznitelik Vektörlerinin YSA ile Sınıflandırılması……... 56
4.6. EEG Öznitelik Vektörlerinin kNN ile Sınıflandırılması…… 59
5. TARTIŞMA VE SONUÇ……... 61
6. KAYNAKLAR…… 63
ÖZGEÇMİŞ……... 69

ÖZET

GÖRSEL - İŞİTSEL UYARANLAR KAYNAKLI OLUŞAN DUYGULARIN EEG İŞARETLERİ İLE SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Hasan POLAT

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

2016

Duygular, insanların birbirleriyle haberleşmesinde oldukça önemli rol oynarlar. Duyguların insanların kelimelerine, ses tonlarına, yüz ifadelerine veya beden diline yansıdığı görülebilmektedir. Ancak, Beyin Bilgisayar Arayüzü (BBA) sistemleri, insanların içinde bulundukları duygu durumlarını yorumlamada henüz istenen seviyeye ulaşmamıştır.

BBA sistemlerince duyguların robotik ortamda anlaşılabilinmesi için insanlardan alınabilen ve yine bu sistemlerce işlenebilen kaynaklara ihtiyaç vardır. Elektroensefalogram (EEG) işaretleri, bu amacı gerçekleştirebilmek için önemli kaynaklardan biridir.

Bu çalışmada, görsel-işitsel uyaranlar kaynaklı oluşan farklı duygu durumlarına ilişkin EEG işaretlerinin sınıflandırılması amaçlanmıştır. Katılımcıların duygu durumlarını belirlemek için SAM (Self Assessment Manikins) görselleri kullanılmıştır. Katılımcılar, sunulan görsel-işitsel uyaranları değerlik, baskınlık, aktivasyon ve beğenme açısından değerlendirmişlerdir. Bu değerlendirmelere göre katılımcıların pozitif ve negatif duygu durumlarına ilişkin EEG işaretleri sınıflandırılmıştır. EEG işaretlerinden ayrık dalgacık dönüşümü (ADD) kullanılarak öznitelik çıkarımı yapılmıştır. ADD kullanılarak elde edilen öznitelik vektörler boyutlarının azaltılması için istatistiksel işlemler uygulanmıştır. Sınıflandırıcı olarak ise yapay sinir ağları ve k-en yakın komşu algoritmaları uygulanmış ve her iki algoritma için elde edilen sınıflandırma başarıları karşılaştırılmıştır.

Anahtar Kelimeler: EEG, Sınıflandırma, Duygu, Dalgacık Dönüşümü, Yapay Sinir Ağları, K-En Yakın Komşu

ABSTRACT

CLASSIFICATION OF EMOTIONS BASED ON AUDIO-VISUAL STIMULUS BY EEG SIGNALS

MsC THESIS

Hasan POLAT

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

2016

Emotions play an important role in communication between humans. Emotions can be reflected through words, voice intonation, facial expression and body language. In contrast, Brain Computer Interface (BCI) systems have not reached the desired level to interpret the people's emotions.

BCI systems need new resources that can be taken from humans and processed by these systems to understand emotions. Electroencephalogram (EEG) signals is one of the most important resources to achieve this target.

The aim of this study was to classify EEG signals related to different emotions based on audio-visual stimulus. SAM (Self Assessment Manikins) was used to determine participants' emotional states. Participants rated each audio-visual stimulus in terms of the level of valence, arousal, like/dislike and dominance. EEG signals that related to positive and negative emotion states have been classified according to participants' ratings. Discrete wavelet transform (DWT) was used for feature extraction from EEG signals. Wavelet coefficients of EEG signals were assumed as feature vector and statistical features were used to reduce dimension of feature vector. In this study, different clusters consisting of EEG signals related to positive and negative emotions groups have been classified by artificial neural network and k-nearest neighborhood algorithm. The classification algorithms' performances have been compared.

Keywords: EEG**,** Classification, Emotions, Wavelet Transform, Artificial Neural Networks, K-Nearest Neighborhood

ÇİZELGE LİSTESİ

Çizelge No		Sayfa
Çizelge 1.1.	EEG işaretlerinin içerdikleri frekans bantları	3
Çizelge 3.1.	Katılımcıların yaş bilgileri	15
Çizelge 3.2.	EEG kanal numaraları ve etiketleri	18
Çizelge 3.3.	Bir katılımcının yapmış olduğu değerlendirmeler	20
Çizelge 3.4.	Yapay Sinir Ağının, Biyolojik Sinir Ağındaki karşılığı	34
Çizelge 3.5.	K=3 için en yakın komşuların sıralanması	43
Çizelge 4.1.	Detay katsayılarının seviyelerine göre bulundukları frekans aralıkları	49
Çizelge 4.2.	Örnek bir karışıklık matrisi	54
Çizelge 4.3.	Bir katılımcı için kanallara göre sınıflandırma başarı oranları	55
Çizelge 4.4.	22 katılımcı için YSA sınıflandırma başarıları ve gizli katman nöron sayısı	58
Çizelge 4.5.	22 katılımcı için kNN sınıflandırma başarıları	60

ŞEKİL LİSTESİ

Şekil No		Sayfa
Şekil 1.1.	İnsan kafatasının farklı bölgelerinden ölçülen örnek EEG işaretleri	2
Şekil 1.2.	EEG işaretlerinin alt frekans bantları	4
Şekil 1.3.	10 – 20 Elektrot Yerleşim Sistemi	6
Şekil 1.4.	EEG tabanlı BBA sistemi	8
Şekil 3.1.	EEG kayıtlarının alınmasında izlenen paradigma	16
Şekil 3.2.	Deney öncesi bir katılımcı	16
Şekil 3.3.	Kullanılan elektrotların 10 – 20 sistemine göre yerleşimi	17
Şekil 3.4.	Kullanıcılara sunulan SAM (Self Assessment Manikins) görselleri	19
Şekil 3.5.	Kısa Zaman Fourier Dönüşümü	22
Şekil 3.6.	Dalgacık dönüşümü	22
Şekil 3.7.	Sinüs dalgası ile Daubechies dalgacığı	23
Şekil 3.8.	Haar dalgacığı	24
Şekil 3.9.	Meksika Şapkası dalgacığı	25
Şekil 3.10.	Morlet dalgacığı	25
Şekil 3.11.	Daubechies dalgacıkları	26
Şekil 3.12.	Sinyalin yaklaşım ve detay bileşenlerine ayrıştırılması	27
Şekil 3.13.	Sinyalin bir seviyeli yaklaşım ve detay dalgacık katsayılarına ayrıştırılması	28
Şekil 3.14.	Sinyalin çok seviyeli bileşenlerine ayrıştırılması	29
Şekil 3.15.	Sinir sisteminin blok diyagramı	30
Şekil 3.16.	Biyolojik bir sinir hücresi ve bileşenleri	31
Şekil 3.17.	Yapay bir sinir hücresi	32
Şekil 3.18.	Sık kullanılan Aktivasyon Fonksiyonları (a) Tek Kutuplu Sigmoid (b) Doğrusal (c) Hiperbolik Tanjant (d) Keskin Sınırlayıcı	33
Şekil 3.19.	İleri beslemeli YSA yapısı	35
Şekil 3.20.	Geri beslemeli YSA yapısı	35
Şekil 3.21.	YSA' da öğrenme metotları	36

Şekil 3.22. Danışmanlı öğrenme blok diyagramı 37

Şekil 3.23. Danışmansız öğrenme blok diyagramı 37

Şekil 3.24. Takviyeli öğrenme blok diyagramı 38

Şekil 3.25. Çok katmanlı YSA 39

Şekil 3.26. kNN sınıflandırma süreci 40

Şekil 3.27. Eğitim verisi üyelerinin bilinen sınıflara atanması 42

Şekil 3.28. Uzaklıkların hesaplanması 42

Şekil 3.29. Bilinmeyen nesnenin sınıflandırılması 43

Şekil 4.1. Sınıflandırma için izlenen işlem aşamaları 45

Şekil 4.2. SAM görsellerinden değerlik paneli 46

Şekil 4.3. Pozitif duygu durumuna ilişkin EEG işareti 47

Şekil 4.4. Negatif duygu durumuna ilişkin EEG işareti 47

Şekil 4.5. EEG sinyalinin 4 seviyeli yaklaşım ve detay katsayılarının elde edilmesi 48

Şekil 4.6. Pozitif duygu durumuna ilişkin örnek EEG işareti 49

Şekil 4.7. Örnek EEG işaretinin teta bandına ait dalgacık katsayıları 49

Şekil 4.8. Negatif duygu durumuna ilişkin örnek EEG işareti 50

Şekil 4.9. Örnek EEG işaretinin teta bandına ait dalgacık katsayıları 50

Şekil 4.10. Sınıflandırma işlemleri için kullanılan kanal seçim mekanizması 52

Şekil 4.11. Çalışmada Kullanılan Çok Katmanlı YSA mimarisi (25 x n x 2), n değeri gizli katmandaki nöron sayısını belirtir 53

Şekil 4.12. Örnek katılımcı için en iyi sınıflandırma performansı sunan beş EEG kanalı 56

Şekil 4.13. Nihai öznitelik vektörlerinin belirlenmesi 57

KISALTMA VE SİMGELER

w_i : Ağırlıklar

x_i : Girişler

y_i : Çıkışlar

θ_j : Eşik değeri

µV : Mikro volt

a : Ölçekleme faktörü

ADD : Ayrık dalgacık dönüşümü

Ag : Gümüş

AgCI : Gümüş Klorür

ANFIS : Uyarlamalı sinirsel bulanık denetim sistemi

b : Öteleme parametresi

BBA : Beyin bilgisayar arayüzü

cA1 : Birinci seviye yaklaşım dalgacık katsayıları

cD1 : Birinci seviye detay dalgacık katsayıları

d : Uzaklık

db4 : Daubechies dalgacığı

DVM : Destek vektör makineleri

EEG : Elektroensefalogram

EKG : Elektrokardiyogram

EMG : Elektromiyograf

EOG : Elektrookülograf

f(n) : Aktivasyon fonksiyonu

fMRI : Fonksiyonel manyetik rezonans görüntüleme

fs : Örnekleme frekansı

GHZ : Giga Herz

GSR : Galvanik deri tepkisi

GSY : Güç Spektral Yoğunluk

h[n] : Yüksek geçiren filtre

Hz : Frekans

KFZD : Kısa zaman Fourier dönüşümü

kNN	: K-en yakın komşu
LVQ	: Learning vector quantization
MEG	: Magnetoensefolografi
MLP	: Multi Layer Perceptron
SAM	: Self assessment manikins
SCR	: Tek hücre kayıtları
SDD	: Sürekli dalgacık dönüşümü
SOM	: Self organizing map
α	: Alfa
β	: Beta
γ	: Gamma
δ	: Delta
θ	: Teta
$\psi(x)$	: Dalgacık fonksiyonu

1. GİRİŞ

İnsanlar varoluşlarından beri diğer insanların duygu durumlarını anlamaya çalışmışlardır. İnsanlar gösterilen herhangi bir davranışın ne ifade ettiğini anlamaya ve bununla birlikte birbirleriyle olan etkileşimlerini geliştirmeye gayret göstermişlerdir.

Duygular, insanların birbirleriyle olan etkileşimlerinde oldukça önemli rol oynarlar. İnsanlar, içinde bulundukları duygu durumlarını kelimeler, ses tonları, yüz ifadeleri ve beden dili gibi birçok işaretle ifade edebilirler.

Beyin Bilgisayar Arayüzü (BBA) sistemleri, insanların içinde bulundukları duygu durumlarını yorumlamada henüz istenen seviyeye ulaşmamıştır. BBA sistemlerince duyguların robotik ortamda anlaşılabilinmesi için insanlardan alınabilen ve yine bu sistemlerce işlenebilen kaynaklara ihtiyaç vardır. Elektroensefalogram (EEG) işaretleri, bu amacı gerçekleştirebilmek için önemli kaynaklardan biridir.

Bu çalışmada, farklı duygu durumlarına ilişkin EEG işaretlerinin sınıflandırılması amaçlanmıştır. Çalışma, EEG tabanlı farklı özniteliklerin farklı sınıflandırma algoritmaları ile sınıflandırılmasına dayanmaktadır.

Bu bölümde konunun daha iyi anlaşılması açısından, temel olarak EEG işaretleri ve alt bantları, EEG ölçümleri ve duygu olgusu hakkında kısaca bilgi verilmiştir.

1.1. EEG İşaretleri, Alt Bantları ve Ölçümü

a) EEG İşaretleri

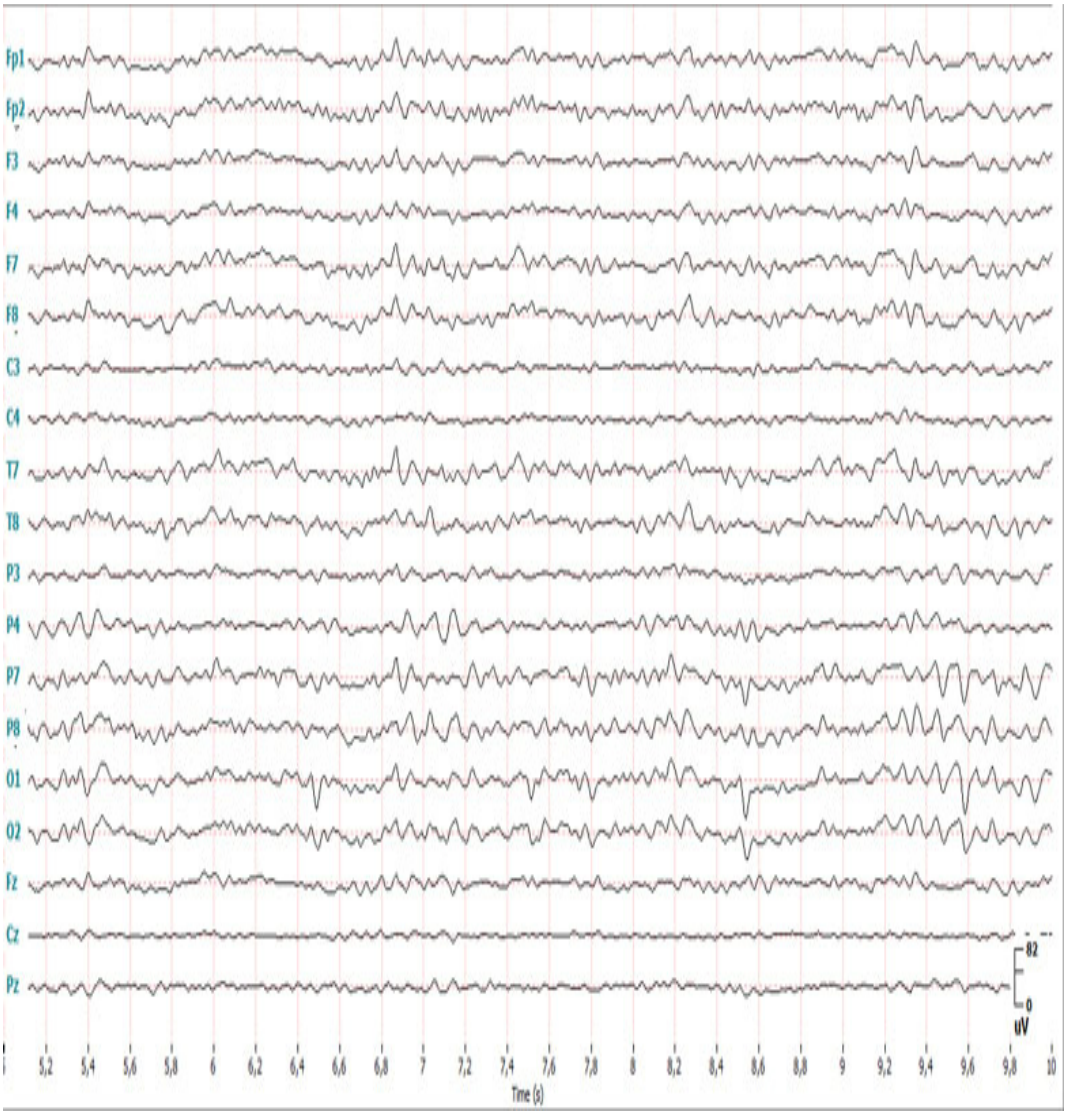
Beyin içerisinde aktif sinir hücrelerinin elektriksel aktiviteleri sonucu akımlar oluşur. Oluşan bu akımların kafatası yüzeyine yansıması ve yüzeyde meydana getirdikleri gerilim değişimlerinin kayıt edilmesiyle elde edilen işaretlere, Elektroensefalogram (EEG) işaretleri denir (Adeli ve ark. 2003).

EEG işaretleri ile ilgili tarihte ilk olarak 1875 yılında Caton, hayvanlar üzerinde yapmış olduğu çalışmalar neticesinde beyinde bir takım elektriksel aktivitelerin var olduğu göstermiştir. 1929 yılında ise Hans Berger, hazırladığı bir düzenekle insan beynindeki elektriksel faaliyetleri, kafatası yüzeyine yerleştirdiği elektrotlar ve bu elektrotlara bağlı bir galvanometre yardımıyla ortaya çıkarmıştır. Sonrasında Hans Berger, 1930 yılında gözlerin açılıp kapanmasıyla EEG işaretinde değişimlerin

oluştuğunu göstermiştir. Ayrıca Berger alfa ritimlerinin EEG işaretlerinin başlıca bileşenleri olduğunu savunmuştur. (Sanei ve Chambers 2007).

Beyin potansiyellerini kayıt edebilmek için ilk kuvvetlendiriciler Berlin'de ve sonrasında EEG işaretlerini kayıt edebilmek için çeşitli kuvvetlendiriciler Rockefeller şirketi tarafından üretilmiştir.

Gelişen elektronik ve bilgisayar teknolojisiyle birlikte, EEG işaretlerinin analizinde de gerek kullanılan araçlar açısından gerekse de kullanılan yöntemler açısından büyük gelişimler sağlanmıştır. Günümüzde EEG işaretlerinin analizleri başta klinik araştırmalar olmak üzere birçok alanda yapılmaktadır. Şekil1.1.'de insan kafatasının farklı bölgelerinden kayıt edilen örnek EEG işaretleri gösterilmiştir.



Şekil 1.1. İnsan kafatasının farklı bölgelerinden ölçülen örnek EEG işaretleri

Şekil 1.1.'de gösterilen örnek EEG kaydında, her bir satırda yer alan değişim bir kanalı ifade eder. Grafikte x ekseni saniye cinsinden zamanı ifade ederken, y ekseni ise mikrovolt cinsinden gerilimi ifade eder.

b) EEG İşaretlerinin Alt Bantları

EEG işaretleri durağan olmayan özellikler gösteren sinyallerdir. Genlik, faz ve frekans bileşenleri sürekli değişkenlik göstermektedirler. Özellikle EEG işaretlerinin frekans bileşenleri beyin fonksiyonları hakkında oldukça önemli bilgiler içerir. EEG işaretlerinin belirli frekans bantları araştırmacılara önemli bilgiler sunacak dalga biçimleri kapsamaktadır (Subaşı ve Erçelebi 2004). EEG işaretlerinin içerdiği belirli alt bantların, beynin fonksiyonları ile yakın ilişkide olduğu birçok çalışmada gösterilmektedir [(Adeli ve ark. 2003), (Subaşı ve Erçelebi 2004), (Koelstra ve ark. 2012), (Liu ve ark. 2014)]. EEG işaretlerinin içerdikleri önemli alt bantlar ile bu bantların frekans aralıkları Çizelge 1.1.'de verilmiştir.

Çizelge 1.1. EEG işaretlerinin içerdikleri frekans bantları

Delta (δ)	**0.5 – 4 Hz**
Teta (θ)	**4 – 8 Hz**
Alfa (α)	**8 – 14 Hz**
Beta (β)	**14 – 30 Hz**
Gamma (γ)	**30 – 100 Hz**

Delta Dalgaları ***(δ)*** : Frekansı 4 Hz' in altındaki yavaş işleyen beyin aktiviteleri sonucu oluşan dalgalardır. Yetişkinlerde derin uyku hallerinde ve süt çocuklarında görülür (Adeli ve ark. 2003).

Teta Dalgaları (**θ**) :Frekans aralığı 4 ile 8 Hz arasında olup, normal bebeklerde ve çocuklarda görülür. Yetişkinlerde ise uyuşukluk halinde olmakla birlikte seyrek bir

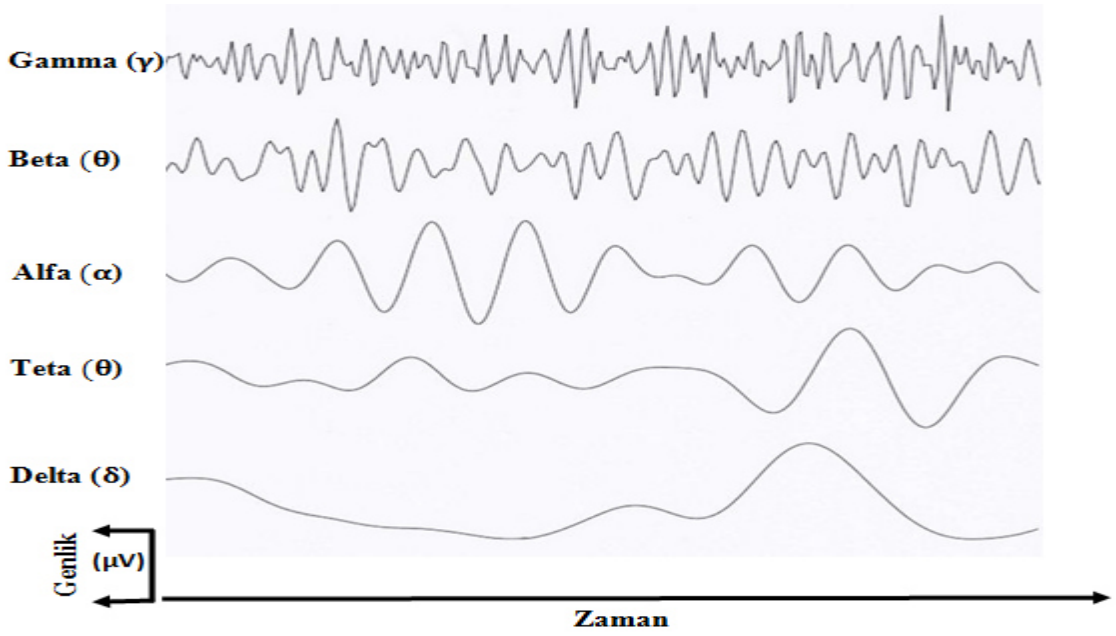
şekilde uyanık hallerde de görülür. Duygusal gerginlik gibi durumlarda ortaya çıkabilirler. Genlikleri 100 μV (p - p)' den küçüktür (Adeli ve ark. 2003).

Alfa Dalgaları (**α**) : Frekans aralığı 8 ile 14 Hz aralığında olan beyin dalgalarıdır. Alfa bandı ritimleri normal yetişkinlerde dinlenme halinde ve hafif uykulu durumlarda görülür. Genlikleri genel olarak 50 μV altındadır. Alfa dalgaları oksipital bölgede belirgin şekilde gözlenebilinir. Gözler açık durumda olduğunda ya da derin düşüncelere dalındığında bu dalgaların oluşumu engellenir (Adeli ve ark. 2003).

Beta Dalgaları (**β**) : Frekans aralığı 14 ile 30 Hz arasında olan dalgalardır. Beta dalgaları çoğunlukla beynin ön tarafında daha baskınlık gösterirler. Alfa dalgalarına göre daha yüksek frekanslı ve daha düşük genliğe sahip olan dalgalardır. Problem çözme ve hatırlama anlarında iyice belirginleşirler. Ayrıca kahve, enerji içecekleri gibi çeşitli uyarıcılar alındığında beta dalgalarında aktifleşme artar [(Yazgan 1996), (Adeli ve ark. 2003)].

Gamma Dalgaları (**γ**) : Frekansı 30 Hz üzerinde olan dalgalardır. Bu frekans aralığındaki dalgalar genellikle klinik çalışmalar dışında kullanılır. Dolayısıyla birçok uygulamada EEG kayıtlarından bu dalgalar filtrelenir (Adeli ve ark. 2003).

Yukarıda sözü edilen alt bantların örnek EEG bileşenleri Şekil 1.2.'de gösterilmiştir.



Şekil 1.2. EEG işaretlerinin alt frekans bantları

c) EEG İşaretlerinin Ölçümü

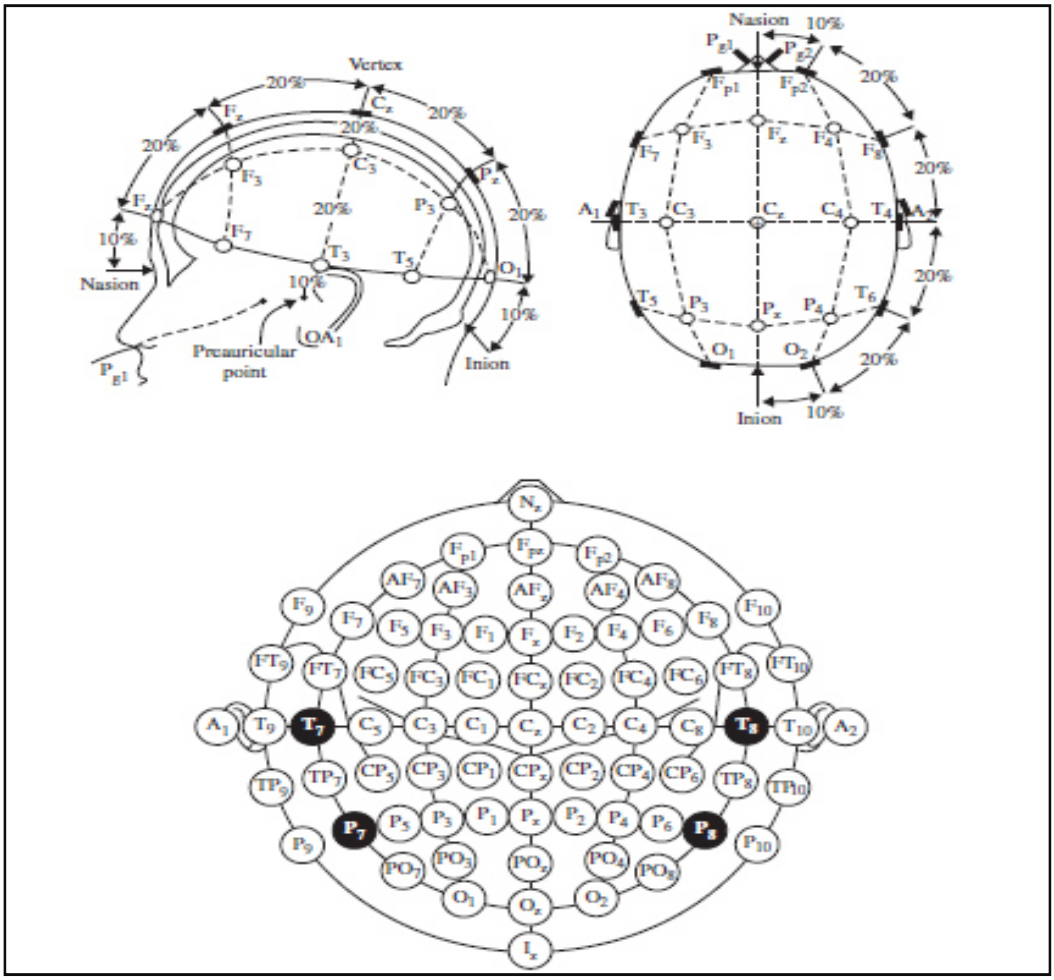
İnsan bedeninden alınan sinyaller ve görüntüler, klinik çalışmalarda hastalıkların önceden teşhisi açısından hayati öneme sahiptir. Tanı amaçlı sıklıkla insan bedeninden ölçülen işaretler; kalpten alınan elektrokardiyogram (EKG), kaslardan alınan elektromiyograf (EMG) ve beyinden alınan elektroensefalogram (EEG) işaretleridir (Sanei ve Chambers 2007).

Bu çalışmada olduğu gibi beyin içerisinde meydana gelen fonksiyonel ve psikolojik değişimlerin analizi için EEG işaretleri kullanılmaktadır. Geçmişte beyin hücreleri aktivitelerinin basit bir galvanometre yardımıyla kayıt edilişinden günümüze gelindiğinde, bilim insanları tarafından EEG işaretlerinin kayıt edilişinde gelişmiş sistemlerin kullanıldığı görülmektedir.

Günümüzde kullanılan EEG kayıt sistemleri, hassas elektrotlardan oluşmaktadır. Kayıt edilen EEG işaretlerinin sayısallaştırılıp ve depolanması bu sistemlerce gerçekleştirilmektedir. EEG işaretlerinin sayısallaştırılması ve depolanabilinmesi, araştırmacılar için bu işaretler üzerinde daha iyi analizler yapılmasını mümkün kılmıştır (Sanei ve Chambers 2007).

Yüksek kalitede EEG kayıtları için kullanılan elektrotlar ve elektrotların konumları oldukça önemlidir. Bu çalışmada da kullanılan EEG işaretleri gibi çok kanalı EEG işaretlerinin kayıt edilişinde, genellikle elektrot şapkaları kullanılır. Kullanılan elektrotlar gümüş – gümüş klorür (Ag – AgCI) disklerinden oluşur.

EEG elektrotlarının bağlantı şekillerinde uluslar arası standartlar kullanılır. En çok kullanılan 10 – 20 elektrot yerleşim sistemidir. Bu yerleşme düzeninde baş dört standart noktayla işaretlenmiştir. Bunlar burun (nasion), başın arka kısmı (inion), sol ve sağ kulak arkalarından (preauriculars) kısımlarından oluşur. Elektrotlar burun ve başın arka kısmı arasına % 10 - 20 - 20 - 20 - 20 - 10 olacak şekilde yerleştirilir (Sanei ve Chambers 2007). Şekil 1.3.'de 75 elektrottan oluşan uluslar arası 10 – 20 elektrot yerleşim sistemi görülmektedir. Bu bağlantı şekillerine ayrıca göz kapağı ve gözü çevreleyen kaslardan gelen sinyalleri ölçmek içinde ekstra elektrotlar bağlanabilinir.



Şekil 1.3. 10 – 20 Elektrot Yerleşim Sistemi (Sanei ve Chambers 2007).

1.2. Duygu Olgusu ve EEG Ölçümleri ile Duyguların Ayrıştırılmasında İzlenen Temel Yaklaşım

Duygu, bireyin iç ve dış çevresinden gelen uyaranlarla etkileşimi sonucu ruh halinde meydana gelen karmaşık psikofizyolojik bir değişim olarak nitelendirilebilir (Akçay ve Çoruk 2012).

Duygular, insanların aklını ve günlük faaliyetlerini etkileyen en önemli faktörlerden biridir. Duygular, insanların birbirleriyle olan etkileşimlerinde oldukça önemli rol oynarlar. İnsanlar, içinde bulundukları duygu durumlarını kelimeler, ses tonları, yüz ifadeleri ve beden dili gibi birçok işaretle ifade edebilmektedirler.

Beyin bilgisayar arayüzü, insanların motor sinir sistemlerini kullanmaksızın sadece beyin işaretleriyle bilgisayar gibi çeşitli cihaz ve uygulamaları kullanabildiği

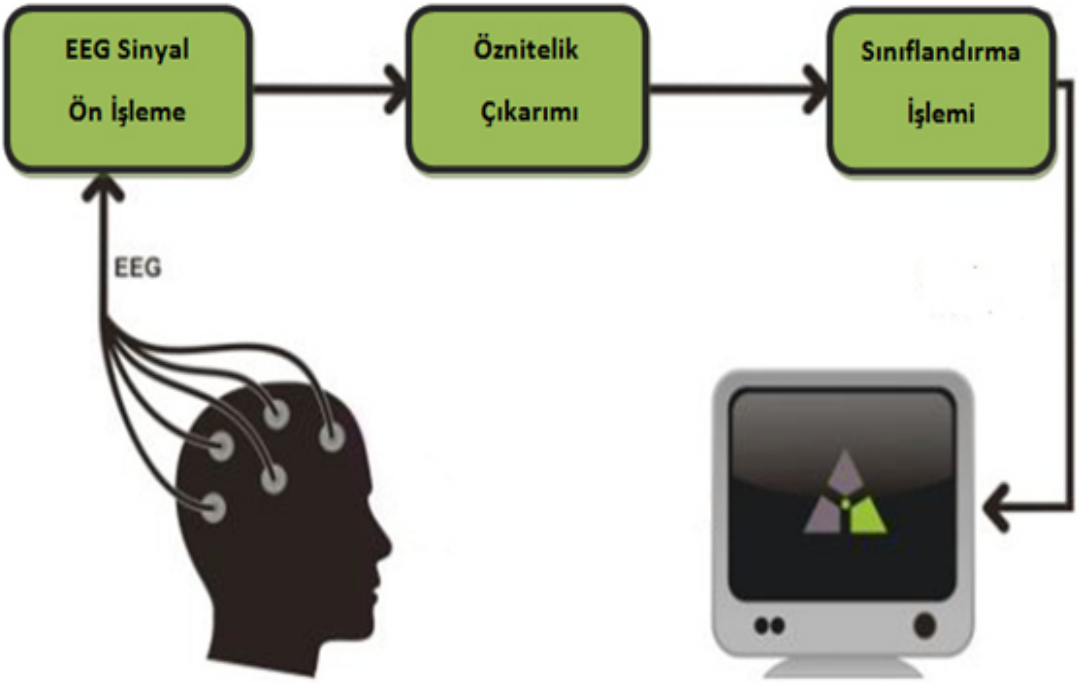
sistemlerin genel adıdır. BBA sistemleri, kullanıcılar ile dış dünya arasında güçlü haberleşme köprülerini oluşturmaktadırlar (Wolpaw ve ark. 2002).

İnsanlar ilk olarak BBA sistemlerini biyomedikal alanda geliştirmişlerdir (Sarah ve ark. 2015). Yapılan ilk çalışmalar, felçli hastalar için çeşitli nöroprotezleri kullanılması amaçlanmıştır (Wolpaw ve ark 2003).

Geçmişten günümüze gelindiğinde BBA sistemlerince insanların duygu durumlarının tespit edilebilmesi oldukça önem kazanmıştır. Fakat EEG ölçümleri ile gerçeklenen beyin bilgisayar arayüzü (BBA) sistemleri, insanların içinde bulundukları duygu durumlarını yorumlamada henüz beklenileni karşılamamaktadır.

EEG işaretlerinin çabuk erişebilinir olması, pratik olması ve kayıt edilişinin maliyet açısından diğer yöntemlere göre ucuz olması gibi avantajlarından dolayı EEG tabanlı BBA sistemlerinin kullanım yaygınlığı artış göstermektedir. EEG tabanlı BBA sistemleri dışında, tek hücre kayıtları (SCR), magnetoensefalografi (MEG) ve fonksiyonel manyetik rezonans görüntüleme (fMRI) gibi tekniklerde BBA sistemlerini geliştirmede kullanılmaktadır.

Şekil 1.4.'de EEG tabanlı BBA sistemi görülmektedir. Bu genel yaklaşım modeli ile duyguların ayrıştırılması sağlanabilmektedir. Ayrıca hastalıkların tanısında, bilgisayar oyunlarında ve günümüzde ön plana çıkan reklamcılık sektöründe görülebilmektedir. Şekilden görüldüğü üzere, ölçülen EEG verileri çeşitli filtrelerden geçirilerek çalışılmak istenen alt bant(lar) elde edilir (önişlem). Ardından verinin boyutu büyük olması nedeniyle, nöral aktiviteden öznitelik çıkarılarak boyut indirgeme işlemi yapılır. Son olarak da elde edilen öznitelikler ile sınıflandırma işlemi yapılır. Her aşamada farklı yöntemlerin ve her yöntemin farklı alternatiflerinin olduğu literatürden görülmektedir.



Şekil 1.4. EEG tabanlı BBA sistemi

2. KAYNAK ÖZETLERİ

Literatürde EEG analizi kapsamında çok çeşitli çalışmaların yapıldığı görülmektedir. Bu çalışmalar kabaca sağlık, reklam ve oyun olmak üzere üç farklı çatıda toparlanabilir. Bu çatılar kapsamında yer alan çalışmalar aşağıda kısaca belirtilmiştir.

1) Sağlık alanında yapılan çalışmalar çoğunlukta olması nedeniyle, bu alan kendi içinde üç bölümde incelenebilir.

a) Hekimlere hastalıkların tanısında destek sağlamak amacıyla yapılan çalışmalar olarak değerlendirilebilir. Örneğin, Epilepsi, Alzheimer ve Bipolar gibi hastaların EEG kayıtları ile normal kişilerin EEG kayıtları karşılaştırılarak aralarındaki farklılıklar saptanmaktadır. Bu kapsamda, hekimler ve biyomedikal mühendisleri görev almaktadırlar. Farklılıklar hastalıklar ile ilişkilendirilmektedir ve dolayısıyla hastalıklar saptanmaktadır. Konuya ilişkin yapılmış bazı literatür çalışmaları aşağıda belirtilmiştir

Subaşı ve Erçelebi (2005), sağlıklı insanlara ve epilepsi hastalarına ait EEG işaretlerini, yapay sinir ağı ve lojistik regresyon algoritmaları kullanarak sınıflandırmışlardır. Çalışmada, EEG işaretlerinin öznitelik vektörlerini elde etmek için dalgacık dönüşümü uygulanmıştır. Dalgacık dönüşümü için Dabuechies dalgacığı (db4) seçilmiştir. Yapay sinir ağı kullanarak % 92 oranında sınıflandırma doğruluğu elde etmişlerdir.

Subaşı (2007), EEG işaretlerini sınıflandırmada, sağlıklı insanlara ve epilepsi hastalarına ait EEG kayıtlarını kullanmıştır. EEG işaretlerinden öznitelik vektörlerini elde etmek için dalgacık dönüşümü ve istatistiksel işlemler uygulamıştır. Sınıflandırıcı algoritması olarak birleştirilmiş bir yapay sinir ağı modeli kullanmıştır. Subaşı (2007) tarafından yapılan çalışmada, birleştirilmiş yapay sinir ağı modeli kullanılarak sınıflandırma başarısı arttırılmış ve sınıflandırma doğruluğu % 94.5 olarak elde edilmiştir. Ayrıca bu çalışmada, sınıflandırma işlemi için farlı dalgacıklar kullanılarak en iyi sonucun Dabuechies dalgacığı ile sağlandığı gözlemlenmiştir.

Orhan ve ark. (2011), sağlıklı insanlara ve epilepsi hastalarına ait EEG işaretlerini sınıflandırmak için çok katmanlı perceptron yapay sinir ağı ile k-ortalama algoritmasını birlikte kullanmışlardır. Çalışmada, EEG işaretlerinin öznitelik

vektörlerini belirlemek için dalgacık dönüşümü ve istatistiksel işlemler uygulanmıştır. Dalgacık analizi için Dabuechies dalgacığı kullanılmıştır. Sağlıklı insanlardan ve epilepsi hastalarından alınan EEG işaretlerinin sınıflandırılmasında % 100 oranında doğruluk elde etmişlerdir.

b) Beynin bölgeleri arasındaki ilişkilerin saptanması üzerine yapılan çalışmalardır. Bu kapsamda, nörologlar, biyofizikçiler ve işaret işleme uzmanları görev almaktadırlar. Kişilere (hasta/normal) farklı paradigmalar uygulanarak EEG kayıtları alınır ve EEG alt bantlarına ayrıştırılır. Ardından, beyin bölgeleri arasındaki iletişim frekans bileşenleri açısından incelenir. Konuya ilişkin yapılmış bazı literatür çalışmaları aşağıda belirtilmiştir.

Wada ve ark. (1998), sağlıklı kişiler ve Alzheimer hastalarından EEG kayıtları alarak, iki grup için beyin bölgeleri arasındaki fonksiyonel uyumluluğu karşılaştırmışlardır. Çalışmada, beynin farklı bölgelerinden alınan EEG kayıtlarına ilişkin farklı alt bantların frekans dinamikleri incelenerek, beynin bölgeleri arasındaki uyumluk ölçülmeye çalışılmıştır. Alzheimer hastaları için beynin frontal ve central bölgeleri arasında alfa ve beta bandındaki uyumluluğun sağlıklı kişilerle kıyaslandığında düşük olduğu gözlemlenmiştir.

Klimesch (1999), zihinsel aktiviteleri incelemek için beynin farklı bölgelerinden kayıt edilen EEG işaretlerinin alfa ve teta bandı dinamiklerini analiz etmiştir. Çalışmada yeni bir bilginin kodlanması beynin hipokampus bölgesinde teta bandı dinamikleri, uzun süreli hafıza işlemleri ise beynin talamus bölgesinde alfa bandı dinamikleri tarafından yansıtıldığı gösterilmiştir.

Hogan ve ark. (2003), normal kişilerden ve Alzheimer hastalarından belirli bir paradigma çerçevesinde EEG kayıtları alarak, beynin farklı bölgelerinden üretilen EEG işaretlerinin birbirleriyle olan farklılıkları incelemişlerdir. Çalışmada, beynin farklı bölgelerinden alınan EEG kayıtlarına ilişkin farklı alt bantların güç spektrumları ve birbirleriyle olan senkronizasyonları analiz edilmiştir. Alzheimer hastalarından alınan EEG kayıtlarının alfa bandındaki güç spektral yoğunluğun sağlıklı kişilerle kıyaslandığında, daha büyük genlikte olduğu ve bu farklılıkların beynin merkez bölgesinde gerçekleştiği görülmüştür. Beynin merkez bölgesinin aksine temporal bölgeden alınan EEG kayıtlarında ise alfa bandında farlılıklar görülmemiştir.

c) Beynin paradigmalara göre hareketliliğini imgeler üzerinden inceleyen çalışmalar bu kapsamda değerlendirilebilir. Konuya ilişkin yapılmış bazı literatür çalışmaları aşağıda belirtilmiştir.

Bajaj ve Pachori (2013), EEG işaretlerini kullanarak uyku evrelerini zaman-frekans görüntüleme tabanlı olarak sınıflandırmışlardır. Çalışmada, EEG işaretlerinin zaman- frekans görüntüleri, alt bölütlere ayrıştırılmış ve işaretlerin önemli alt bantlarında zaman-frekans görüntüleri elde edilmiştir. Elde edilen görüntülerin gri seviye histogramından öznitelik vektörleri çıkarılmıştır. Uyku evrelerinin sınıflandırılmasında maksimum olarak % 92.93 oranında doğruluk elde edilmiştir.

Fu ve ark. (2014), sağlıklı kişilerden ve epilepsi hastalarından epileptik nöbet esnasında kayıt edilen EEG işaretlerini, gri tonlama yöntemi ile elde ettikleri öznitelik vektörlerini kullanarak sınıflandırmışlardır. EEG işaretlerinin farklı bantlarda zaman - frekans dağılımını gri tonlama ile imgeleştirmişlerdir. Sınıflandırıcı algoritma olarak ise destek vektör makinelerini kullanmış ve en iyi sonucu teta bandı dinamiklerinden çıkarttıkları özniteliklerle elde etmişlerdir.

2) (Reklam Sektörü) Ürünler ile ilişkili çekilen resim ve/veya videoların kişilere izlettirilerek, doğrudan EEG kayıtları üzerinden reklamın etkisi saptanmaya çalışılır. Konuya ilişkin yapılmış bazı literatür çalışmaları aşağıda belirtilmiştir.

Schaaff ve Schultz (2009), yapmış oldukları çalışmada 3 farklı duygu durumunu EEG işareti kullanarak sınıflandırmışlardır. Kullanılan EEG işaretleri 5 erkek katılımcıdan alınmıştır. Katılımcılardan alınan EEG işaretleri, farklı duygular uyandıracak resimler sunularak kayıt edilmiştir. Katılımcılara sunulan görsel uyarıcılar sonunda, katılımcıların duygu durumlarını değerlendirmeleri için SAM (Self Assessment Manikins) görselleri kullanılmıştır. Katılımcılar, duygu durumlarını SAM görsellerine göre aktivasyon ve değerlik açısından değerlendirmişlerdir. Çalışmada, sınıflandırıcı algoritması olarak destek vektör makineleri (DVM) kullanılmış ve % 66.7 oranında sınıflandırma doğruluğu elde edilmiştir.

Lin ve ark. (2010), EEG tabanlı olarak dört farklı duygu durumunu sınıflandırmışlardır. Katılımcılarda fark duyguların uyandırılması için işitsel uyarıcılar kullanılmıştır. Farklı duygu durumlarına ait EEG işaretleri, katılımcılara farklı müziklerin dinletilmesiyle kayıt edilmiştir. Öznitelik vektörleri olarak EEG işaretinin

farklı frekans alt bantları ele alınmıştır. Sınıflandırıcı algoritma olarak destek vektör makineleri kullanılmış ve maksimum sınıflandırma doğruluğunu % 82.29 olarak elde etmişlerdir.

Petrantonakis ve Hadjileontiadis (2010), yapmış oldukları çalışmada altı farklı duygu durumuna ait EEG işaretlerini çeşitli sınıflandırıcı algoritmalarıyla sınıflandırmışlardır. Kullandıkları veri setini oluşturan EEG işaretleri, kişilere farklı görsel uyarıcalar gösterilerek kayıt edilmişlerdir. EEG işaretlerinden öznitelik vektörlerini elde etmek için istatistiksel işlemler uygulamışlardır. Yapmış oldukları çalışmada, k-en kNN ve DVM gibi sınıflandırıcı algoritmaları kullanmışlardır. DVM ve kNN sınıflandırıcı algoritmalarını birlikte kullanarak zıt duygu durumlarını sınıflandırmışlardır. Sınıflandırma doğruluğunu ise % 73.94 olarak elde etmişlerdir.

Lee ve ark. (2014), görsel uyarıcılar aracılığıyla kişilerde oluşan farklı duygu durumlarına ait EEG işaretlerini farklı sınıflandırıcı algoritmalarıyla sınıflandırmaya çalışmışlardır. Kişilerde farklı duyguların uyandırılması için 30 saniyelik videolar kullanılmıştır. Katılımcılardan alınan farklı duygu durumlarına ait EEG kayıtları, pozitif ve negatif olarak sınıflandırılmaya çalışılmıştır. Sağ ve sol hemisfere ait EEG kayıtlarına kısa zaman fourier dönüşümünün (KFZD) uygulanmasıyla elde edilen frekans bantlarının güç spektral yoğunluğu (GSY) analiz edilmiştir. Sağ ve sol hemisferdeki EEG işaretlerinin güç yoğunluk farklılıkları aktivasyon değeri olarak değerlendirilmiştir. Pozitif ve negatif duygu durumlarını ANFIS (adaptive neuro fuzzy inference system – uyarlamalı sinirsel bulanık denetim sistemi) algoritması kullanarak sınıflandırmışlardır. Sınıflandırma doğruluğunu maksimum % 78.45 olarak elde etmişlerdir.

Wang ve ark. (2014), EEG tabanlı olarak farklı duygu durumlarını sınıflandırmaya çalışmışlardır. EEG işaretlerinin öznitelik vektörlerinin elde edilmesi için dalgacık dönüşümü, güç spektrum kestirimi ve doğrusal olmayan dinamikler yöntemlerini uygulamışlardır. Sınıflandırıcı olarak ise destek vektör makineleri (DVM) kullanmışlardır. Çalışmada kullanılan EEG işaretleri, 6 kişiden alınan kayıtlardan oluşmaktadır. Kişilerde farklı duygular uyandırmak için 4 dakikalık film sahneleri kullanılmıştır. Kişiler izledikleri film sahneleri sonunda duygu durumlarını SAM görselleri aracılığıyla belirtmişlerdir. Wang ve ark. (2014) tarafından dalgacık

dönüşümü ve destek vektör makineleri kullanılarak farklı duygu durumlarının sınıflandırılmasında maksimum % 78.41 sınıflandırma doğruluğu elde edilmiştir.

Polat ve Özerdem (2015), farklı hikayelerden kaynaklı oluşan duyguların EEG işareti üzerine olan yansımalarını incelemişlerdir. Çalışmada, EEG işaretlerinin önemli alt bantlarını kapsayan frekans aralığına inmek için dalgacık dönüşümünü kullanmıştır. İlgili frekans aralığına filtrelenen EEG işaretlerinin güç spektral yoğunlukları alınmıştır. Sonuç olarak farklı hikayelerden kaynaklı oluşan duyguların EEG işaretine olan yansıma oranlarının farklı düzeyde olduklarını ve bu değişimlerin özellikle 5-8Hz aralığında meydana geldiklerini göstermişleridir.

3) (Oyun Sektörü) Günümüz bilgisayar oyunlarında, joystick yerine EEG kayıtlarının kullanılmaya başlandığı görülebilmektedir. Konuya ilişkin yapılmış bazı literatür çalışmaları aşağıda belirtilmiştir.

Lopetequi ve ark. (2012), EEG işaretlerini kullanarak, bir bilgisayar tenis oyununda kişilerin klavye ve fare kullanmadan oyuncuyu yönlendirebilmelerini sağlayan bir çalışma yapmışlardır. Çalışmada ilk olarak katılımcıların oyun esnasında oyuncunun yapması gereken hareketlere odaklanmaları istenmiş ve eşzamanlı olarak EEG kayıtları alınmıştır. Kayıt edilen EEG işaretlerinden istenmeyen artefaktlar Butterworth filtresi kullanılarak kaldırılmış ve kısa zaman Fourier dönüşümü ile EEG işaretlerinden öznitelik vektörleri çıkarılmıştır. Katılımcıların oyunu oynadıkları sırada EEG işaretlerinin eş zamanlı olarak kayıt edilip ve analiz edilmesiyle, katılımcıların beyin aktiviteleri ile oyuncuyu yönlendirebilmeleri sağlanmıştır. 4 katılımcının katıldığı deneyde, bütün katılımcılar için oyun boyunca yapılan doğru hamleler baz alındığında % 80'in üzerinde başarı elde edilmiştir. Ayrıca katılımcıların oyun oynadıkları sırada EEG işaretlerinin frekans genliklerinin 8 -12 Hz aralığında daha yüksek genlikte seyrettiği gözlemlenmiştir.

Leeb ve ark. (2013), EEG işaretlerini kullanarak, bir bilgisayar oyununda kişilerin klavye ve joystick kullanmadan oyuncuyu yönlendirebilmelerini sağlayan bir çalışma yapmışlardır. Çalışmada, katılımcıların oyunda klavye ve joystick kullanarak elde ettikleri başarılar, klavye ve joystick kullanmadan elde ettikleri başarılarla kıyaslanmıştır. Sonuç olarak, insanların sadece beyin dalgaları ile oyun karakterini yönlendirebildiklerini göstermişlerdir.

Khong ve ark. (2014), BBA tabanlı bir bilgisayar oyunu tasarlamışlardır. Katılımcıların oyun oynadıkları sırada EEG kayıtlarını alarak, dikkat seviyelerini EEG işaretlerinden çıkardıkları özniteliklerle belirleyip, katılımcıların oyun performanslarını artırmaya çalışmışlardır. Çalışmada katılımcıların dikkat seviyeleri, EEG işaretlerinin frekans alt bantları güç yoğunluklarının hesaplanmasıyla belirlenmiştir. Alfa bandı güç yoğunluğu ile teta bandı güç yoğunluğu oranları belirlenmiştir.

Bu tez çalışmasında katılımcıların SAM (Self Assissment Manikins) görselleri aracılığıyla yapmış oldukları değerlendirmeler esas alınarak katılımcıların pozitif ve negatif duygu durumlarına ilişkin EEG işaretlerinin sınıflandırılması gerçekleştirilmiştir. Katılımcılardan alınan EEG işaretlerinden ayrık dalgacık dönüşümü (ADD) kullanılarak öznitelik çıkarımı yapılmıştır. ADD kullanılarak elde edilen öznitelik vektörlerinin boyutlarının azaltılması için istatistiksel işlemler uygulanmıştır. Sınıflandırıcı olarak ise yapay sinir ağları ve k-en yakın komşu algoritmaları uygulanmış ve her iki algoritma için elde edilen sınıflandırma başarıları karşılaştırılmıştır.

3. MATERYAL VE METOT

Bu çalışmada, farklı görsel - işitsel uyaranlar kaynaklı oluşan pozitif (mutlu, neşeli, vb.) ve negatif (üzgün, mutsuz, vb.) duygu durumlarına ilişkin EEG işaretlerinin sınıflandırılması amaçlanmıştır. Bu amacı gerçeklemek için kullanılan veri setinin özellikleri ve EEG işaretlerinin sınıflandırılması için tez kapsamında kullanılan yöntemlerin detayları açıklanmıştır.

3.1. Çalışmada Kullanılan Veri Seti

Bu tez çalışmasında 15'i kadın ve 17'si erkek gönüllü olmak üzere toplam 32 sağlıklı katılımcıdan alınan EEG kayıtları kullanılmıştır (DEAP 2012). Deneye katılan katılımcıların yaşa ilişkin detayları çizelge 3.1.'de verilmiştir.

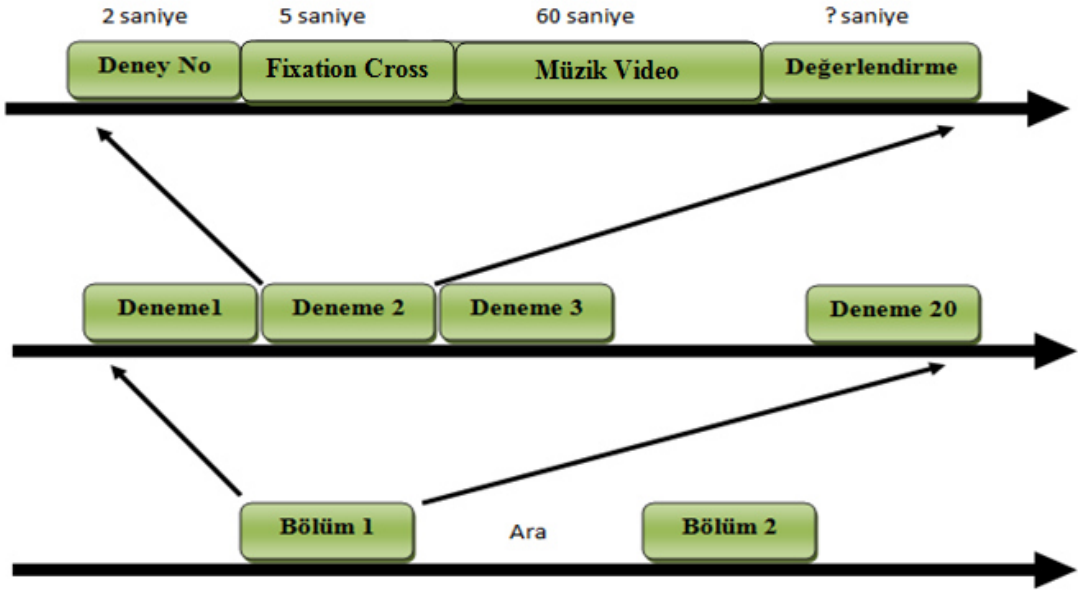
Çizelge 3.1. Katılımcıların yaş bilgileri

Yaş	Kadın	Erkek
Aralığı	[19 - 33]	[23 - 37]
Ortalama	25.4	28.76

Çalışmada kullanılan EEG işaretleri, her katılımcıya uygulanan belirli bir paradigma çerçevesinde kayıt edilmiştir. Paradigma, her biri 20 deneme içeren iki bölümden oluşmaktadır. Her deneme sırasıyla;

a) Katılımcıya 2 saniye boyunca ilgili deneme numarası hakkında bilgi veren video kaydının gösterimi
b) Katılımcının sunulacak müzik videosu öncesi dikkatinin hazır için 5 saniye boyunca önceden kayıtlı videonun gösterimi
c) Her denemede farklı olmak üzere rastgele seçilen 60 saniyelik sesli müzik videosunun izletilmesi
d) Katılımcının deneme sonunda izlediği müzik videosunun kendisinde uyandırdığı duygu durumunu değerlik, aktivasyon, baskınlık ve beğenme açışından değerlendirmesi

olmak üzere dört aşamadan oluşmaktadır. Şekil 3.1.'de EEG verilerinin kayıt edilişinde izlenen paradigma gösterilmiştir.



Şekil 3.1. EEG kayıtlarının alınmasında izlenen paradigma

Şekil 3.1.'de görüldüğü gibi EEG işaretlerinin kayıt edilişi iki bölümden oluşmaktadır. Her bölümde 20 deneme gerçekleştirilmiş ve her iki bölüm arasında bir ara verilmiştir. Şekil 3.2.'de deneme öncesi bir katılımcıya ait görüntü verilmiştir.



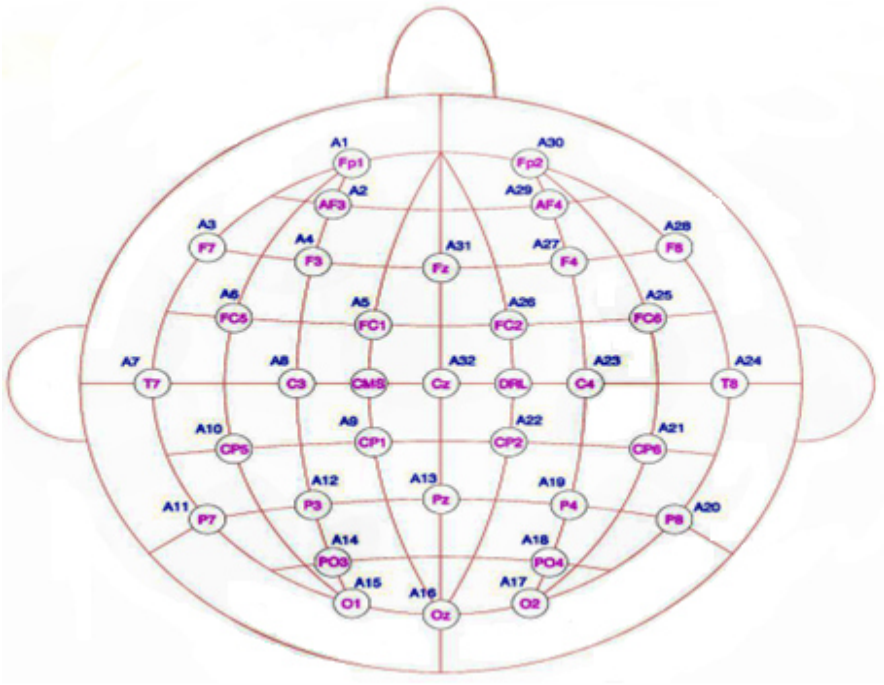
Şekil 3.2. Deney öncesi bir katılımcı (Koelstra ve ark. 2012)

EEG kayıtlarının alınması, Twente ve Genova'da olmak üzere iki laboratuarda gerçekleştirilmiştir. 32 katılımcılardan 22'sinin EEG kayıtları Twente Üniversitesindeki laboratuarda elde edilmiştir. İki laboratuar arasında çeşitli protokol farklılıklarından dolayı, bu çalışmada yalnızca Twente Üniversitesi tarafından deneye alınan katılımcıların EEG işaretleri kullanılmıştır.

Katılımcıların EEG işaretlerinin kayıt edilmesi için kullanılan görsel ve işitsel uyarıcılar, işlemcisi 3.2 GHz olan ve 1200 x 800 ekran çözünürlüğe sahip bir bilgisayar ile sağlanmıştır. Göz hareketlerinin minimize edilmesi amacıyla, video görüntülerinin çözünürlüğü 800x600 boyutlarına indirgenerek katılımcılara sunulmuştur.

3.1.1. Kullanılan EEG İşaretlerinin Özellikleri

Bu çalışmada EEG işaretlerinin ölçümü için 32 aktif AgCl elektrot kullanılmıştır. EEG işaretlerinin kayıt edilmesinde kullanılan elektrotlar, uluslar arası 10 – 20 elektrot yerleşim sistemine göre konumlandırılmıştır. Katılımcılardan alınan EEG kayıtları çok kanallı olup, kayıtlar 32 kanaldan ölçülmüştür (Şekil 3.3.). Kayıt edilen EEG işaretleri, örnekleme hızı 512 Hz olan 24 bit analog sayısal dönüştürücü ile sayısallaştırılmıştır. Sayısallaştırılan verinin boyutunun küçültülmesi için örnekleme hızı daha sonra aşağı örnekleme metodu ile 128 Hz'e indirgenmiştir.



Şekil 3.3. Kullanılan elektrotların 10 – 20 sistemine göre yerleşimi

EEG işaretlerinin kayıt edilmesinde kullanılan elektrotlara ilişkin Şekil 3.3.'de görüldüğü gibi bu yerleşme düzeninde, elektrotlar burun ve başın arka kısmı arasına % 10 - 20 - 20 - 20 - 20 - 10 olacak şekilde yerleştirilmiştir.

EEG işaretlerinin ölçülmesi için konumlandırılan elektrotların kanal numaraları ve kanal etiketleri çizelge 3.2.'de listelenmiştir.

Çizelge 3.2. EEG kanal numaraları ve etiketleri

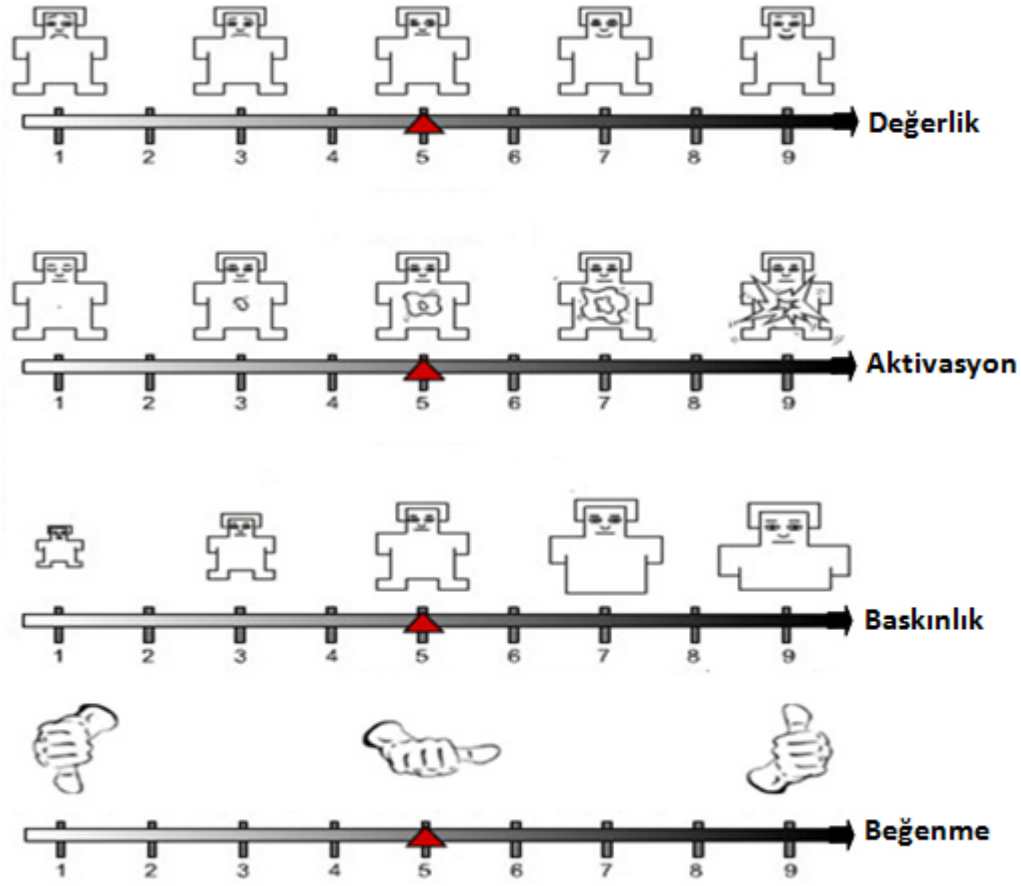
Kanal No	Kanal Etiketi
1	Fp1
2	AF3
3	F3
4	F7
5	FC5
6	FC1
7	C3
8	T7
9	CP5
10	CP1
11	P3
12	P7
13	PO3
14	O1
15	Oz
16	Pz
17	Fp2
18	AF4
19	Fz
20	F4
21	F8
22	FC6
23	FC2
24	Cz
25	C4
26	T8
27	CP6
28	CP2
29	P4
30	P8
31	PO4
32	O2

Katılımcılardan EEG kayıtları ile birlikte EOG (Elektrookülografi) ve EMG (Elektronöromiyografi) işaretleri de kayıt edilmiştir. Ayrıca yerleştirilen çevresel

sensörler aracılığıyla katılımcıların deney esnasında kan basınçları, solunum hızları, vücut ısıları ve GSR (galvanik deri tepkisi) gibi çeşitli fizyolojik işaretleri de kayıt edilmiştir. Bu çalışmada, duyguların EEG ile olan ilişkisi çalışıldığından dolayı, sadece katılımcıların EEG işaretleri analize dahil edilmiştir.

3.1.2. Kullanılan Görsel–İşitsel Uyarıcıların Değerlendirilmesi

Şekil 3.1'de gösterilen paradigmada olduğu gibi katılımcılara sunulan müzik videolarının kendilerinde oluşturduğu duygu durumunu boyutlarına göre değerlendirmeleri istenmiştir. Bu değerlendirmeleri yapmaları için katılımcılara kişisel değerlendirme modeli olan SAM görselleri sunulmuştur. SAM görselleri duygu durumlarının değerlendirilmesinde literatürde sık kullanılan bir modeldir [(Bradley ve Lang 1994), (Schaaf ve Schultz 2009), (Wang ve ark. 2014)]. Sunulan bu model ile katılımcılar izledikleri müzik videolarının kendilerinde uyandırdığı duygu boyutlarını değerlik, aktivasyon, baskınlık ve beğeni açısından değerlendirmişlerdir. Şekil 3.4.'de katılımcılara sunulan SAM görselleri verilmiştir.



Şekil 3.4. Kullanıcılara sunulan SAM (Self Assessment Manikins) görselleri

Kişisel değerlendirme modelinde değerlik paneli negatif duygu durumundan pozitif duygu durumuna geçişi, aktivasyon paneli sakin duygu durumundan heyecanlı duygu durumuna geçişi ve baskınlık paneli ise zayıf duygu durumundan güçlü duygu durumuna geçişi temsil etmektedir (Koelstra ve ark. 2012). Katılımcılar, sunulan farklı müzik videolarının kendilerinde oluşturduğu duygu durumlarını, SAM görselleri aracılığıyla duygu boyutlarına göre değerlendirmişlerdir. Katılımcılar, içinde bulundukları duygu durumuna en yakın ifadeyi, model altında yer alan 1 – 9 aralığındaki skalayı bir fare yardımıyla işaretleyerek belirtmişlerdir. Çizelge 3.3.'de örnek olarak bir katılımcının izlediği her müzik videosunun kendisinde uyandırdığı duygu durumunu belirtmek için değerlik, aktivasyon, baskınlık ve beğenme açısından yapmış olduğu değerlendirmeler listelenmiştir.

Çizelge 3.3. Bir katılımcının yapmış olduğu değerlendirmeler

	Değerlik	Aktivasyon	Baskınlık	Beğenme
Müzik Video_1	8,22	7,78	4	7,42
Müzik Video_2	6,05	7,9	5,06	5,01
Müzik Video_3	7,5	6,68	7,14	7,58
Müzik Video_4	7,38	6,72	6,18	6,94
Müzik Video_5	3,99	7,06	7,99	8,03
Müzik Video_6	7,19	6,83	6,55	7,67
Müzik Video_7	6,85	5,53	6,18	7,62
Müzik Video_8	7	6,21	7,18	7,96
Müzik Video_9	7,69	7,44	8,42	8,92
Müzik Video_10	1,88	8,03	7,09	4,05
Müzik Video_11	8,03	4,26	5,73	7,85
Müzik Video_12	7,63	2,6	5,08	7,01
Müzik Video_13	6,79	3,19	3,88	6,85
Müzik Video_14	8,03	4,36	7,99	7,99
Müzik Video_15	7,08	3,37	5,14	7,17
Müzik Video_16	3,96	2,35	3,65	4,51
Müzik Video_17	6,06	3,32	6,28	6,04
Müzik Video_18	8,09	3,15	5,08	7,53
Müzik Video_19	7,55	5,92	6,06	5,23
Müzik Video_20	7,33	6,63	3,27	4,65
Müzik Video_21	1,03	6,09	1,94	3,78
Müzik Video_22	4,1	3,14	3,01	5,01
Müzik Video_23	2,41	5,95	2,69	6,96
Müzik Video_24	2,36	6,19	2,45	5,71
Müzik Video_25	3,87	3,09	3,06	6,36

Çizelge 3.3. Bir katılımcının yapmış olduğu değerlendirmeler (devamı)

Müzik Video_26	**3,28**	**2,32**	**4**	**6,77**
Müzik Video_27	5,81	3,09	3,97	6,74
Müzik Video_28	2,53	2,96	2,1	6
Müzik Video_29	2,92	5,96	3,24	6,53
Müzik Video_30	1,1	5,94	3,14	7,04
Müzik Video_31	3,26	6,49	6,27	5,82
Müzik Video_32	1,99	6,95	7,01	3,4
Müzik Video_33	3,18	5,83	3,81	2,9
Müzik Video_34	2,5	6,08	2,73	1,09
Müzik Video_35	2,68	6,17	3,68	3,49
Müzik Video_36	2,01	6,21	6,13	2,01
Müzik Video_37	3,47	5,96	4,04	2,4
Müzik Video_38	2,26	5,77	3,23	3,13
Müzik Video_39	6,65	7,06	7,78	2,78
Müzik Video_40	6,68	6,86	6	5,23

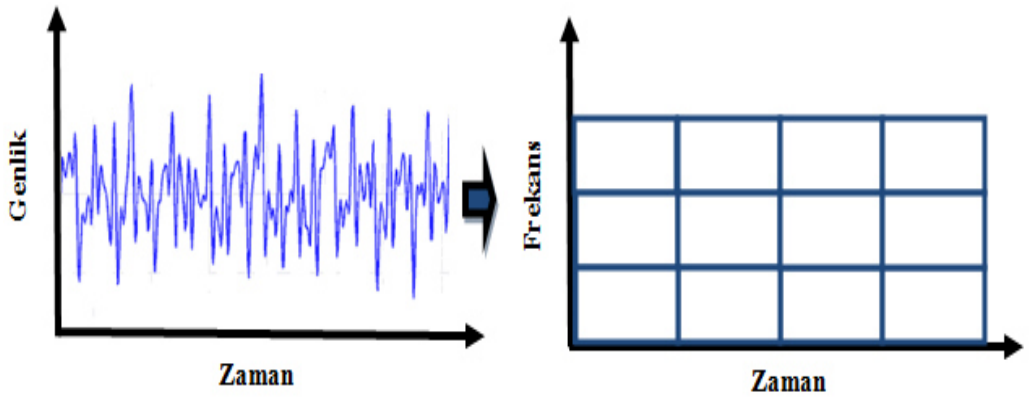
Bu çalışmada, katılımcıların değerlik değerlendirmeleri esas alınarak kişilerinin pozitif ve negatif duygu durumlarına ilişkin EEG işaretlerinin sınıflandırılması gerçekleştirilmiştir.

3.2. Öznitelik Çıkarımı için Dalgacık Dönüşümü

Dalgacık dönüşümü, EEG işaretleri gibi durağan olmayan işaretlerin analizlerinde sık kullanılan metotlardan biridir. Dalgacık dönüşümü, durağan olmayan sinyallerin analizi yanı sıra görüntü işleme, haberleşme sistemleri ve birçok alanda uygulama sahası bulabilen oldukça faydalı bir araçtır.

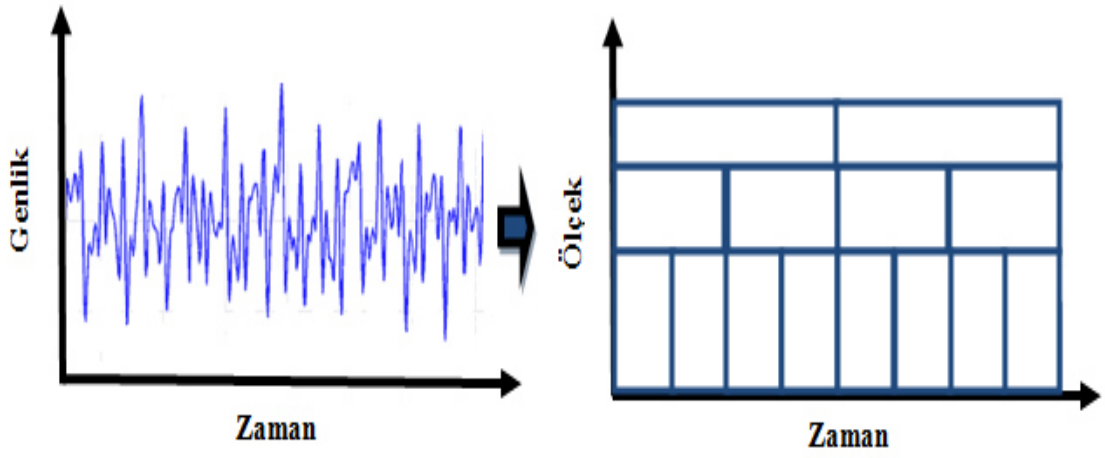
Sinyallerin zaman alanında temsil edilmeleri çoğu durum için yeterli bilgiler sunmayabilir. Sinyallerin daha iyi yorumlanması ve üzerinde daha iyi analizler yapılması için sinyaller genellikle frekans alanında incelenir. Sinyallerin frekans alanında temsil edilebilmesi için dalgacık dönüşümü ile birlikte bir takım sayısal dönüşüm metotları mevcuttur. Bu metotlardan Fourier dönüşümü, sinyali bütün olarak ele almasından dolayı EEG gibi durağan olmayan özellikler barındıran sinyallerin analizlerinde verimli sonuçlar vermemektedir. Bu yüzden sinyali bölütlere ayırarak yani belirli bir zaman penceresinde Fourier dönüşümleri alabilmek için kısa zaman Fourier dönüşümü geliştirilmiştir (Şekil 3.5.). Kısa zaman Fourier dönüşümü ise sabit pencereler kullanmasından dolayı durağan olmayan özellikler barındıran sinyallerin

analizinde verimli bir zaman frekans çözünürlüğü sunamamaktadır [(Çolak 2006), (Polikar 2006)].



Şekil 3.5. Kısa Zaman Fourier Dönüşümü

Dalgacık dönüşümü durağan olmayan sinyallerin spektral analizlerinde Fourier ve kısa zaman Fourier dönüşümü gibi metotlara göre üstünlükleri vardır. Dalgacık dönüşümünün en önemli avantajı, sinyalin alçak frekans bölgesinde geniş pencereler, yüksek frekans bölgesinde ise dar pencereler olacak şekilde değişebilen pencereler kullanmasıdır. Bu özelliğinden dolayı ani değişimlerin olduğu EEG gibi işaretlerin analizinde başarılı bir şekilde zaman ve frekans çözünürlüğü sunmaktadır [(Dabuechies 1990), (Hazerika ve ark. 2000), (Adeli 2003), (Übeyli ve Güler 2004)].



Şekil 3.6. Dalgacık Dönüşümü

3.2.1. Dalgacık

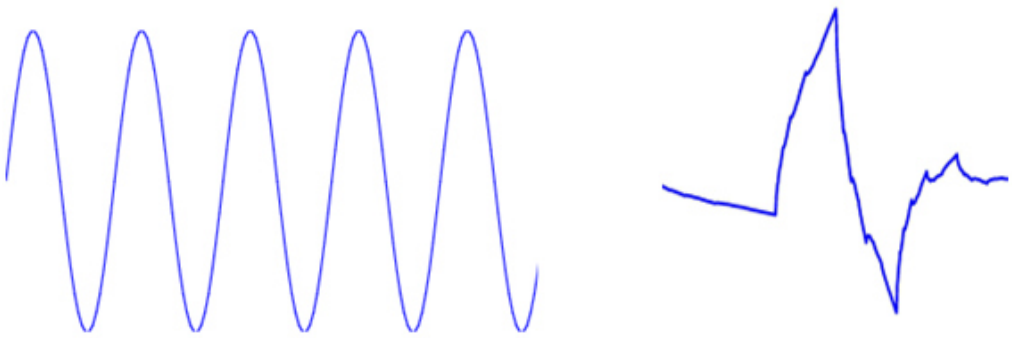
Kelime anlamından yola çıkarak dalgacık küçük dalga anlamına gelmektedir. Bir dalgacık sınırlı yapıda olup integrali sıfıra eşittir. Aynı zamanda karesinin integral değeri de bire eşit olmalıdır.

$$\int_{-\infty}^{+\infty} \psi(x)dx = 0 \tag{3.1}$$

$$\int_{-\infty}^{+\infty} \psi(x)^2 dx = 1 \tag{3.2}$$

Yukarıdaki denklemlerde verilen eşitlikleri sağlayan her $\psi(x)$ fonksiyonu dalgacık olarak nitelendirilir.

Fourier dönüşümlerinde kullanılan temel sinyaller, sinüzoidal sinyaller olup belirli bir sınırı olmayan kendini $+\infty$ ile $-\infty$ arasında tekrar eden düzenli ve simetrik sinyallerdir. Dalgacık dönüşümünde ise kullanılan dalgacıklar düzensiz yapıda olup ve asimetriktirler. Şekil 3.7.'de sinüzoidal bir sinyal ile örnek bir dalgacık gösterilmiştir.



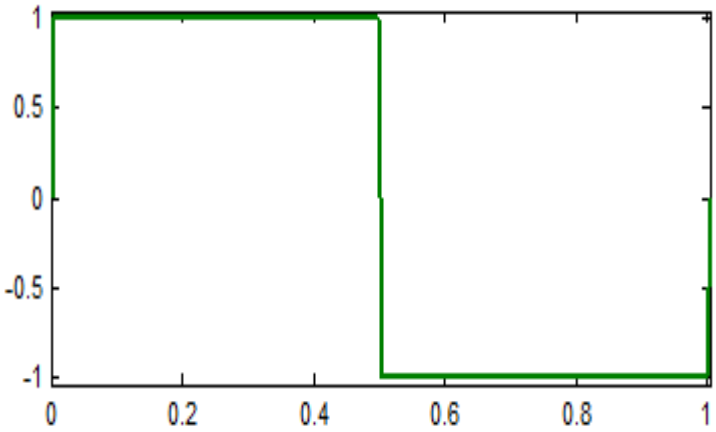
Şekil 3.7. Sinüs dalgası ile Daubechies dalgacığı

3.2.2. Sık Kullanılan Ana Dalgacıklar

Fourier dönüşümünde kullanılan sinyaller, sinüzoidal sinyallerin farklı frekansları alınarak ifade edilir. Dalgacık dönüşümünde ise sinyaller, seçilen ana dalgacıkların ölçeklenip ve zamanda ötelenmesiyle ifade edilir (Tepe 2009). Çeşitli uygulamalar için sık kullanılan dalgacıklar;

Haar Dalgacığı; Alfred Haar tarafından kendi doktora tezinde kullandığı bilinen ilk dalgacıktır. Haar dalgacığın matematiksel ifadesi Eşitlik (3.3)'de ve dalga biçimi Şekil 3.8.'de verilmiştir.

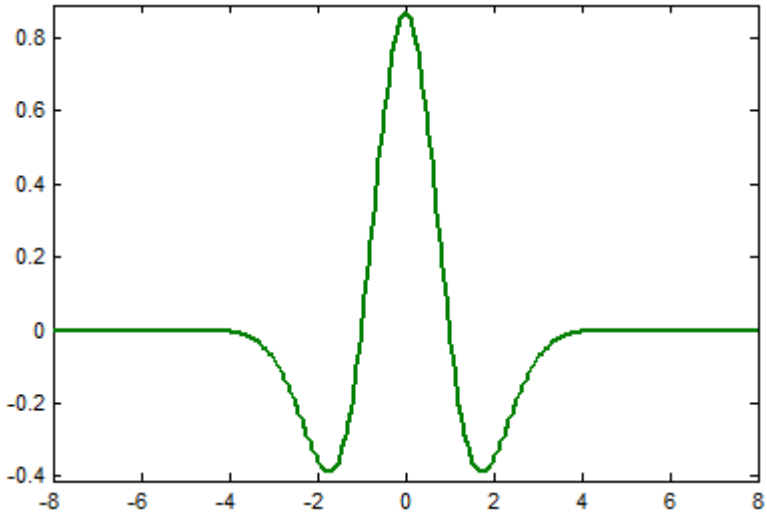
$$\psi(x) = \begin{cases} -\frac{1}{\sqrt{2}}, & -1 < x \leq 0; \\ \frac{1}{\sqrt{2}}, & 0 < x \leq 1; \\ 0, & \text{diğer}; \end{cases} \tag{3.3}$$



Şekil 3.8. Haar dalgacığı

Meksika şapkası dalgacığı; Meksika şapkası dalgacığının matematiksel ifadesi Eşitlik (3.4)'de verilmiştir. Grafiksel gösterimi ise Şekil 3.9.'da verilmiştir.

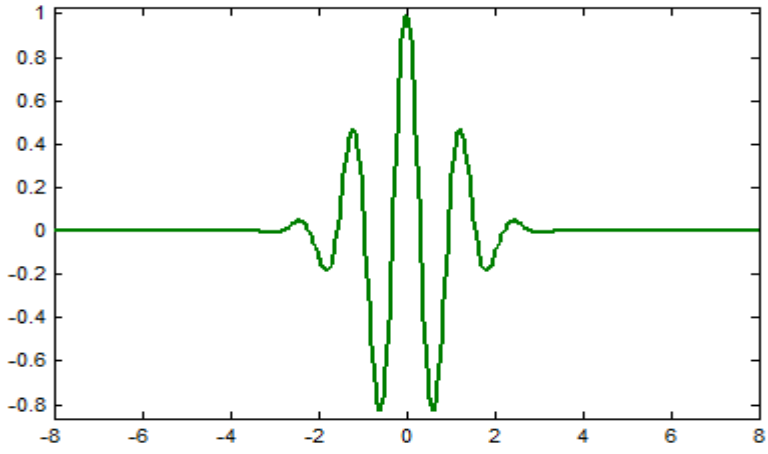
$$\psi(x) = \left(\frac{2}{\sqrt{3}}\pi^{-\frac{1}{4}}\right)(1 - x^2)e^{-x^2/2} \tag{3.4}$$



Şekil 3.9. Meksika şapkası dalgacığı

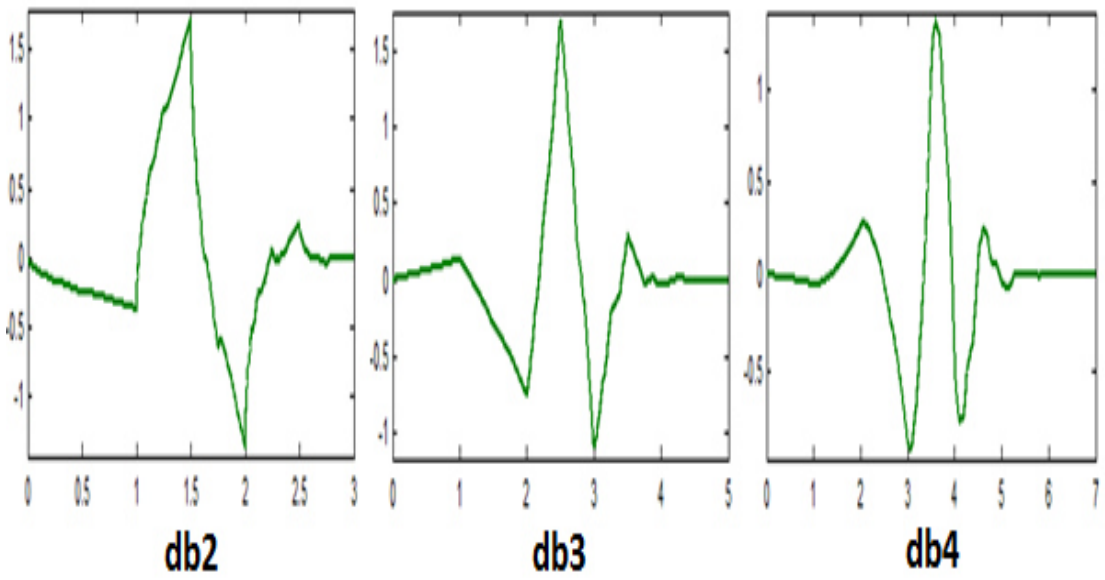
Morlet Dalgacığı; Morlet dalgacığının matematiksel ifadesi Eşitlik (3.5)'de verilmiştir. Grafiksel olarak gösterimi ise Şekil 3.10.'da verilmiştir.

$$\psi(x) = Ce^{-x^2/2}.\cos 5x \tag{3.5}$$



Şekil 3.10. Morlet dalgacığı

Daubechies dalgacığı; Daubechies dalgacığı özellikle EEG işaretlerinin analizinde sık kullanılır. Daubechies dalgacığın grafiksel gösterimi Şekil 3.11.'de verilmiştir.



Şekil 3.11. Daubechies dalgacıkları

3.2.3. Sürekli Dalgacık Dönüşümü

Sürekli dalgacık dönüşümü (SDD) , bütün zaman aralığı boyunca seçilen bir ana dalgacığın ölçeklenip ve zamanda ötelenerek analizi yapılacak sinyalin çarpımından oluşur. SDD, kısa zaman Fourier dönüşümden farklı olarak düşük frekans bölgesinde geniş zaman aralığı, yüksek frekans bölgesinde dar zaman aralığını kullanmaktadır [(Tepe 2009), (Estrada ve ark. 2011)]. Sürekli dalgacık dönüşümünün matematiksel ifadesi Eşitlik (3.6)'da verilmiştir.

$$\mathrm{SDD}(a,u) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t)\psi\left(\frac{t-u}{a}\right) dt \qquad (3.6)$$

Eşitlik (3.6)'da (u) öteleme (a) ise ölçekleme parametresini temsil etmektedir. $\psi(x)$ ise ana dalgacığı temsil eder. SDD yönteminde her bir ölçek değeri için dalgacık katsayılarını bulmak, oldukça büyük veri yığınlarının oluşmasına sebep olur. Aynı zamanda SDD yönteminin zaman alıcı hesaplar gerektirmesi, yöntemi ayrık dalgacık dönüşümüne (ADD) göre dezavantajlı kılar. Bu yüzden ADD yöntemi daha sık olarak tercih edilmektedir (Falarazmi ve ark. 2014).

3.2.4. Ayrık Dalgacık Dönüşümü

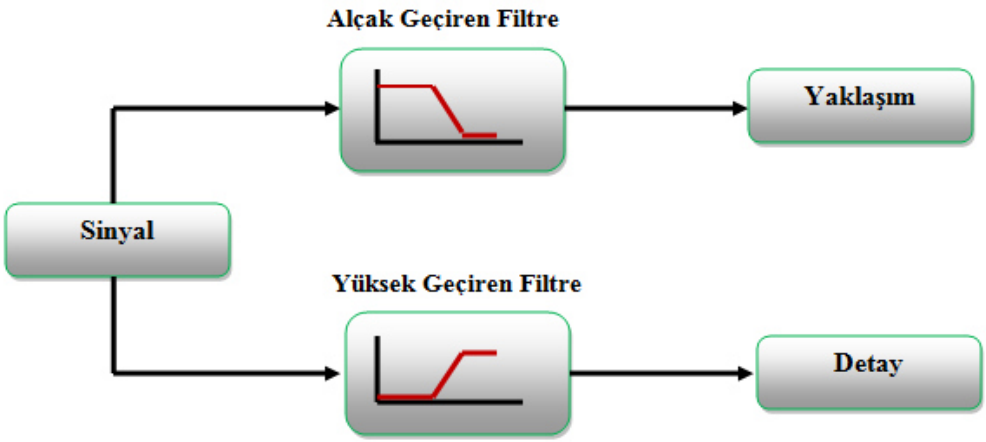
SDD yönteminde bütün ölçek değerleri için dalgacık katsayılarının elde edilmesi oldukça büyük veri yığınlarının oluşmasına neden olmaktadır. Bu yüzden oluşabilecek büyük veri yığınlarından ve hesap yükünden kaçınmak için ADD yöntemi geliştirilmiştir. ADD yönteminde ölçekleme ve öteleme parametreleri belli bir basamağa göre seçilerek, sinyal analiz edilir [(Misiti ve ark. 1997), (Subası 2007)]. Eşitlik (3.7)'de ayrık dalgacık dönüşümünün matematiksel ifadesi verilmiştir

$$C_{(a,b)} = C_{(j,k)} = \sum x[n].2^{-\left(\frac{j}{2}\right)}.g\left(\left(2^{-j}\right)n - k\right) \qquad (3.7)$$

Eşitlik (3.7)'de $a = 2^j$, $b = k2^j$ ve $k \in Z$ olarak verilmiştir.

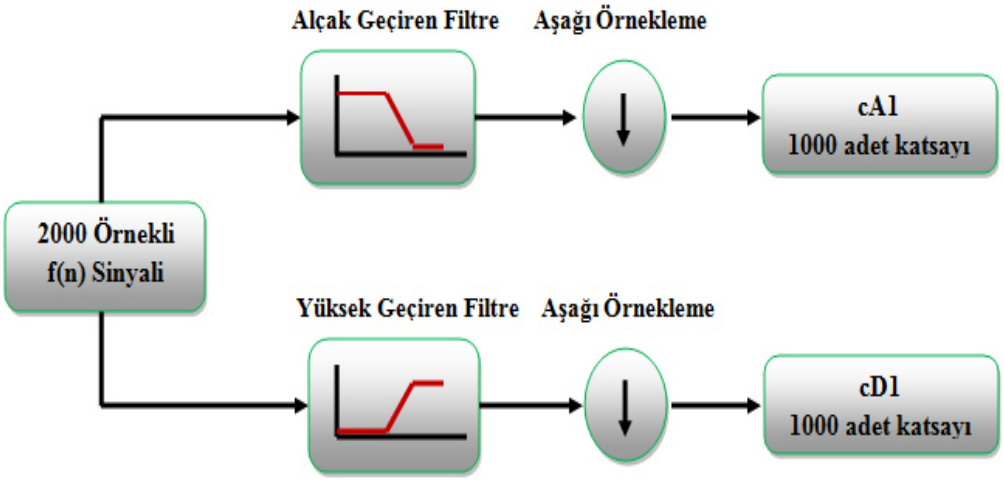
Birçok sinyal için alçak frekans içeriği, sinyalin en önemli kısmını temsil eder. Sinyalin alçak frekans içeriği birçok sinyal için kimlik niteliğindedir. Örneğin, bir insan sesinin yüksek frekans bileşenleri filtrelendiğinde, ses tonunun değişmesine rağmen sesin anlaşılır kaldığı gözlemlenir. Fakat sesin alçak frekans bileşeni filtrelendiğinde sesin anlaşılmaz bir forma geldiği gözlemlenir (Misiti ve ark 1997).

ADD yöntemi, sinyali alçak ve yüksek geçiren dalgacık filtrelerinden geçirerek sinyali yaklaşım ve detay bileşenlerine ayrıştırır (Kıymık ve ark. 2004). Yaklaşım yüksek ölçeklidir ve sinyalin alçak frekans içeriğini temsil eder. Detay ise düşük ölçeklidir ve sinyalin yüksek frekans içeriğini temsil eder (Misiti ve ark. 1997). Şekil 3.12.' de örnek bir sinyalin alçak ve yüksek geçiren filtrelerle süzgeçlenerek yaklaşım ve detay bileşenlerinin elde edilmesi gösterilmiştir.



Şekil 3.12. Sinyalin yaklaşım ve detay bileşenlerine ayrıştırılması

Şekil 3.12.' de gösterilen işlemler sayısal bir işarete uygulandığında sonuç olarak elde edilen yaklaşım ve detay katsayı değerlerinin toplamı, ayrıştırılmamış sinyalin veri boyutunun iki katı olur. Analiz sonucunda veri boyutunun iki katına çıkması istenmeyen bir durumdur. Bu durumun çözümü için aşağı örnekleme metodu kullanılır. Örneğin, başlangıçta 2000 örnekten oluşan bir işarete, ayrık dalgacık dönüşümü uygulanması ve ardından 2 ile aşağı örnekleme yapılması durumunda, 1000 örnekli yaklaşım katsayısı (cA1) ve 1000 örnekli detay katsayısı (cD1) elde edilir. Böylelikle, analiz sonucunda veri boyutunda meydana gelen artış önlenerek, verinin depolanma sorunları ortadan kaldırılmış olur. Şekil 3.13.' de sayısal bir sinyalin bir seviyeli yaklaşım ve detay katsayılarına ayrıştırılması gösterilmiştir.



Şekil 3.13. Sinyalin bir seviyeli yaklaşım ve detay dalgacık katsayılarına ayrıştırılması

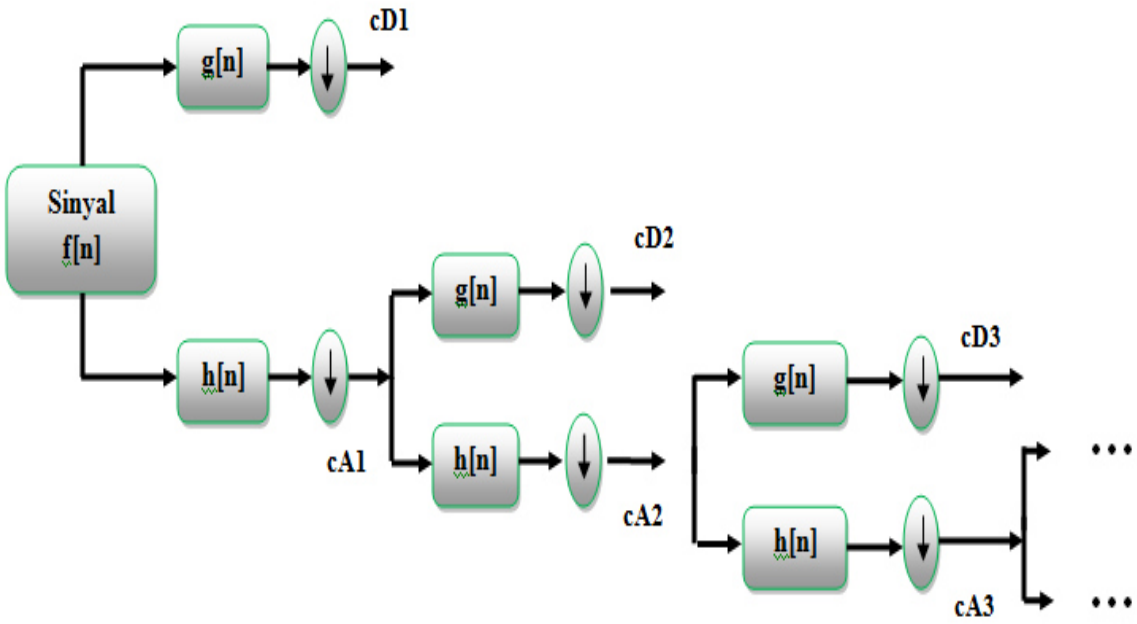
Şekil 3.13.' de görüldüğü üzere aşağı örnekleme yapılarak ölçek 2 katına çıkar fakat bununla birlikte çözünürlük yarıya düşer.

ADD yönteminde, f(n) sinyalinin alçak ve yüksek geçiren filtrelerle süzgeçten geçirilerek yaklaşım ve detay katsayılarının elde edilmesinin matematiksel gösterimi, Eşitlik (3.8) ve Eşitlik (3.9)' da verilmiştir

$$cD1 = \sum_{-\infty}^{\infty} \mathrm{f[n]} \,.\, \mathrm{g[2n - k]} \tag{3.8}$$

$$cA1 = \sum_{-\infty}^{\infty} \mathrm{f[n]} \,.\, \mathrm{h[2n - k]} \tag{3.9}$$

Çok seviyeli ayrıştırma işlemi, işaretin yaklaşım kısmından başlanarak, ardışık bir şekilde işlemlerin tekrarından oluşur (Şekil 3.14).



Sekil 3.14. Sinyalin çok seviyeli bileşenlerine ayrıştırılması

Şekil 3.14.' de gösterilen h[n] ayrık fonksiyonu alçak geçiren filtreyi, g[n] ise yüksek geçiren filtreyi temsil eder.

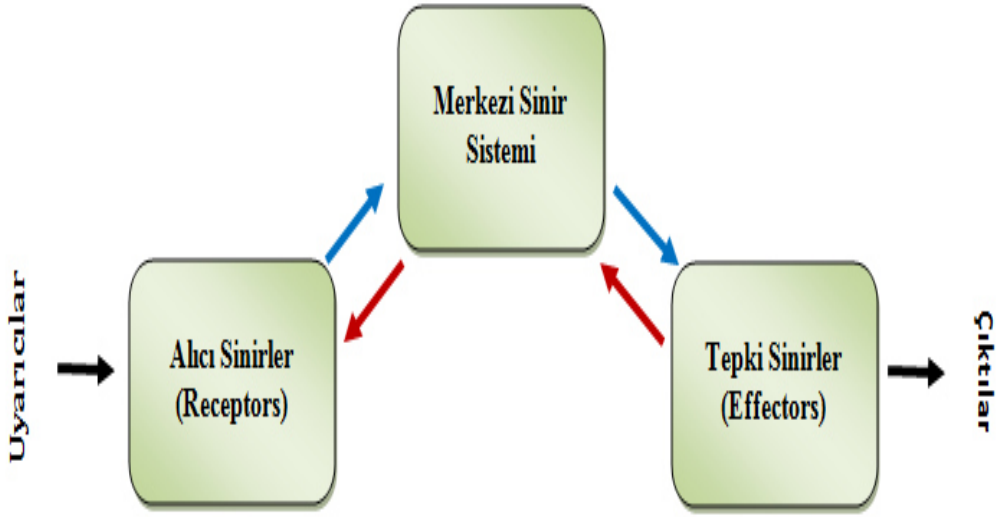
EEG işaret analizlerinde ADD yönteminin sık kullanıldığı literatürden görülmektedir. Bu nedenle bu tez çalışmasında, ADD yöntemi kullanılmıştır. ADD yönteminin en önemli özelliklerinden biri, işaretin istenilen frekans aralığına yöntem yardımıyla erişilebilmesidir. Ancak erişim sürecinde, uygun dalgacık seçimi ve aynı şekilde uygun ayrıştırma seviyesi seçimi oldukça önemlidir (Subaşı 2007).

3.3. Sınıflandırıcı Olarak Yapay Sinir Ağları

Yapay sinir ağları (YSA), biyolojik sinir ağlarının fonksiyonel işlevlerine benzer (öğrenme, tepki verme, ilişkilendirme, sınıflandırma vb) karakteristik bir takım özelliklerinin bilgisayar ortamında gerçekleştirilebilmesi için geliştirilmiştir [(Batar 2005), (Elmas 2007)]. Yapay sinir ağlarının daha anlaşılır olması için biyolojik sinir ağlarının da temel olarak irdelenmesi yararlı olacaktır.

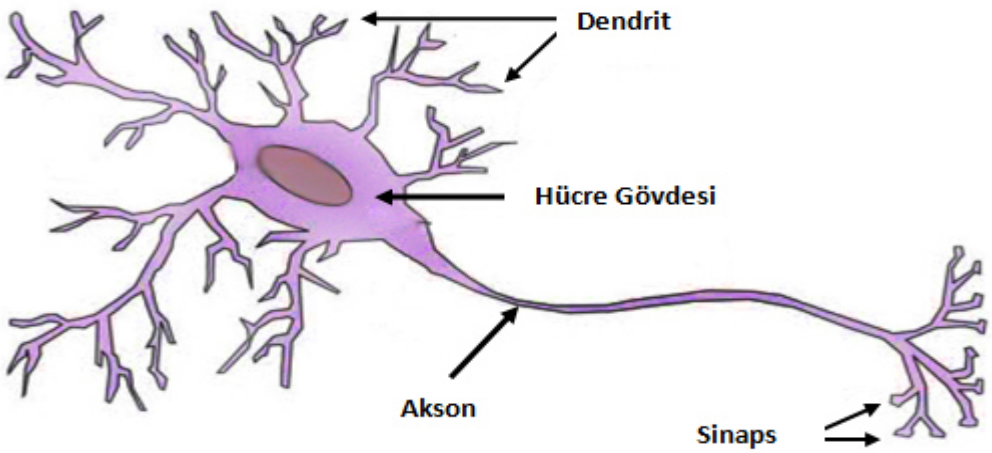
3.3.1. Biyolojik Sinir Ağları ve Hücresi

İnsan sinir sistemi üç aşamalı olarak ele alınır. Dışarıdan aldığı bilgileri yorumlayan ve bunlara uygun kararlar üreten beyin, sinir sisteminin merkezidir. İnsan bedeninden ya da dış çevreden gelen uyarıları elektriksel işarete çevirip sinir sistemi merkezine ileten alıcı sinirler (receptors) ile beyin tarafından üretilen elektriksel işaretleri organizma çıktısı olarak uygun tepkilere dönüştüren tepki sinirleri (effectors) sinir sisteminin diğer iki aşamasını oluşturur. Şekil 3.15.' da biyolojik bir sinir sisteminin blok diyagramı verilmiştir (Haykin 2009).



Şekil 3.15. Sinir sisteminin blok diyagramı

Yapay sinir ağlarının iyi anlaşılır olabilmesi için öncelikle bir biyolojik sinir hücresinin yapısını ve çalışma ilkelerini iyi bir şekilde irdelemek gerekir. İnsan beyninin temel işlem birimi sinir hücreleridir. İnsan beyninde, gelen bilgiyi alan, yorumlayan ve uygun çıktıyı iletebilen yaklaşık olarak 10^{11} sinir hücresi bulunur. Bir sinir hücresinin 10^3 - 10^5 kadar komşu bağlantısı (sinaps) vardır. Beynin temel birimi olan sinir hücreleri farklı boyutlarda ve şekillerde olabilmelerine karşın hepsi temel olarak dört kısımdan oluşur. Bu kısımlar hücre gövdesi (soma), dendrit, akson ve sinaps olarak adlandırılmıştır [(Batar 2005), (Elmas 2007), (Haykin 2009)]. Şekil 3.16.' de basitleştirilmiş bir biyolojik sinir hücresi ve bileşenleri gösterilmiştir.



Şekil 3.16. Biyolojik bir sinir hücresi ve bileşenleri

Dendritler: Kısa lifler olup ve hücre gövdesinden uzanan dalları ağaca benzer. Dendritler birçok kaynaktan aldıkları elektriksel sinyallerinin hücre gövdesine iletilmesini sağlarlar. Dendrit dalları kümeleri dendrit ağaçları olarak adlandırılmaktadırlar (Kriesel 2005).

Hücre gövdesi: Sinapslar ve dendritler vasıtasıyla gelen bilgileri toparlayarak uygun çıktıların diğer sinir hücrelerine iletilmesini sağlarlar.

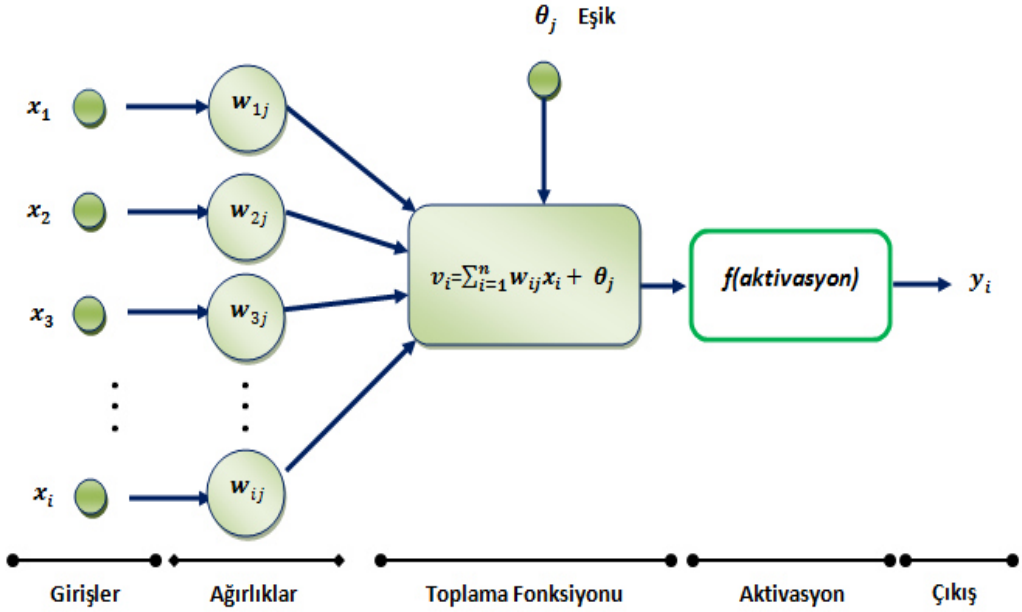
Aksonlar: Yapısal olarak uzun lifler olup darbelerin diğer sinir hücrelerine iletilmesini sağlarlar. Aksonlar hücre gövdesinden uzanan ince ve uzun yapılardır.

Sinapslar: Akson ve başka bir sinir hücresine ait dendritin birleştiği kısımlardır. Basit bir sinir hücresi modelinde, gerçekte oluşabilecek akson ile akson veya bir dendrit ile diğerleri arasında oluşabilecek sinaptik bağlantılar görmezden gelinir [(Batar 2005), (Kriesel 2005)].

3.3.2. Yapay Sinir Hücresi

YSA, birbirine bağlı çok sayıda yapay sinirlerden (nöronlardan) oluşur. Bunlar paralel yapıda olup ve uyarlamalı ağırlıklarla birbirine bağlanmaktadır. YSA, insan beyin sinirlerinden esinlenerek geliştirilmiştir. Yapay sinir hücreleri, biyolojik sinir hücrelerinin kaba bir şekilde matematiksel olarak taklit edilmesi mantığına dayanır. Nöronlar insan beyni gibi öğrenme, hatırlama ve genelleme yapabilme yeteneğine

sahiptirler [(Batar 2005), (Elmas 2007)]. Şekil 3.17.' de bir yapay sinir hücresi gösterilmiştir.



Şekil 3.17. Yapay sinir hücresi

Yapay sinir ağlarının temel birimi olan yapay sinirler, biyolojik sinirlerin dört temel işlevini taklit eder. Şekil 3.18.' de görüldüğü gibi girişler (x_i) her biri ağırlıklarla (w) ile çarpılır ve bu değerler eşik değeri (θ_j) ile toplanır. Sonuç elde etmek için sonuç aktivasyon fonksiyonu ile işlem yapılır ve çıkış (y_i) elde edilir. Yapay sinirlerin öğrenme yeteneği ağırlıkların uygun bir şekilde ayarlanmasıyla sağlanır (Elmas 2007).

i) Girişler

Girişler $(x_1, x_2, x_3, \ldots, x_i)$ aldıkları bilgileri sinir hücresine iletirler. Gelen bilgiler, başka sinirlerden ve dış ortamdan gelen bilgiler olmak üzere ikiye ayrılır. Bir yapay sinir hücresinin genellikle birçok girdisi bulunur. Girişler sütün vektör olarak ifade edilirler (Elmas 2007).

ii) Ağırlıklar

Ağırlıklar $(w_1, w_2, w_3, \ldots, w_i)$, özellikle yapay sinir hücrelerinin öğrenmesinde oldukça önemli bileşenlerdir. Ağırlıklar, girişlerin sinir üzerindeki etkisini belirleyen katsayılar olarak nitelendirilebilinir. Girişlerin her biri kendine ait bir ağırlığa sahiptir.

Ağırlıklar, yapay sinir ağlarının eğitim ve öğrenme aşamalarında uygun çıkışın sağlanabilmesi için değiştirilirler. Bir ağırlığın değeri başlangıçta rastgele olarak seçilir. Sonrasında uygun çıkışa göre değerler alarak değişir. Bir girişin bağlı bulunduğu ağırlığın değerine göre girişin ağdaki etkisinin güçlü ya da zayıf olduğu anlaşılabilir [(Batar 2005), (Elmas 2007)].

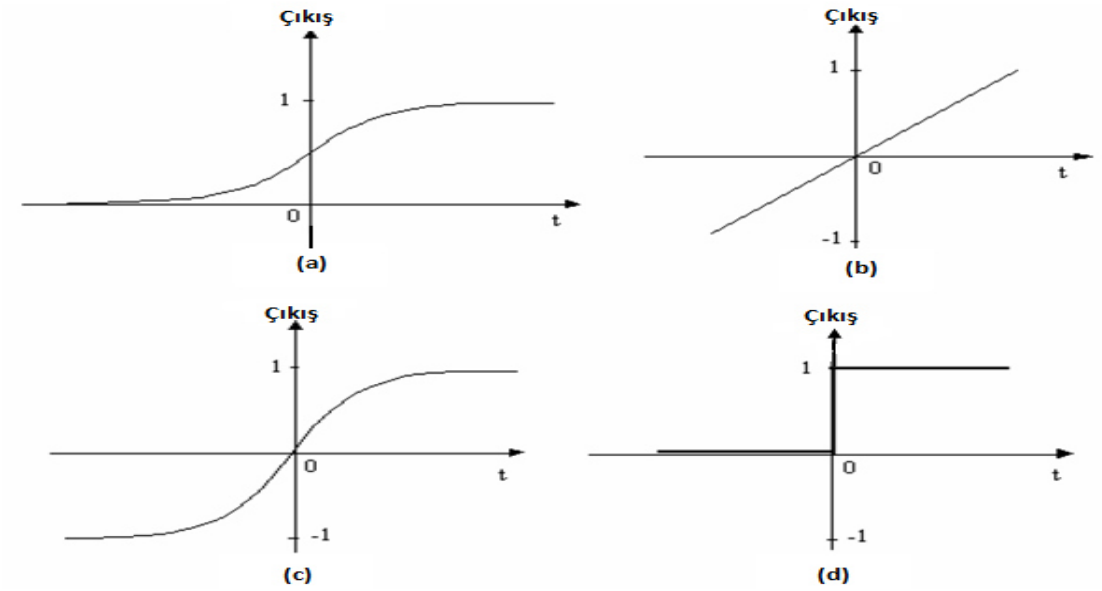
iii) Toplama Fonksiyonu

Toplama fonksiyonu yapay sinire gelen girişlerin bağlantılı oldukları ağırlıklarla çarpılıp toplanmalarını sağlar. Elde edilen sonuç, eşik değerle toplanarak aktivasyon fonksiyonuna iletilir.

iv) Aktivasyon Fonksiyonu

Toplama fonksiyonundan alınan sonuçlar aktivasyon fonksiyonundan geçirilip, çıkışa iletilir. Aktivasyon fonksiyonları, gelen girişleri önceden belirlenen sınırda tutarak, uygun çıkışlar oluşmasını sağlarlar. Böylelikle ağda, girişler ve çıkışlar arasında daha güçlü bir ilişkinin meydana gelmesi sağlanır [(Elmas 2007), (Batar 2005)].

Yapay sinir ağlarında sık tercih edilen dört tür aktivasyon fonksiyonu Şekil 3.18.'de gösterilmiştir.



Şekil 3.18. Sık kullanılan Aktivasyon Fonksiyonları (a) Tek Kutuplu Sigmoid (b) Doğrusal (c) Hiperbolik Tanjant (d) Keskin Sınırlayıcı (Batar 2007)

v) Çıkışlar

Yapay sinir hücreleri tarafından üretilen sonucun dış ortama ya da diğer sinir hücrelerine iletilmesini sağlayan bölümdür. Bir yapay sinirinin yalnızca bir çıkışı olup ve bu çıkış birden fazla yapay sinirin girişi olabilir. Bu özellik de biyolojik sinir hücrelerin de olan bir durumdur. Biyolojik sinir hücrelerinin de birden fazla girişi olmasına rağmen tek çıkışı vardır (Elmas 2007).

YSA biyolojik sinir ağından esinlenmiştir. Çizelge 3.4.' de Yapay bir sinir hücresi bileşenlerinin biyolojik sinir hücresinde karşılıkları gösterilmiştir.

Çizelge 3.4. Yapay Sinir Ağının, Biyolojik Sinir Ağındaki karşılığı

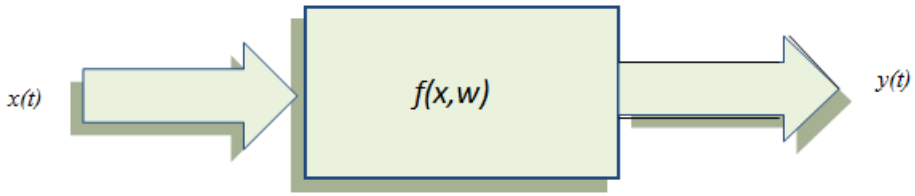
Yapay Sinir Ağı	Biyolojik Sinir Ağı
Sinir Hücresi (İşlem Elemanı)	Sinir Hücresi
Sinirler Arsı Bağlantı	Sinaps
Toplama Fonksiyonu	Dendrit
Aktivasyon Fonksiyonu	Hücre Gövdesi (Soma)
Yapay Sinir Çıkışı	Akson

3.3.3. Yapılarına göre YSA' ların Sınıflandırılması

YSA genel olarak birbirine bağlı birçok yapay sinir hücresinden oluşur. Yapay sinirler (nöronlar) tarafından üretilen çıkışlar, yine kendilerine ya da başka sinir hücrelerine giriş olabilirler. Yapay sinir hücrelerinin birbirleriyle olan bağlantı şekillerine göre farlı YSA yapıları geliştirilmiştir. Yapay sinir ağları yapılarına göre ileri beslemeli ve geri beslemeli ağlar olmak üzere ikiye ayrılır (Çağlar 2007).

a) İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağlarında, ağı oluşturan hücreler (nöronlar) katmanlar şeklinde düzenlenip ayrıştırılmıştırlar. Bir katmandaki hücreler tarafından üretilen çıkışlar, tek yönlü olarak diğer katmandaki hücrelere giriş olarak iletilirler. Aynı katmanda bulunan hücrelerin birbiriyle bağlantıları bulunmaz. Giriş katmanından gelen bilgiler orta (gizli) katman ve çıkış katmanları tarafından işlenerek ağın çıktısı üretilir. Şekil 3.19.' da genelleştirilmiş ileri beslemeli bir YSA yapısı gösterilmiştir.

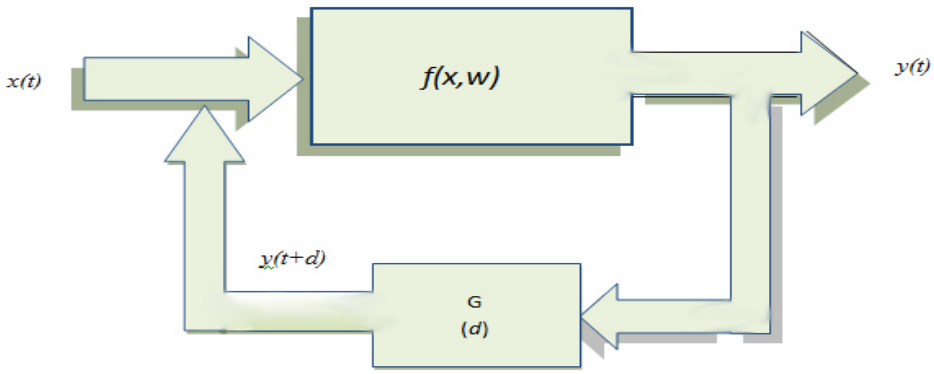


Şekil 3.19. İleri Beslemeli YSA Yapısı

İleri beslemeli ağlarda giriş katmanının giriş ve çıkışları aynı olup sadece girişlerin çoğalmasını sağlarlar (Çağlar 2007). İleri beslemeli YSA' lara örnek olarak çok katmanlı perceptron (Multi Layer Perceptron - MLP) ve LVQ (Learning Vector Quantization) verilebilir.

b) Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağlarında gizli ve çıkış katmanlarındaki üretilen çıkışların giriş ya da bir önceki katmanlardaki hücrelere geri besleme olarak iletildiği ağ yapılarıdır. Geri beslemeli ağlarda ileri beslemeli ağlardan farklı olarak aynı katman içerisinde yer alan hücreler arasında da bağlantıların bulunabileceği ağlardır. Geri beslemeli ağlarda üretilen çıkışlar hem o andaki hem de önceki girişleri yansıtır. Yapılan geri beslemeler genel olarak bir geciktirme elamanı tarafından yapılır (Çağlar 2007). Şekil 3.20.'de genelleştirilmiş geri beslemeli bir YSA yapısı gösterilmiştir.

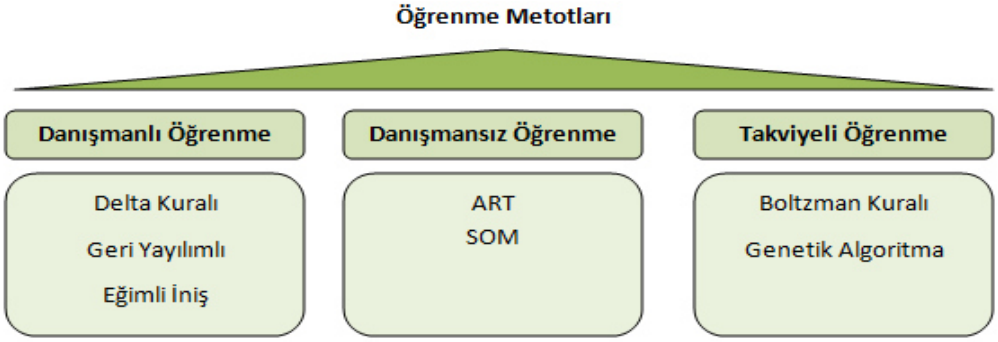


Şekil 3.20. Geri Beslemeli YSA

Geri beslemeli ağlara örnek olarak Hopfield, SOM (SELF Organizing Map) ve Elman ağları verilebilinir.

3.3.4. Öğrenme Algoritmalarına göre YSA' ların Sınıflandırılması

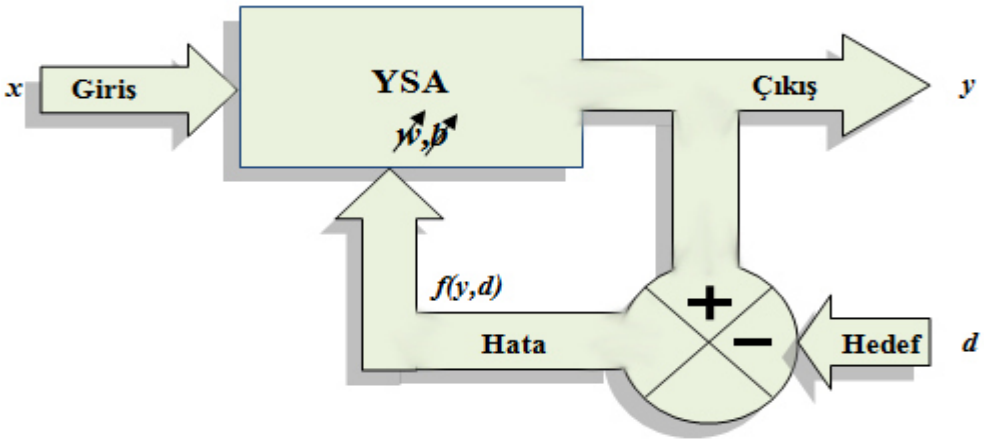
Genel olarak öğrenme, davranışta gözlem, eğitim ve tecrübeler sonucu meydana gelen kalıcı değişimler olarak nitelendirilebilir. Yapay sinir ağlarında ise öğrenme istenilen çıkışların üretilebilmesi için ağırlıkların ayarlanması sürecidir. YSA'da öğrenme temel olarak üç metotdan oluşur. Bu metotlar danışmanlı, danışmansız ve takviyeli öğrenme olup farklı kuralları içermektedirler. Şekil 3.21.'de öğrenme metotları özet olarak gösterilmiştir.



Şekil 3.21. YSA' da Öğrenme Metotları

a) Danışmanlı Öğrenme

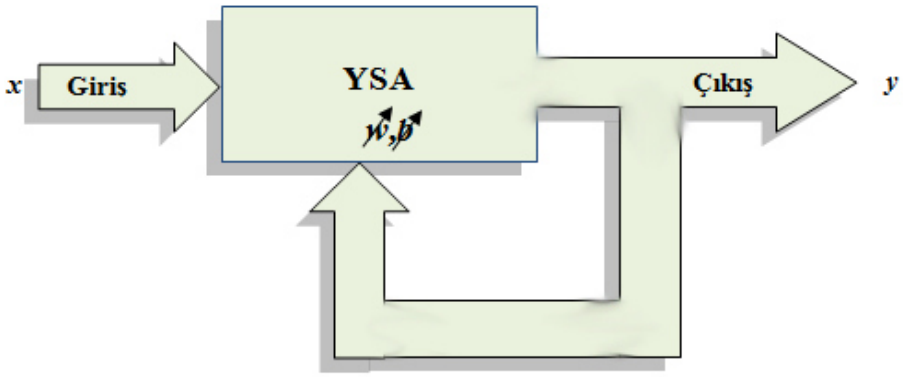
Danışmanlı öğrenme metodunda yapay sinir ağlarının uygulama öncesi eğitilmesi gerekir. Bu metotla, ağa girişler ve çıkışlar (hedefler) sunularak öğrenme gerçeklenir. Danışmanlı öğrenmede YSA tarafından üretilen çıkışlar önceden belirlenen çıkışlarla kıyaslanır ve aradaki fark hata değeri olarak hesaplanır. YSA tarafından rastgele atanan ağırlık katsayıları, hata değerinin kabul edilebilir seviyeye inmesi için sürekli güncellenir. Sonuç olarak verilen girişlere göre istenilen çıkışların YSA tarafından üretilmesi istenir. Hata değerinin kabul edilebilir seviyeye ulaşmasıyla öğrenme gerçekleşir. Yapay sinir ağlarına sunulan giriş ve çıkış bilgilerinin sunuluş biçimi ağın başarısı için oldukça önemlidir. Şekil 3.22.' de danışmanlı öğrenme metodunun blok diyagramı gösterilmiştir.



Şekil 3.22. Danışmanlı öğrenme blok diyagramı

b) Danışmansız Öğrenme

Danışmansız öğrenme metodunda danışmanlı öğrenmeden farklı olarak ağa istenilen çıkış (hedef) bilgisi sunulmaz. Bu metotta ağa sadece giriş bilgileri sunularak ağın verilen girişleri gruplaması (sınıflaması) beklenir. Ağ, girişte sunulan bilgilere göre giriş verilerini sınıflandırmak için kendi kurallarını oluşturur. YSA, bağlantı ağırlıklarını aynı özellikte olan giriş verilerini sınıflandıracak şekilde düzenleyerek öğrenme işlemini tamamlar. Şekil 3.23.'de danışmansız öğrenme metodunun blok diyagramı gösterilmiştir.

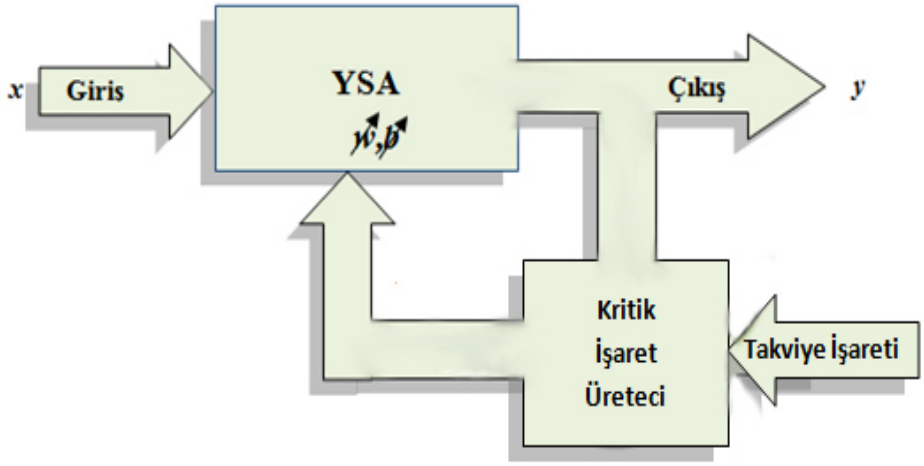


Şekil 3.23. Danışmansız öğrenme blok diyagramı

c) Takviyeli Öğrenme

Takviyeli örenme metodu genel olarak danışmanlı öğrenme metoduna yakındır. Bu metotta ağa istenilen çıkış bilgisi verilmez. Ağa her döngü sonunda ağın ürettiği

sonucun iyi veya kötü olduğuna dair bilgi verilir. Ağ bu bilgilere göre kendini düzenler. Şekil 3.24. takviye öğrenmenin blok diyagramı gösterilmiştir.

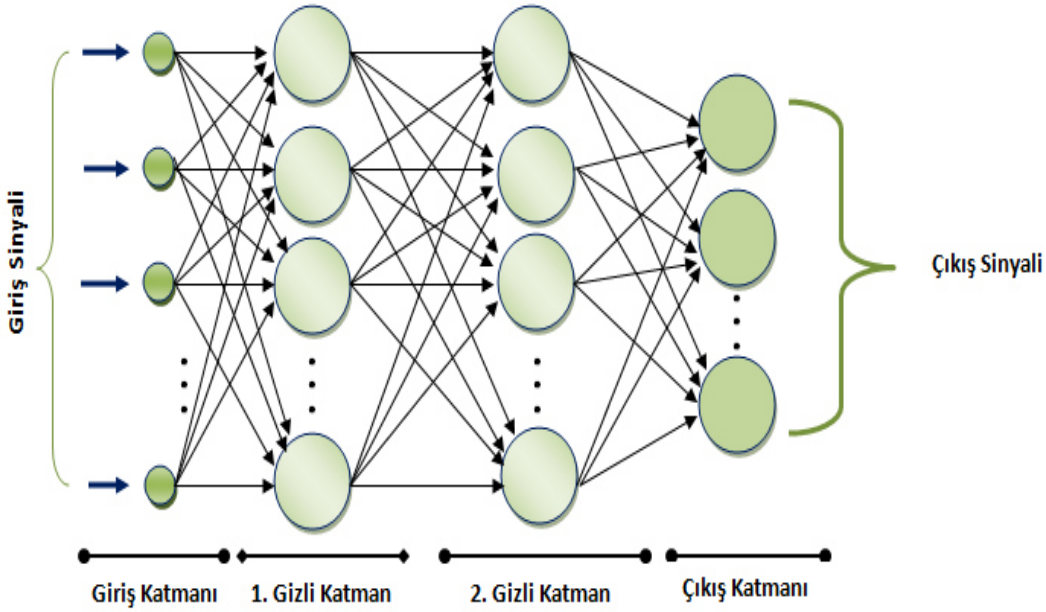


Şekil 3.24. Takviyeli öğrenme blok diyagramı

3.3.5. Tez Kapsamında Kullanılan YSA Mimarisi ve Öğrenme Algoritması

a) Çok Katmanlı YSA

Çok sayıda katman içeren yapay sinir ağlarıdır. Geliştirilen ilk modellerin doğrusal olmayan ilişkileri çözebilme yeteneğinden yoksun olmalarından dolayı geliştirilmiştir. Giriş katmanı, gizli katman ve çıkış katmanından oluşurlar (Öztemel 2003). Giriş katmanı, herhangi bir aktivasyon fonksiyonu kullanılmadan ağa sunulan bilgileri ağırlık değerleriyle çarparak gizli katmana iletilmesini sağlar. Gizli katman ise giriş katmanından uygun ağırlıkla gelen bilgileri aktive ederek çıkış katmanına yollar. Gizli katmandaki nöronlar özellik algılayıcı olarak davranırlar. Aşamalı bir şekilde verinin belirgin özelliklerini keşfederek ağa sunulan bilginin karakterize edilmesini sağlarlar (Haykin 2009). Teorik olarak bir ağda çok sayıda gizli katman kullanılmasına rağmen genelde bir ya da iki gizli katman kullanılması arzu edilen sonucu sunabilmektedir. 3.25.'de iki gizli katman içeren çok katmanlı bir YSA yapısı gösterilmiştir.



Şekil 3.25. Çok katmanlı YSA

b) Geriye Yayılımlı Öğrenme Algoritması

Geliştirilen yapay sinir ağlarının karşılan problemlere çözüm üretebilmeleri için eğitilmeleri gerekir. Eğitim, karşılaşılan problemin giriş ve çıkış ilişkisi baz alınarak ağırlık değerlerinin ayarlanmasıyla gerçekleşir.

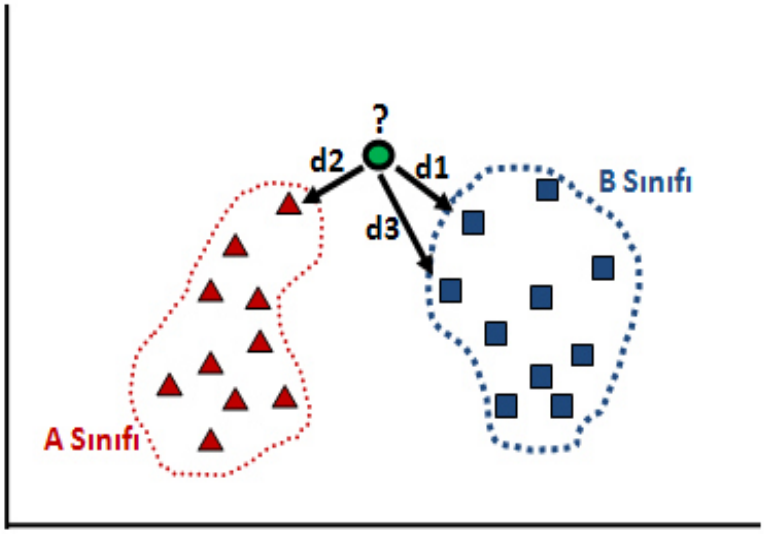
Rumelhart ve ark. (1986), tarafından geliştirilen geriye yayılımlı öğrenme algoritması, sık kullanılan ve çok katmanlı YSA' lar için temel öğrenme algoritmasıdır. Bu yöntem, hata kareler toplamının geri yayılımla küçültülmesi mantığına dayanır. Bu yöntemle ağın girişlerine bağlı olarak YSA tarafından üretilen çıkış değeri arzu edilen çıkış değeriyle karşılaştırılır. Farklılık varsa bu farklılık ağ tarafından rastgele belirlenen ağırlık değerlerinin güncellemesi ile azaltılmaya çalışılır (Rumelhart ve ark. 1986).

3.4. Sınıflandırıcı Olarak K - En Yakın Komşu Algoritması

K - en yakın komşu (kNN) algoritması, sınıflandırıcı olarak en sık kullanılan algoritmalardan biridir. kNN basit ve yorumlanabilmesi kolay, denetimli makina öğrenimi algoritmalarından biridir (Larose 2005).

kNN, uzaklığa dayalı bir öğrenme algoritmasıdır. kNN algoritması n boyutlu özellik uzayında karşılaşılan yeni bir nesnenin özniteliklerini inceleyerek önceden belirlenen sınıflara yerleştirilmesini sağlar (Berrueta ve ark. 2007). kNN algoritmasında

sınıflandırma, yeni bir örneğin eğitim setinde yer alan nesnelerin her birine olan uzaklığının hesaplanması ile sağlanır. Hesaplama sonrası sınıfları önceden belirlenen nesnelerden k adet en yakın komşu dikkate alınarak sınıflandırma işlemi gerçekleştirilir Algoritmada k değişkeni pozitif tamsayı olarak belirtilir. Eğer k=1 ise, sınıflandırılmaya çalışılan nesne en yakın komşusunun ait olduğu sınıfa dahil olur. Eğer k=3 ise, sınıflandırılmaya çalışılan nesne için en yakın üç komşu dikkate alınarak sınıflandırma işlemi gerçekleştirilir. Şekil 3.26.'da iki sınıfa ait nesnelerin bulunduğu uzayda, sınıfı bilinmeyen bir nesnenin 3-NN algoritmasıyla sınıflandırma süreci gösterilmiştir. En yakın üç komşunun ikisi B sınıfında olması nedeniyle, yeni nesne B sınıfına dahil edilir.



Şekil 3.26. kNN sınıflandırma süreci

Diğer bir değişle, kNN algoritmasında, bilinmeyen bir nesnenin sınıflandırılması oylama işlemine benzer [(Brereton 2003), (Ferreira ve ark. 2014)]. Şekil 3.28.'de görüldüğü gibi k=3 için bilinmeyen nesneye, uzaklıkları d1, d2 ve d3 olan iki sınıfa ait en yakın 3 komşu belirlenmiştir. Belirlenen en yakın komşuların her biri ait olduğu sınıf için bir oy niteliğindedir. Bilinmeyen nesne oylama sonunda en fazla oy verilen sınıfa dahil edilir.

3.4.1. kNN Algoritmasında Kullanılan Uzaklık Ölçütleri

kNN algoritmasında sınıflandırma işlemi, belirlenen k değerine göre k adet en yakın komşunun bulunmasıyla gerçekleştirilir. En yakın komşuların bulunması için sınıflandırılmaya çalışılan nesnenin eğitim kümesinde yer alan her üyeye olan

uzaklığının ayrı bir şekilde hesaplanması gerekir. İki nesne arasındaki uzaklığın büyük olması benzerliğin düşük olduğu, uzaklığın küçük olması ise benzerliğin büyük olduğu anlamına gelir.

kNN algoritmasında uzaklığın hesaplanmasında farklı yöntemler kullanılır. Bu yöntemlere Minkowski, Manhattan, Euclidean ve Hamming uzaklık ölçütleri örnek olarak verilebilir.

Minkowski uzaklık ölçütü n boyutlu uzayda iki nokta arasındaki uzaklıkları hesaplamak için kullanılır. Minkowski uzaklık ölçütünün matematiksel ifadesi Eşitlik (3.10)'da verilmiştir.

$$d = \left(\sum_{i=1}^{n} (|x_i - y_i|)^q \right)^{1/q} \tag{3.10}$$

Minkowski uzaklık ölçütünden türetilen Manhattan uzaklık ölçütü, q değişkeninin 1 olarak ayarlamasıyla elde edilir. Eşitlik (3.11)'de Manhattan uzaklık ölçütünün matematiksel ifadesi verilmiştir.

$$d = \sum_{i=1}^{n} (|x_i - y_i|) \tag{3.11}$$

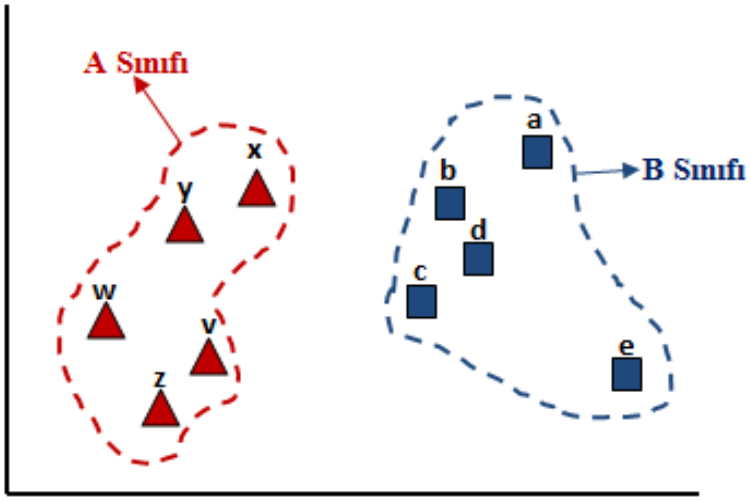
Diğer bir uzaklık ölçütü olan Euclidean ölçütü de Minkowski uzaklık ölçütünden türetilmiştir. Euclidean uzaklık ölçütü k-en yakın komşu algoritmasında en çok tercih edilen yöntem olup matematiksel ifadesi Eşitlik (3.12)'de verilmiştir.

$$d = \sqrt{\sum_{i=1}^{n} (x_i - y_i)^2} \tag{3.12}$$

Sayısal olarak belirtilen iki nesnenin birbirine olan uzaklıklarının hesaplanmasında bahsi geçen yöntemlerin kullanılması oldukça uygundur. Fakat sayısal olarak belirtilmeyen cinsiyet ve renk gibi özelliklerin birbirine olan uzaklıklarını hesaplamak için Hamming uzaklık ölçütü geliştirilmiştir. Hamming uzaklık ölçütünde aynı niteliklerle belirtilen özellikler arasında ki uzaklık 0, farklı niteliklerle belirtilen özellikler arasındaki uzaklık ise 1 olarak değerlendirilir.

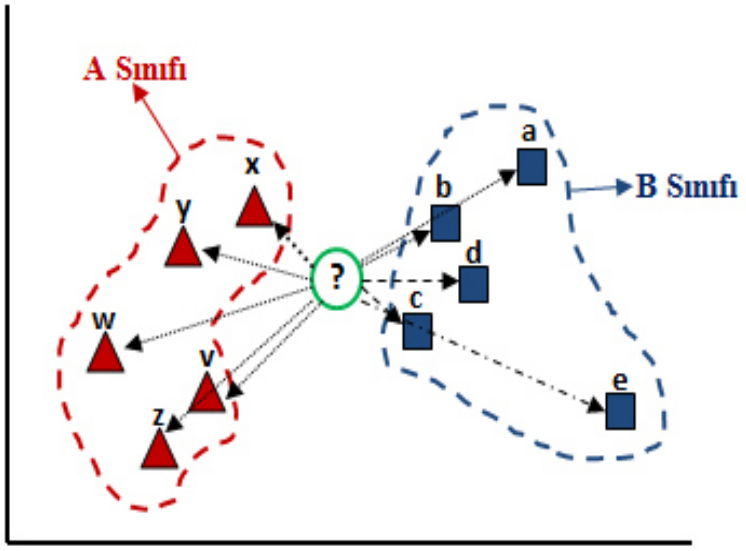
3.4.2. kNN Algoritması İşlem Basamakları

1) İlk olarak eğitim verilerinin bilinen sınıflara atanması sağlanır (Şekil 3.27.).



Şekil 3.27. Eğitim verisi üyelerinin bilinen sınıflara atanması

2) Bilinmeyen yeni bir nesnesin farklı sınıflardaki bütün nesnelere olan uzaklığı ayrı bir şekilde hesaplanır (Şekil 3.28.).



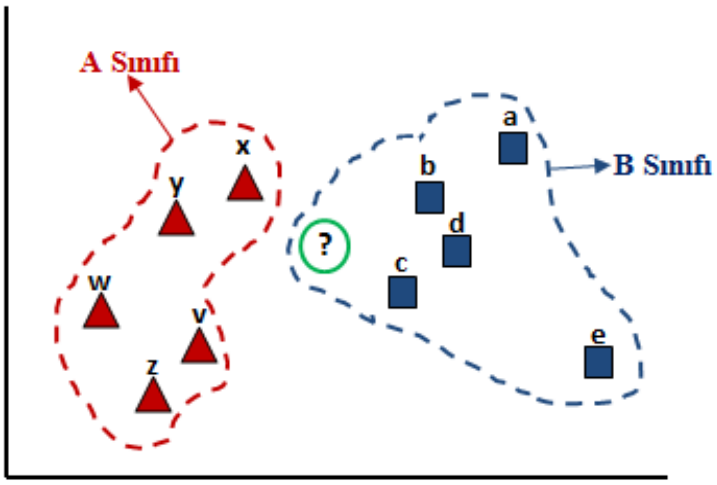
Şekil 3.28. Uzaklıkların hesaplanması

3) Bilinmeyen nesnenin eğitim verisinde yer alan nesnelere olan uzaklığı sıralanır ve seçilen k değerine göre en yakın k adet komşu alınır. Çizelge 3.5.' de k=3 için en yakın 3 komşu sıralanması listelenmiştir.

Çizelge 3.5. K=3 için en yakın komşuların sıralanması

En Yakın Komşular	Ait Oldukları Sınıflar
c	B
x	A
b	B

4) Sınıflandırılmak istenen nesne, algoritma tarafından belirlenen k adet en yakın komşunun ait oldukları sınıflar dikkate alınarak, en fazla üyesi bulanan sınıfa atanır. Çizelge 3.5.'de görüldüğü gibi belirlenen en yakın 3 komşudan 2'si B sınıfına, 1'i ise A sınıfına aittir. Bu durumda bilinmeyen nesne, algoritma tarafından B sınıfına dahil edilir. Şekil 3.29.'da bilinmeyen nesnenin ait olduğu sınıfa dahil edildiği gösterilmiştir.



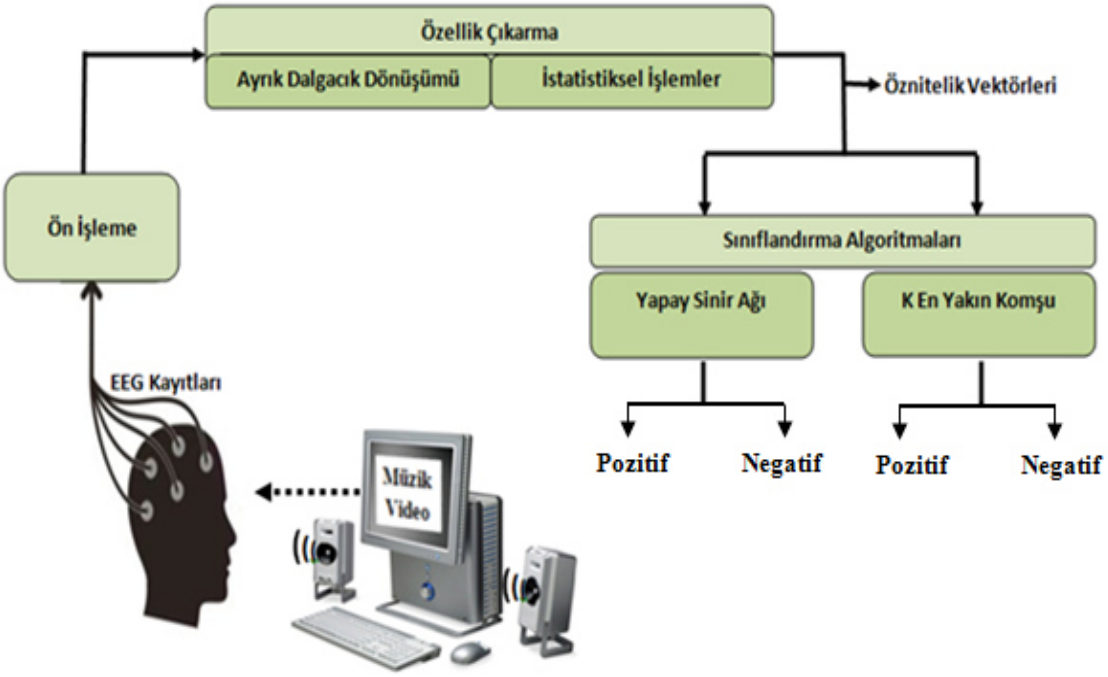
Şekil 3.29. Bilinmeyen nesnenin sınıflandırılması

4. ARAŞTIRMA BLGULARI

Bu tez çalışmasında katılımcıların değerlik değerlendirmeleri esas alınarak, belirlenen pozitif ve negatif duygu durumlarına ilişkin EEG işaretlerinin sınıflandırılması gerçekleştirilmiştir.

ADD kullanılarak, farklı duygu durumlarına ilişkin EEG işaretlerinden özellik çıkarımı yapılmıştır. ADD kullanılarak elde edilen öznitelik vektör boyutlarının azaltılması için istatistiksel işlemler uygulanmıştır. Sınıflandırıcı olarak ise YSA ve kNN uygulanmış ve her iki algoritma için elde edilen sınıflandırma başarıları karşılaştırılmıştır.

Çalışmada kullanılan EEG işaretleri 32 kanallı olup, analizler her kanal için ayrı bir şekilde yapılmıştır. Her katılımcı için en iyi sınıflandırma doğruluğu sunan beş kanal belirlenmiş ve bu beş kanala ait EEG işaretlerinin öznitelik vektörleri birleştirilerek sınıflandırma başarısı arttırılmıştır. Yapılan işlemler deneye katılan 22 katılımcının her biri için ayrı bir şekilde yapılmıştır. Şekil 4.1.'de bu tez çalışmasında önerilen sürecin aşamaları gösterilmiştir.

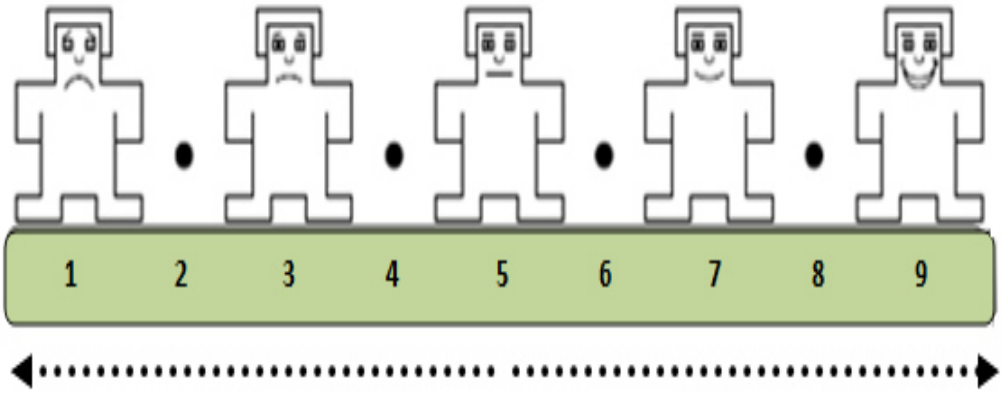


Şekil 4.1. Sınıflandırma için izlenen işlem aşamaları

4.1. EEG Ölçümleri için Önişleme

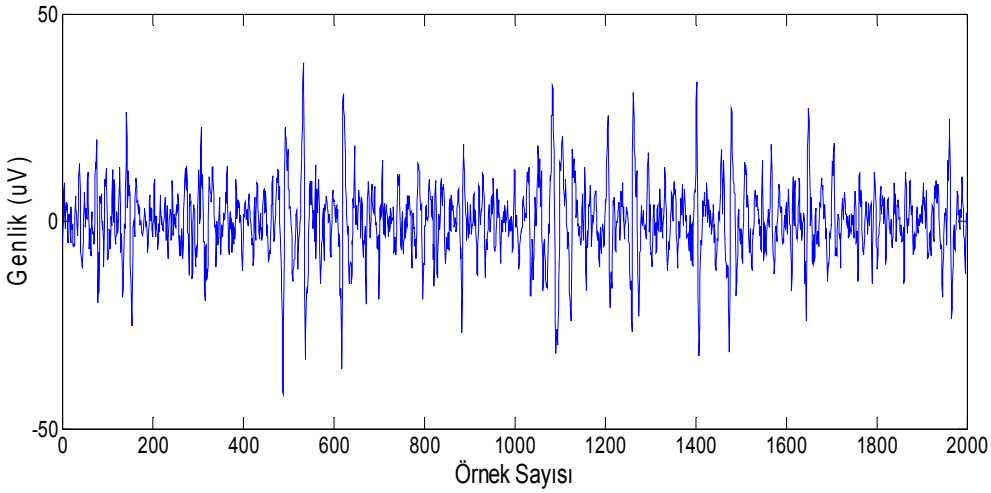
Kullanılan EEG kayıtları, Twente ve Genova'da olmak üzere iki laboratuarda yapılan deneyler sonucu katılımcılardan elde edilmiştir. 32 katılımcıdan 22'sinin EEG kayıtları Twente Üniversitesindeki laboratuarda elde edilmiştir. İki laboratuar arasında çeşitli protokol farklılıklarından dolayı, bu çalışmada yalnızca Twente Üniversitesi tarafından deneye alınan katılımcılara ilişkin EEG işaretleri değerlendirmeye alınmıştır. Her katılımcı için 32 kanal EEG ölçümü yapılmıştır. Örnekleme hızı 512 Hz' den aşağı örnekleme metoduyla 128 Hz' e düşürülmüştür. Kayıt Edilen EEG sinyalleri 4.0-45.0 Hz bant geçiren filtre ile filtrelenmiştir. Ayrıca kayıt esnasında izlenen paradigma çerçevesinde görsel ve işitsel uyaranların öncesi ve sonrasında yer alan kayıtlar ve EOG artefaktları EEG işaretlerinden filtrelenerek, kaldırılmıştır. Sonuç olarak, sunulan her müzik video kaydı ile birlikte bir EEG bölütü elde edilmiştir. Dolayısıyla her bir katılımcının 40 adet müzik videosuyla ilişkili 40 adet EEG bölütü elde edilmiştir.

Farklı duygu durumlarını içeren EEG işaretlerinin sınıflandırılması için katılımcıların SAM (Self Assessment Manikins) görsellerine göre yapmış oldukları değerlendirmeler dikkate alınmıştır. Katılımcılar, kendilerine sunulan 40 adet birer dakikalık müzik videoları sonunda o andaki duygu durumlarını SAM aracılığıyla değerlik, aktivasyon, baskınlık ve beğeni açısından değerlendirmişlerdir. Katılımcılar duygu boyutlarını sayısal olarak 1-9 aralığında ondalıklı bir şekilde belirtebilmişlerdir. Bu çalışmada ise sadece katılımcıların değerlik açısından yapmış oldukları değerlendirmeler dikkate alınmıştır. Şekil 4.2.'de SAM görsellerinden değerlik paneli gösterilmiştir.

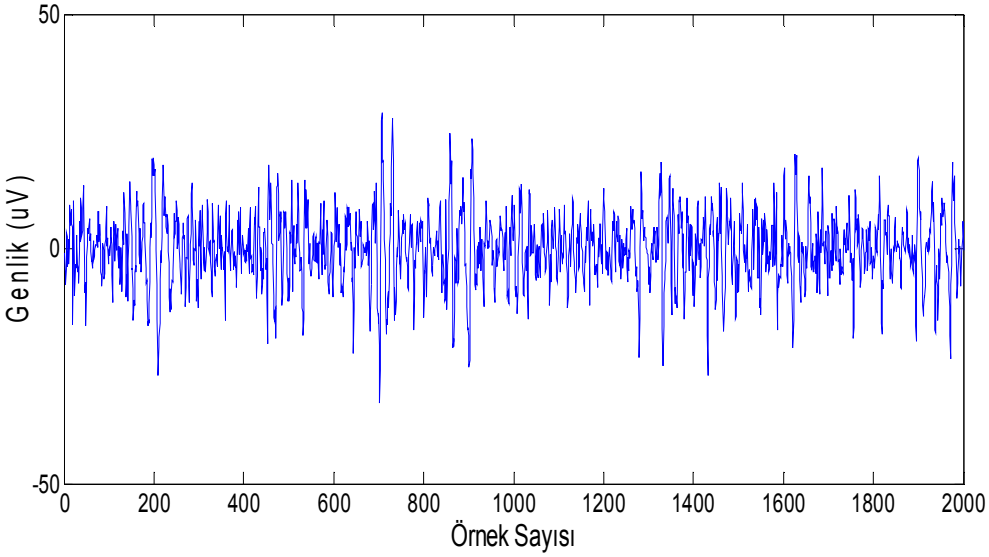


Şekil 4.2. SAM görsellerinden değerlik paneli

Katılımcılar, değerlik derecelendirmelerini Şekil 4.2.'de görüldüğü gibi 1-9 aralığında yapmışlardır. 1 değeri tamamen negatif (mutsuz, üzgün, vb.), 9 ise tamamen pozitif (mutlu, neşeli, vb.) duygu durumuna karşılık gelmektedir. Bu çalışmada, SAM değerlik paneli görsellerine göre 5'den küçük yapılan değerlendirmeler negatif (üzgün duygu durumu, 5' den büyük yapılan değerlendirmeler ise pozitif duygu durumu olarak kabul edilmiştir. Şekil 4.3. ve Şekil 4.4.'de sırasıyla bir katılımcının yapmış olduğu değerlendirmelere göre katılımcının pozitif ve negatif duygu durumlarına ilişkin örnek EEG işaretleri gösterilmiştir. Örnek EEG işaretlerinin daha iyi görüntülenmesi için ilk 2000 örnekleri gösterilmiştir.



Şekil 4.3. Pozitif duygu durumuna ilişkin EEG işareti

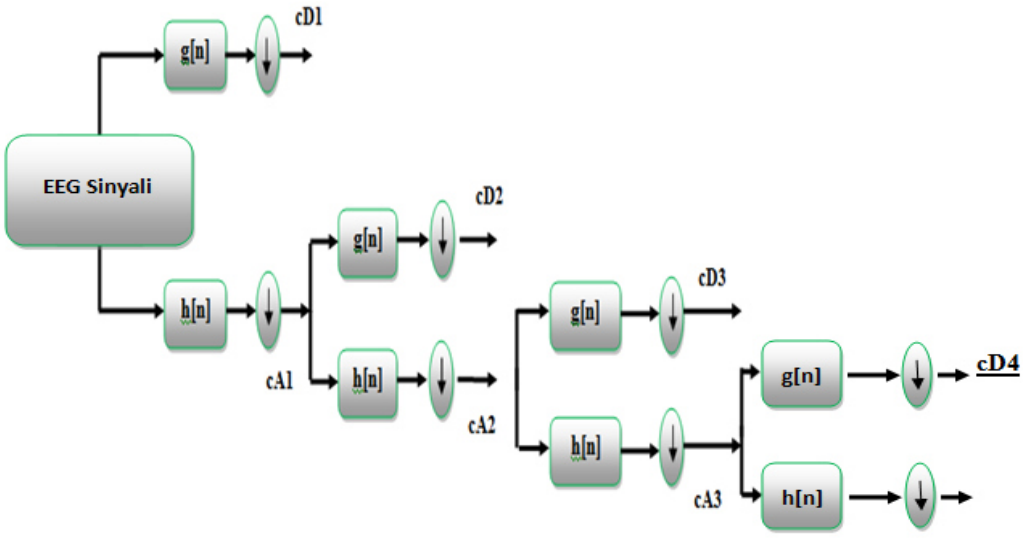


Şekil 4.4. Negatif duygu durumuna ilişkin EEG işareti

4.2. ADD Kullanılarak EEG İşaretlerinden Öznitelik Çıkarımı

ADD, EEG işaretlerinin analizinde oldukça sık kullanılan bir metottur. Analizi yapılacak sinyalin istenilen frekans aralığına ayrık dalgacık dönüşümü kullanılarak ulaşılabilinir. Bu yüzden uygun dalgacık seçimi ve aynı şekilde uygun ayrıştırma seviyesi seçimi oldukça önemlidir (Subaşı 2007). Literatürde, EEG teta bandı dinamiklerinin duygu durumlarını içerdiğine ilişkin çalışmalar görülebilmektedir [(Koelstra ve ark. 2012), (Uusberg ve ark. 2014), (Polat ve Özerdem 2015)]. Bu sebepten dolayı, bu çalışmada da EEG işretlerinden özellik çıkarımı için teta bandı dinamikleri kullanılmıştır.

Örnekleme hızı 128Hz olması nedeniyle dalgacık ayrıştırma seviyesi 4 alınarak teta (4-8Hz) bandı elde edilmiştir. . Literatürde EEG işaretlerinin analizinde Daubechies dalgacığının iyi sonuçlar üretmiş olmasından dolayı [(Subaşı 2007), (Orhan ve ark. 2011)], bu çalışmada da dalgacık tipi olarak 2. dereceden Daubechies (db2) dalgacık kullanımı uygun görülmüştür. EEG teta bandına ilişkin dalgacık katsayılarının elde edilmesi için 4 seviyeli ayrıştırma işlemi yapılmıştır. Konuya ilişkin işlem akışı şekil 4.5'de gösterilmiştir.



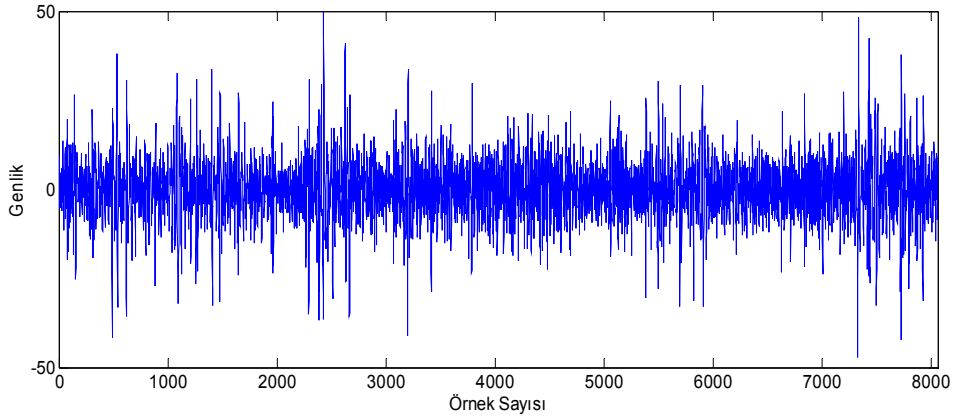
Şekil 4.5. EEG işaretinin 4 seviyeli yaklaşım ve detay katsayılarının elde edilmesi

Şekil 4.5.' de görülen detay dalgacık katsayılarının seviyelerine göre bulunduğu frekans aralığı çizelge 4.1. de gösterilmiştir.

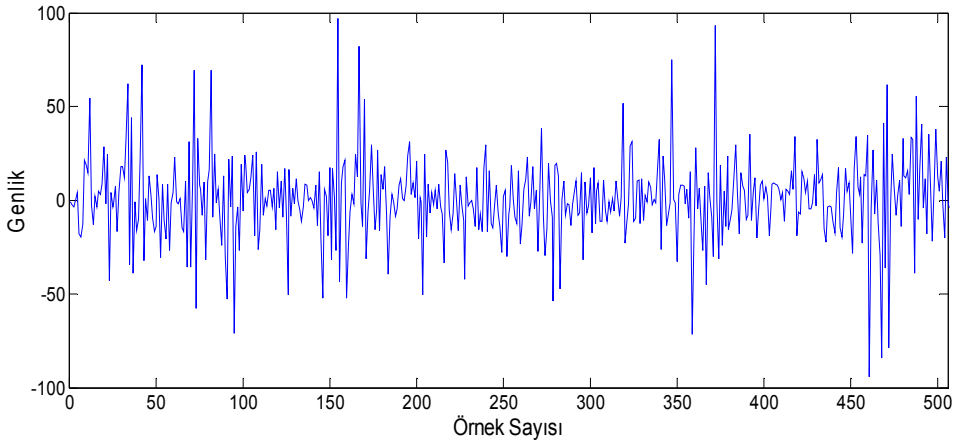
Çizelge 4.1. Detay katsayılarının seviyelerine göre bulundukları frekans aralıkları

Dalgacık Katsayıları	Frekans Aralıkları
cD1	32 – 64 Hz
cD2	16 – 32 Hz
cD3	8 – 16 Hz
cD4	4 – 8 Hz (teta)

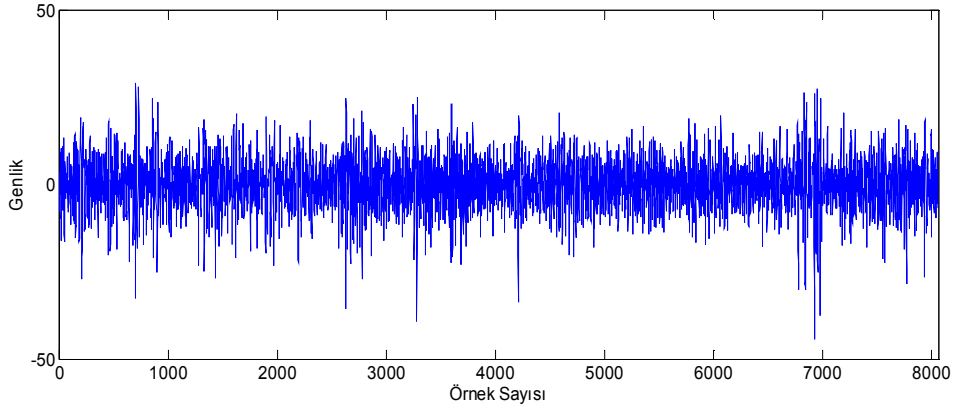
Dalgacık katsayıları işaret hakkında önemli bilgiler içerdiklerinden dolayı öznitelik vektörleri olarak değerlendirilebilir. Bu çalışmada, ADD yöntemi ile elde edilen EEG işaretlerinin teta bandındaki dalgacık katsayıları (cD4), öznitelik vektörleri olarak değerlendirilmiştir. Pozitif duygu durumuna ilişkin örnek EEG işareti ve teta bandındaki dalgacık katsayıları, Şekil 4.6. ve Şekil 4.7.'de ve negatif duygu durumlarına ilişkin örnek EEG işareti ve teta bandındaki dalgacık katsayıları ise Şekil 4.8. ve Şekil 4.9.'da gösterilmiştir.



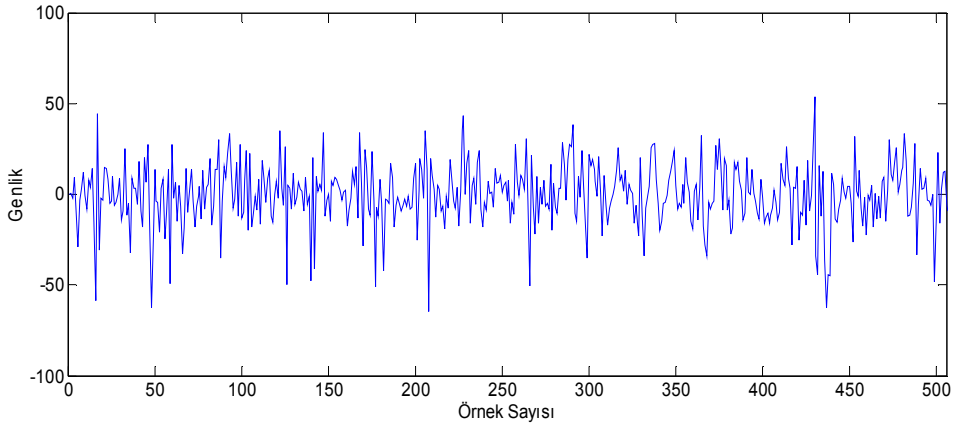
Şekil 4.6. Pozitif duygu durumuna ilişkin örnek EEG işareti



Şekil 4.7. Örnek EEG işaretinin teta bandına ait dalgacık katsayıları



Şekil 4.8. Negatif duygu durumuna ilişkin örnek EEG işareti



Şekil 4.9. Örnek EEG işaretinin teta bandına ait dalgacık katsayıları

4.3. Öznitelik Vektör Boyutunun Düşürülmesi ve Kanal Seçimi

Bu çalışmada deneye alınan 22 katılımdan her birine ait farklı duygu durumlarına ilişkin 40 EEG bölütünün sınıflandırılması için farklı algoritmalar kullanılmıştır. Katılımcıların farklı duygu durumlarına ait EEG kayıtları için öznitelik vektörleri ADD kullanılarak elde edilmiştir. EEG işaretlerinin teta bantlarına ait dalgacık katsayıları (cD4) öznitelik vektörleri olarak değerlendirilmiştir. 506 örnekten oluşan öznitelik vektör boyutlarının düşürülmesi için teta bandındaki katsayılardan 5 adet istatistiksel veri elde edilmiştir. Katsayılar için kullanılan bu istatistiksel veriler; mutlak değerce en büyük değer, kuvvetlerinin ortalaması, standart sapma, ortalama güç ve enerjidir. Belirlenen istatistiksel işlemler ve matematiksel ifadeleri aşağıda verilmiştir.

1. Katsayıların mutlak değerlerinin maksimumu:

$$x_{max} = max|x(n)| \tag{4.1}$$

2. Katsayı kuvvetlerinin ortalaması:

$$x_{ort} = \sum_{n=1}^{N} \frac{x(n)}{N} \tag{4.2}$$

Burada x(n), n=1, 2, 3, …, *N* için bir zaman serisidir.

3. Katsayıların standart sapması:

$$x_{std} = \sqrt{\frac{1}{N}\sum_{n=1}^{N}(x(n) - x_{ort})^2} \tag{4.3}$$

Burada x_{ort} , x(n) işaretinin ortalamasını ifade eder.

4. Katsayıların ortalama gücü:

$$P_{ort} = \frac{1}{N}\sum_{n=1}^{N} x^2(n) \tag{4.4}$$

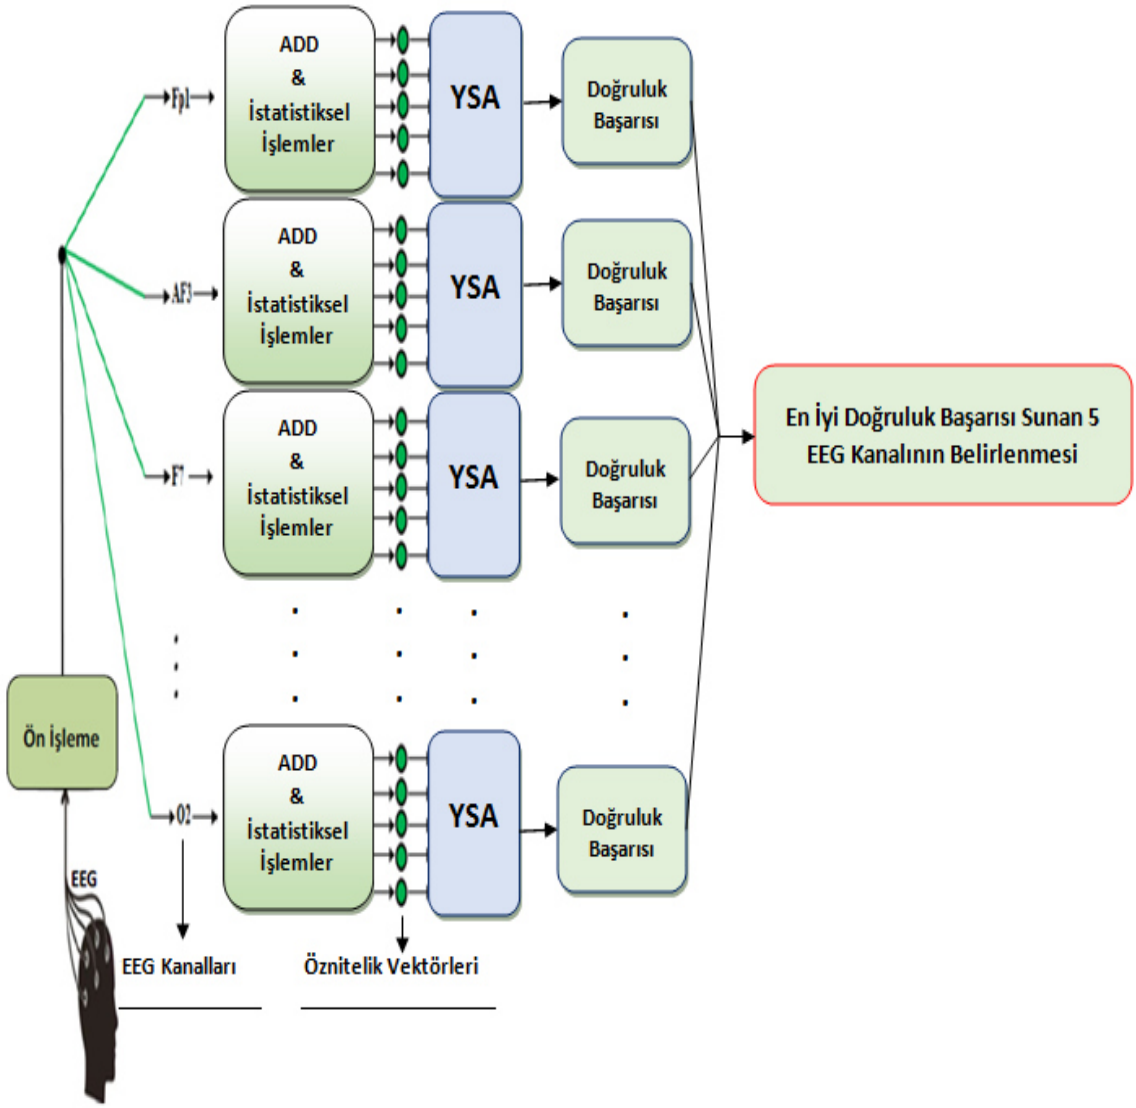
5. Katsayıların toplam enerjisi:

$$E_{top} = \frac{1}{f_s}\sum_{n=1}^{N} x^2(n) \tag{4.5}$$

Burada f_s , EEG işaretinin örnekleme hızını temsil etmektedir.

EEG işaretlerine ADD yöntemi ve istatistiksel işlemler uygulanarak beş örnekten oluşan öznitelik vektörleri elde edilmiştir. Her katılımcıdan alınan EEG kayıtlarından elde edilen öznitelik vektörleri, ilk olarak yapay sinir ağına uygulanmak üzere eğitim ve test kümelerine ayrıştırılmıştır. Yapılan analizler bütün katılımcılar için ayrı bir şekilde yapılmış ve her katılımcı için en iyi sınıflandırma performansı sunan beş EEG kanalı tespit edilmiştir (Şekil 4.10.). Tespit edilen en iyi beş EEG kanalına ait öznitelik vektörleri birleştirilerek 25 örnekten oluşan yeni öznitelik vektörleri elde edilmiştir. Böylelikle farklı duygu durumlarına ilişkin 40 adet EEG bölütünün her biri

yeni öznitelik vektörü ile temsil edilmiştir. Nihai işlem ise, 25 örnekten oluşan yeni öznitelik vektörlerinin YSA ve K-NN yöntemleri ile sınıflandırılmasıdır.

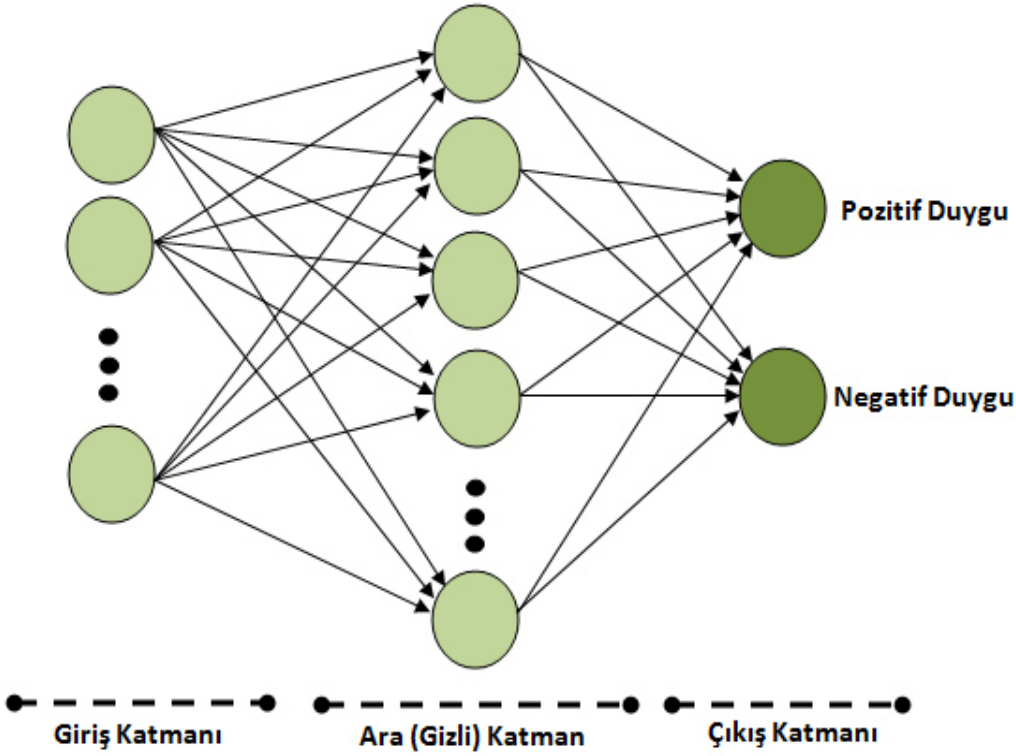


Şekil 4.10. Sınıflandırma işlemleri için kullanılan kanal seçim mekanizması

4.4. EEG Öznitelik Vektörleri ile Kanal Seçimi

Bu tez çalışmasında YSA, ilk olarak kanal seçiminde kullanılmıştır. Her katılımcının 32 kanalı ayrı ayrı değerlendirilmeye alınmış ve en iyi sınıflandırma performansı sunan beş EEG kanalı tespit edilmiştir. Bu uygulama tüm katılımcılara uygulandığında, çoğunlukla aynı kanallara ilişkin performansın yüksek olduğu görülmüştür. Her bir video sunumu için katılımcıdan alınan bir bölüt olduğuna göre, 40 video sunumunda elde edilen 40 bölütün bir kısmı pozitif ve bir kısmı ise negatif duygu

durumlarını içermektedir. Bu bölütler değerlik değerlerine bakıldığında yaklaşık yarısı pozitif ve kalan yarısı ise negatif duygu durumunu içerdiği görülmüştür. Elde edilen öznitelik vektörleri, çok katmanlı perseptron girişine uygulanmıştır. YSA çıkış vektörleri pozitif duygu durumu için [1 0], negatif duygu durumu için [0 1] olarak tanımlanmıştır. Ağın eğitimi için 30 EEG bölütü ve testi için 10 EEG bölütü kullanılmıştır. Şekil 4.11.'da kullanılan çok katmanlı YSA yapısı gösterilmiştir.



Şekil 4.11. Çalışmada Kullanılan Çok Katmanlı YSA mimarisi (25 x n x 2), n değeri gizli katmandaki nöron sayısını belirtir.

YSA mimarisi olarak tek gizli katmanlı 25xnx2 mimarisi kullanılmıştır. Gizli katmandaki nöron sayısı örnek katılımcı için n=12 olarak alınmıştır. Yapılan birçok denemede en yüksek performansın örnek katılımcı için n=12 nöron sayısında elde edildiği gözlenmiştir. Gizli katman ve çıkış katmanlarında kullanılan aktivasyon fonksiyonları sırasıyla, logsig ve tansig fonksiyonlarıdır. Eğitim aşamasında öğrenme katsayısı 0.7 ve momentum katsayısı ise 0.9 olarak alınmıştır.

EEG bölütlerinin sınıflandırmasında en iyi sonuç üreten beş EEG kanalının belirlenmesi için model başarım ölçütlerinden, doğruluk ölçütü kullanılmıştır. Doğruluk ölçütü, sınıflandırıcı algoritma tarafından çıkışta doğru sınıflandırılmış örnek sayısının

toplam örnek sayısına oranıdır. Doğruluk ile birlikte özgüllük ve duyarlılık ölçütleri de literatürde sık kullanılan başarı değerlendirme ölçütleri arasında yer alır. Bu çalışma için özgüllük, sınıflandırıcının pozitif duygu durumuna ait örnekleri doğru olarak sınıflandırma yeteneğini; Duyarlılık ise sınıflandırıcının negatif duygu durumuna ait örnekleri doğru olarak sınıflandırma yeteneğini temsil etmektedir. Doğruluk, özgüllük ve duyarlılık değerleri ağın çıkışına göre karışıklık matrisinden (Class Confusion Matrix) elde edilir. Çizelge 4.2.'de örnek bir karışıklık matrisi modeli verilmiştir.

Çizelge 4.2. Örnek bir karışıklık matrisi

		Ağın Çıkışı	
		Pozitif Duygu	**Negatif Duygu**
Doğru Sınıf	**Pozitif Duygu**	**(Doğru Pozitif) DP**	**(Yanlış Negatif) YN**
	Negatif Duygu	**(Yanlış Pozitif) YP**	**(Doğru Negatif) DN**

Çizelge 4.2.'de DP (Doğru Pozitif) ve DN (Doğru Negatif) ağın iki sınıf için doğru sınıflandırdığı örnekleri, YP (Yanlış Pozitif) ve YN (Yanlış Negatif) ise ağın iki sınıf için yanlış sınıflandırdığı örnekleri temsil eder. Eşitlik (4.6)'da doğruluk ölçütünün matematiksel ifadesi verilmiştir.

$$\text{Doğruluk} = \frac{\text{DP} + \text{DN}}{\text{DP} + \text{YP} + \text{DN} + \text{YN}} \tag{4.6}$$

Özgüllük ölçütünün matematiksel ifadesi Eşitlik (4.7)'de verilmiştir.

$$\text{Özgüllük} = \frac{\text{DP}}{\text{DP} + \text{YP}} \tag{4.7}$$

Duyarlılık ölçütünü matematiksel ifadesi Eşitlik (4.8)'de verilmiştir.

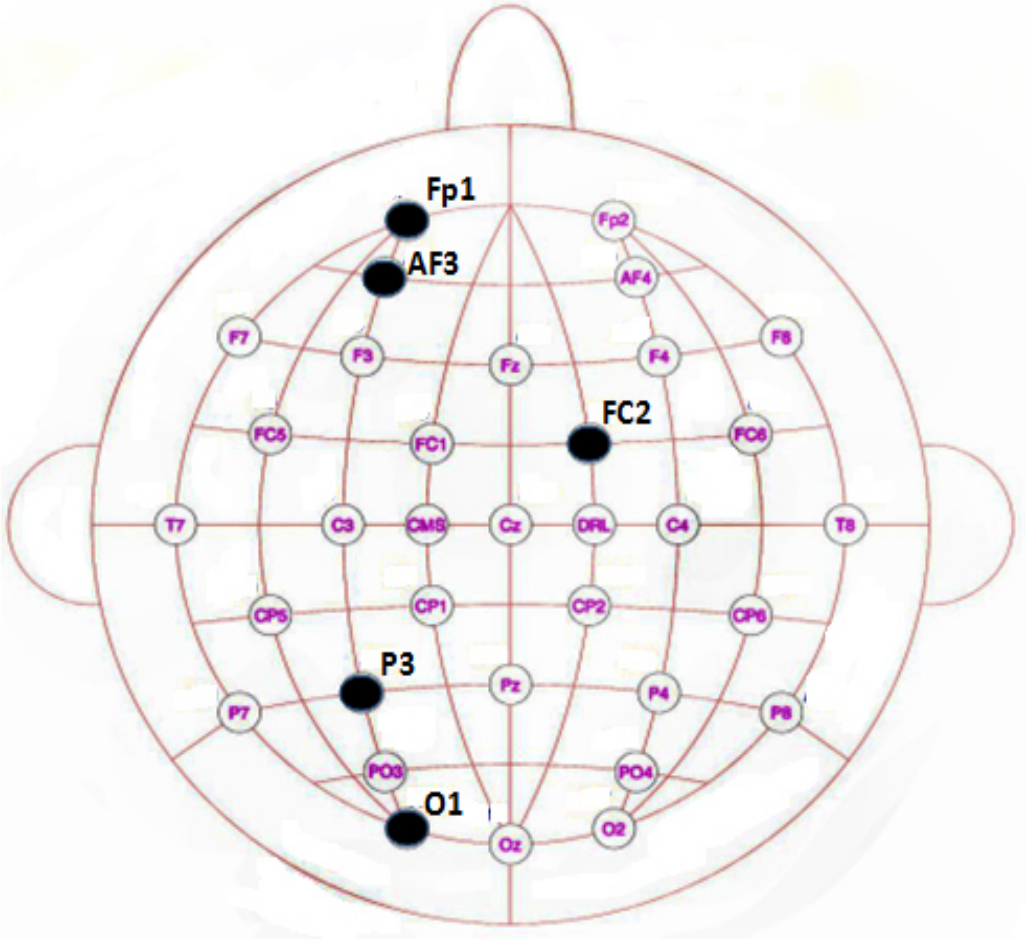
$$\text{Duyarlılık} = \frac{\text{DN}}{\text{DN} + \text{YN}} \tag{4.8}$$

Örneğin bir katılımcının 32 EEG kanalı için yapılan sınıflandırma çalışmasının başarı oranları Çizelge 4.3.'de verilmiştir. Başarının değerlendirilmesinde, doğruluk ölçütü kullanılmıştır.

Çizelge 4.3. Bir Katılımcı için kanallara göre sınıflandırma başarı oranları

EEG Kanalları	Sınıflandırma Doğruluğu
Fp1	**% 75**
AF3	**% 80**
F3	**% 71**
F7	**% 70**
FC5	**% 63**
FC1	**% 72**
C3	**% 56**
T7	**% 60**
CP5	**% 65**
CP1	**% 63**
P3	**% 82**
P7	**% 69**
PO3	**% 73**
O1	**% 79**
Oz	**% 64**
Pz	**% 64**
Fp2	**% 57**
AF4	**% 68**
Fz	**% 66**
F4	**% 61**
F8	**% 65**
FC6	**% 68**
FC2	**% 82**
Cz	**% 73**
C4	**% 61**
T8	**% 69**
CP6	**% 67**
CP2	**% 57**
P4	**% 69**
P8	**% 71**
PO4	**% 64**
O2	**% 64**

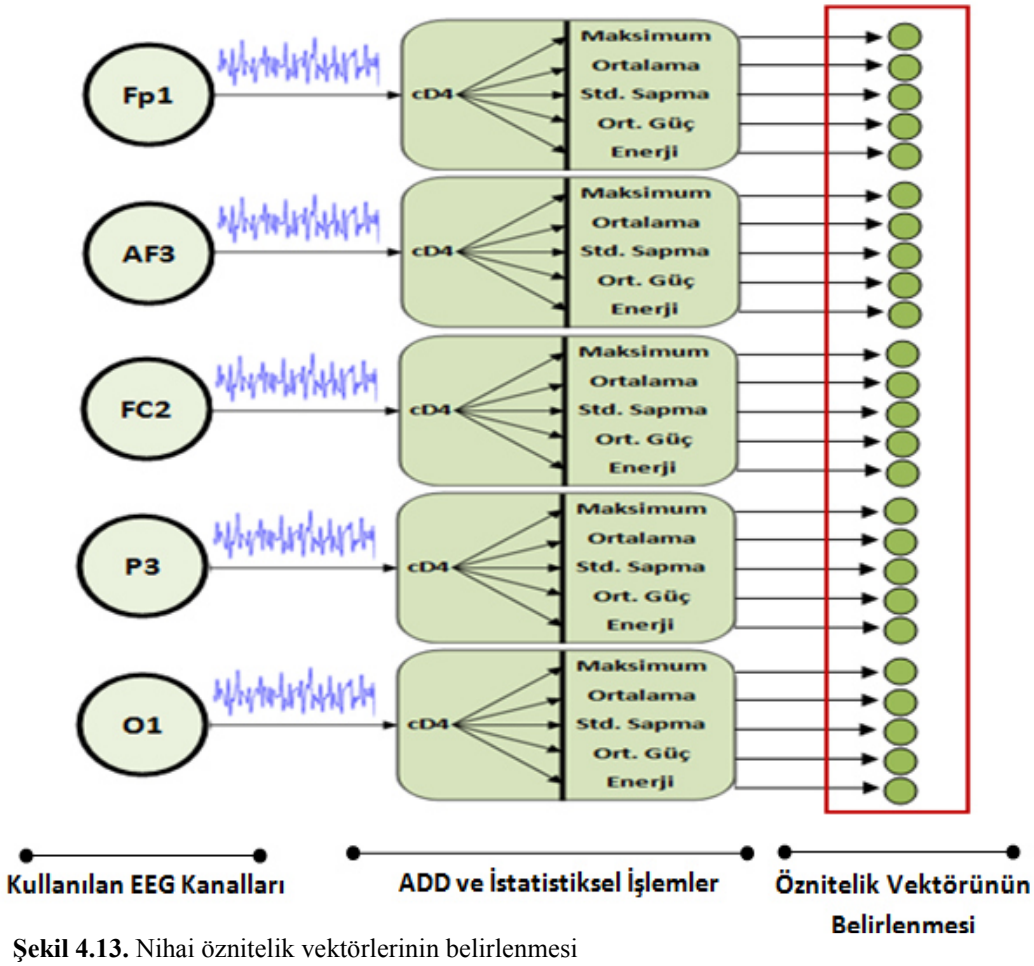
Çizelge 4.3.'de görüldüğü üzere, tüm kanal için sınıflandırma başarı ortalaması % 67.75 olduğu saptanmıştır. 32 kanal içerisinden en iyi performansı sağlayan kanalların sırasıyla P3, FC2, AF3, O1 ve Fp1 olduğu görülmektedir. Şekil 4.12.'de örnek katılımcı için en iyi sınıflandırma performansı sunan beş EEG kanalının konumları gösterilmiştir.



Şekil 4.12. Örnek katılımcı için en iyi sınıflandırma performansı sunan beş EEG kanalı

4.5. EEG Öznitelik Vektörlerinin YSA ile Sınıflandırılması

Belirlenen beş kanala ait EEG bölütlerinin öznitelikleri birleştirilerek nihai öznitelik vektörleri elde edilmiştir. Böylece pozitif ve negatif duygu durumlarına ait her EEG bölütü için beş kanaldan alınan özelliklerden 25 boyutlu nihai öznitelik vektörleri belirlenmiştir. Yapılan bütün işlemler deneye alınan 22 katılımcı için ayrı bir şekilde gerçekleştirilmiştir. Şekil 4.13.'de en iyi performansa sahip kanalların belirlenmesinden sonra, örnek bir katılımcı için nihai öznitelik vektörlerinin oluşturulma süreci gösterilmiştir.



Şekil 4.13. Nihai öznitelik vektörlerinin belirlenmesi

EEG tabanlı duyguların sınıflandırılması için her katılımcının 25 örnekten oluşan öznitelik vektörleri, çok katmanlı perseptron ağının girişine uygulanmıştır. Kanal seçiminde izlenen yaklaşım, bu aşamada da tekrar edilmiştir. YSA çıkış vektörleri pozitif duygu durumu için [1 0], negatif duygu durumu için [0 1] olarak tanımlanmıştır. Ağın eğitimi için 30 EEG bölütü ve testi için ise 10 EEG bölütü kullanılmıştır. Deneye katılan 22 katılımcı için de aynı işlemler tekrar edilmiştir.

YSA eğitim aşamasında, tek gizli katmanlı 25xnx2 mimarisi kullanılmıştır. Gizli katmandaki nöron sayısı testler sonucu her katılımcı için farklı olarak alınmıştır. Her katılımcı için en iyi sonucu sağlayan n değeri, Çizelge 4.4.' de gösterilmiştir. Gizli katmanda logsig ve çıkış katmanında tansig aktivasyon fonksiyonu kullanılmıştır. Öğrenme katsayısı 0.7, momentum katsayısı 0.9 olarak alınmıştır. Çizelge 4.4.'de görüldüğü üzere, tüm katılımcılar için doğruluk ortalama değeri % 76.25, özgüllük ortalama değeri % 81.39 ve duyarlılık ortalama değeri % 74.53 olduğu görülmüştür.

Çizelge 4.4. 22 katılımcı için YSA sınıflandırma başarıları ve gizli katman nöron sayısı

Katılımcılar	Doğruluk (%)	Özgüllük (%)	Duyarlılık (%)	Gizli Katman Nöron Sayısı
Katılımcı_ 1	% 77.5	% 78.9	% 76.2	38
Katılımcı_ 2	% 72.5	% 76.4	% 69.5	30
Katılımcı_ 3	% 80	% 89.4	% 74.1	18
Katılımcı_ 4	% 70	% 64.2	% 83.3	25
Katılımcı_ 5	-	-	-	-
Katılımcı_ 6	-	-	-	-
Katılımcı_ 7	% 80	% 100	% 71.4	25
Katılımcı_ 8	% 75	% 81.2	% 70.8	34
Katılımcı_ 9	% 90	% 100	% 83.3	22
Katılımcı_10	% 80	% 80	% 80	54
Katılımcı_11	% 60	% 62.5	% 58.3	50
Katılımcı_12	% 65	% 63.6	% 66.6	40
Katılımcı_13	% 80	% 74.1	% 89.4	39
Katılımcı_14	% 85	% 93.7	% 79.1	12
Katılımcı_15	% 75	% 91.6	% 67.8	65
Katılımcı_16	% 67.5	% 62.9	% 76.9	24
Katılımcı_17	% 80	% 87.5	% 75	8
Katılımcı_18	% 72.5	% 76.4	% 69.5	24
Katılımcı_19	% 80	% 80	% 80	27
Katılımcı_20	% 77.5	% 86.6	% 72	14
Katılımcı_21	% 80	% 100	% 71.4	25
Katılımcı_22	% 77.5	% 78.9	% 76.1	35

Her katılımcı için çapraz doğrulama yapılarak sınıflandırma sonuçları elde edilmiştir. Sonuçların başarım ölçütleri olarak doğruluk, özgüllük ve duyarlılık ölçütleri kullanılarak değerlendirilmiştir. Çizelge 4.4.'de 22 katılımcı için çok katmanlı YSA

kullanılarak yapılan sınıflandırma işlemlerine dair elde edilen başarı değerleri gösterilmiştir.

YSA parametreleri değiştirilmeden 4 katlı çapraz doğrulama yapılarak sonuçlar elde edilmiştir. Böylece her EEG bölütüne ait öznitelik vektörlerinin eğitim ve test kümelerinde yer alması sağlanmıştır. Çizelge 4.4.'de görüldüğü gibi en yüksek sınıflandırma doğrulu % 90 olarak, 9. katılımcı için elde edilmiştir. Katılımcı 5 ve 6 tarafından SAM görsellerine göre yapılan değerlendirmelerin sağlıklı olmayışından ötürü bu katılımcılar için sınıflandırma işlemleri gerçekleştirilmemiştir. Değerlendirilmeye alınan 20 katılımcı için ortalama sınıflandırma doğruluğu YSA ile % 76.25 olarak elde edilmiştir.

4.6. EEG Öznitelik Vektörlerinin kNN ile Sınıflandırılması

Bu bölümde, 22 katılımcıdan alınan pozitif ve negatif duygu durumlarına ait EEG bölütleri için belirlenen öznitelik vektörleri kNN kullanılarak da sınıflandırılmaya çalışılmıştır.

Her katılımcı için 32 kanallı EEG işaretlerinden en iyi beş kanalın öznitelikleri birleştirilerek elde edilen 25 boyutlu öznitelik vektörleri değiştirilmeden kNN algoritması ile sınıflandırılmaya çalışılmıştır. Uzaklık ölçütü olarak literatürde sık kullanılmasından dolayı Euclidean uzaklık ölçütü seçilmiştir. Algoritmanın eğitimi için 30 EEG bölütü ve testi için ise 10 EEG bölütü kullanılmıştır. 4 katlı çapraz doğrulama ile yapılan sınıflandırma sonunda her katılımcı için en az hata değeri sunan k değeri farklı olmakla birlikte, 1 ve 3 olarak belirlenmiştir. Deneye katılan 22 katılımcı için de aynı işlemler uygulanmış ve bütün katılımcılar için pozitif ve negatif duygu durumlarına ilişkin EEG bölütleri sınıflandırılmıştır. Çizelge 4.5.'de 22 katılımcı için kNN kullanılarak yapılan sınıflandırma işlemlerine dair elde edilen başarı değerleri gösterilmiştir. Sınıflandırma başarı değerlendirmelerinde Çizelge 4.4.'de olduğu gibi doğruluk, özgüllük ve duyarlılık ölçütleri kullanılmıştır. Çizelge 4.5.'de görüldüğü gibi en yüksek sınıflandırma doğrulu % 85 olarak, 14. ve 22. katılımcı için elde edilmiştir. Katılımcı 5 ve 6 tarafından SAM görsellerine göre yapılan değerlendirmelerin sağlıklı olmayışından ötürü bu katılımcılar için sınıflandırma işlemi gerçekleştirilmemiştir. Değerlendirilmeye alınan 20 katılımcı için ortalama sınıflandırma doğruluğu kNN ile % 73.75 olarak elde edilmiştir.

Çizelge 4.5. 22 katılımcı için kNN sınıflandırma başarıları

Katılımcılar	Doğruluk (%)	Özgüllük (%)	Duyarlılık (%)
Katılımcı_ 1	% 77.5	% 78.9	% 76.2
Katılımcı_ 2	% 75	% 75	% 75
Katılımcı_ 3	% 75	% 81.2	% 70.1
Katılımcı_ 4	% 55	% 53.5	% 72.7
Katılımcı_ 5	-	-	-
Katılımcı_ 6	-	-	-
Katılımcı_ 7	% 80	% 87.5	% 75
Katılımcı_ 8	% 70	% 81.2	% 64.7
Katılımcı_ 9	% 82.5	% 100	% 74
Katılımcı_10	% 77.5	% 82.3	% 73.9
Katılımcı_11	% 65	% 71.4	% 61.5
Katılımcı_12	% 65	% 71.4	% 61.5
Katılımcı_13	% 67.5	% 73.3	% 64
Katılımcı_14	% 85	% 100	% 74
Katılımcı_15	% 70	% 91.6	% 63.1
Katılımcı_16	% 62.5	% 60.8	% 64.7
Katılımcı_17	% 75	% 85.7	% 69.2
Katılımcı_18	% 72.5	% 53.5	% 58.33
Katılımcı_19	% 75	% 90.9	% 65.5
Katılımcı_20	% 82.5	% 93.3	% 76
Katılımcı_21	% 77.5	% 86.6	%72
Katılımcı_22	% 85	% 85	% 85

Çizelge 4.5.'de görüldüğü üzere, tüm katılımcılar için doğruluk ortalama değeri % 73.75, özgüllük ortalama değeri % 80.15 ve duyarlılık ortalama değeri % 69.82 olduğu görülmüştür.

5. TARTIŞMA VE SONUÇ

Bu tez çalışmasında, görsel ve işitsel kaynaklı oluşan duyguların EEG ile sınıflandırılması amaçlanmıştır.

Tez çalışmasında elde edilen sonuçlar aşağıda belirtildiği şekilde yorumlanabilir.

1) İşlem yükünün azaltılması: Ayrık dalgacık dönüşümü (ADD) kullanılarak farklı duygu durumlarına ait EEG işaretlerinden dalgacık katsayıları elde edilmiştir. Elde edilen dalgacık katsayıları öznitelik vektörleri olarak değerlendirilmiştir. Öznitelik vektör boyutları istatistiksel (mutlak değerce en büyük değer, kuvvetlerinin ortalaması, standart sapma, ortalama güç ve enerji) işlemler uygulanarak küçültülmüştür. Öznitelik vektör boyutlarının küçültülmesi ile çalışmada kullanılan sınıflandırıcı algoritmaların işlem yükü azaltılmış ve daha seri olarak başarılı sonuçların elde edilmesi sağlanmıştır.

2) Kanal seçimi: Her bir katılımcının 32 EEG kanalı için sınıflandırma işlemi yapılmış ve en iyi performansı sağlayan kanallar belirlenmiştir. 20 katılımcı için yapılan çalışmada, en iyi performansı sağlayan kanalların benzer olması önemli bir sonuçtur. Bu kanallar sırasıyla P3, FC2, AF3, O1 ve Fp1 olduğu saptanmıştır.

3) Sınıflandırma performansı (Genel): Belirlenen beş kanaldan alınan öznitelik vektörleri birleştirilerek, farklı duygu durumları için beynin farklı bölgelerinden eş zamanlı alınan EEG işaretlerinin kullanılması sağlanmıştır. Böylece her katılımcı için dinamik bir sınıflandırma işlemi gerçekleştirilebilinmesi sağlanmıştır. Sınıflandırıcı olarak çok katmanlı perceptron ve kNN algoritması kullanılmıştır. Sınıflandırma işlemleri 20 katılımcı için ayrı ayrı yapılmıştır. Ortalama değerlere bakıldığında, doğruluk, özgüllük ve duyarlılık açısından YSA'nın kNN yöntemine göre daha iyi sonuçlar ürettiği gözlenmiştir. 20 katılımcı için ortalama sınıflandırma doğruluğu YSA ile % 76.25 olarak elde edildiği görülmüştür. kNN yaklaşımında ise % 73.75 olarak elde edildiği görülmüştür.

Sınıflandırmada ortalama özgüllük değeri YSA ile % 81.39 olarak elde edildiği görülmüştür. kNN yaklaşımında ise % 80.15 olarak elde edildiği görülmüştür.

Sınıflandırmada ortalama duyarlılık değeri YSA ile % 74.53 olarak elde edilirken, kNN yaklaşımında ise % 69.82 olarak elde edildiği görülmüştür.

4) Sınıflandırma performansı (Bireysel): Her bir katılımcının bireysel olarak sınıflandırma performansları incelendiğinde, en yüksek sınıflandırma doğruluğunun YSA ile % 90 olarak elde edildiği görülmüştür. Diğer bir taraftan, en yüksek sınıflandırma doğruluğunun kNN ile % 85 olarak elde edildiği görülmüştür.

Sınıflandırmada en yüksek özgüllük değeri YSA ve kNN yaklaşımlarında % 100 olarak elde edildiği görülmüştür

Sınıflandırmada en yüksek duyarlılık değeri YSA ile % 89.4 olarak elde edilirken, kNN yaklaşımında ise % 85 olarak elde edildiği görülmüştür.

Yapılan çalışmada, çok katmanlı YSA ve kNN algoritmaları kullanılarak elde edilen sınıflandırma başarı performansları karşılaştırıldığında, çok katmanlı YSA kullanılarak farklı duygu durumlarının sınıflandırılmasında genel olarak daha iyi sonuçlar elde edildiği görülmüştür.

5) EEG Band seçimi: Literatürde teta bandının duygu ile ilişkili olduğuna ilişkin bilgiler yer almaktadır [(Koelstra ve ark. 2012), (Uusberg ve ark. 2014), (Polat ve Özerdem 2015)]. Bundan dolayı bu çalışmada doğrudan teta bandı dikkate alınmıştır. Tez kapsamında teta bandı kullanılarak elde edilen yüksek performans değerleri, teta bandının duygu ile ilişkisinin olduğunu teyit etmiştir.

6) Çalışmada kullanılan özniteliklerin güncellenmesi veya yeni özniteliklerin dahil edilmesi ile sistem performansının artacağı düşünülmektedir. İleriki aşamada sistem performansının iyileştirme üzerine çalışılması planlanmaktadır.

6. KAYNAKLAR

Abdulkader, S. N., Atia, A., Mostafa, M. M. 2015. Brain computer interfacing: Aplications and challenges. Egyptian Informatics Journal, 16: 213-230.

Adeli, H., Zhou, Z., Dadmehr, N. 2003. Analysis of EEG records in an epileptic patient using wavelet transform. Journal of Neuroscience Methods, 123 (1): 69-87.

Akçay, C., Çoruk, A. 2012. Çalışma Yaşamında Duygular ve Yönetimi: Kavramsal Bir İnceleme. Eğitimde Politika Analizi Dergisi, Cilt 1, Sayı 1: 3-25.

Bajaj, V., Pachori, R. B. 2013. Automatic classification of sleep stages based onthe time frequency image of EEG signals. Computer Methods and Programs in Biomedicine, 112: 320-328.

Batar, H. 2005. EEG İşaretlerinin Dalgacık Analiz Yöntemleri Kullanılarak Yapay Sinir Ağları ile Sınıflandırılması. Yüksek Lisans Tezi, KSÜ Fen Bilimleri Enstitüsü, Kahramanmaraş, 102.

Berrueta, L.A. Alonso, R. M. Heberger, K. 2007. Supervised pattern recognition in food analysis. Journal of Chromatography A, 1158: 196-214.

Bradley, M. M., Lang, P.J. 1994. Measuring emotions: The Self-Assessment Manikin and the Sematic Differential. Journal of Behavior Therapy and Experimental Psychiatry, 25 (1): 49-59.

Brereton, R. G. 2003. Data Analysis fort he Laboratory and Chemical Plant. John Wiley and Sons Ltd, 489, England.

Çağlar, M. F. 2007. Yapay Sinir Ağı ile Smith Abağı Modeli. Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 154.

Çolak, Ö. H. 2006. Dalgacık Dönüşümü Kullanılarak Sismik Sinyallerin Analizi. Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya, 107.

Daubechies, I. 1990. The Wavelet Transform, Time-Frequency Localization and Signal Analysis. IEEE Transactions on Information Theory, 36 (5): 961-1005.

DEAP. 2012. A Dataset for Emotion Analysis EEG Physiological and Video Signals. Erişim: [http://www.eecs.qmul.ac.uk/mmv/datasets/deap/index.html], Erişim Tarihi: 01.05.2015

Elmas, Ç. 2007. Yapay Zeka Uygulamaları. Seçkin Yayıncılık, Sayfa: 425, Ankara.

Estrada, E., Nazeran, H., Sierra, G., Ebrahimi, F., Setarehdan, S. K. 2011. Wavelet-based EEG denoising for automatic sleep stage classification. 21st International Electrical Communications and Computers, San Andres Cholula, 295-298.

Falamarzi, Y., Palizdan, N., Huangb, Y. F., Lee, T. S. 2014. Estimating evapotranspiration from temperature and wind speeddata using artificial and wavelet neural networks (WNNs). Agricultural Water Management, 140: 26-36.

Ferreira, J. E. V., Costa, C. H. S., Miranda, R. M., Figueiredo, A. F. 2015. The use of the k nearest neighbor method to classify the representative elements. Education Quimica, 26: 195-201.

Fu, K., Qu, J., Chai, Y., D, Y. 2014. Classification of seizure based on the time-frequency image of EEG signals using HHT and SVM. Biomedical Signal Processing and Control, 13: 15-22.

Haykin, S. 2009. Neural Networks and Learning Machines (3rd Edition). Prentice Hall, Sayfa: 906, New Jersey.

Hazarika, N., Chen, J. Z., Tsoi, A. C., Sergejew, A. 1997. Classification of EEG signals using the wavelet transform. Signal Processing, 59: 61-72.

Hogan, M. J., Swanwick, G. R. J., Kaiser, J., Rowan, M., Lawlor, B. 2003. Memory related EEG power and coherence reductions in mild Alzheimer's disease. International Journal of Psychophysiology, 49: 147-163.

Kıymık, M. K., Akın, M., Subaşı, A. 2004. Automatic recognition of alertness level by using wavelet transform and artificial neural network. Journal of Neuroscience Methods, 139: 231-240.

Klimesch, W. 1999. EEG alpha and theta oscillations reflect cognitive and memory performance: a review and analysis. Brain Research Reviews, 29: 169-195.

Koelstra, S., Mühl, C., Soleymani, M., Lee, J., Yazdani, A., Ebrahimi, T., Pun, T., Nijholt, A., Patras, I. 2012. DEAP: A Database for Emotion Analysis using Physiological Signals. IEEE Transactions on Affective Computing, 3 (1): 18-31.

Kriesel, D. 2005. A Brief Introduction to Neural Networks. Erişim: [http://www.dkriesel.com/en/science/neural_networks], Erişim Tarihi: 27.05.2015

Larose, D. T. 2005. Discovering Knowledge in Data. A John Wiley and Sons INC, Sayfa: 222, New Jersey.

Lee, G., Kwon, M., Sri, S. K., Lee, M. 2014. Emotion recognition based on 3D fuzzy visual and EEG features in movie clips. Neurocomputing, 144: 560-568.

Leeb, R., Lancelle, M., Kaiser, V., Fellner, D. W., Pfurtscheller, G. 2013. Thinking Penguin: Multimodal Brain Computer Interface Control of a VR Game. IEEE Transaction on Computational Intelligence and AI in Games, 5(2): 117-128.

Lin, Y. P., Wang, C. H., Jung, T. P., Wu, T. L., Jeng, S. K., Duann, J. R., Chen, J. H. 2010. EEG-Based Emotion Recognition in Music Listening. IEEE Transaction on Biomedical Engineering, 57 (7): 1798-1806.

Lopetegui, E., Zapirain, B.G., Mendez, A. 2011. Tennis computer game with brain control using EEG signals. The 16 th International Conference on Computer Games, USA, 228-234.

Misiti, M., Misiti, Y., Oppenheim, G., Poggi, J.M. 1997-2002. Wavelet Toolbox For Use with Matlab. The MathWorks Inc., United States.

Ocak, H. 2008. Optimal classification of epileptic seizures in EEG using waveletanalysis and genetic algorithm. Signal Processing, 88: 1858-1867.

Orhan, U., Hekim, M., Ozer, M. 2011. EEG signals classification using the K-means clustering and a multilayer perceptron neural network model. Expert Systems with Applications, 38: 13475-13481.

Öztemel, E. 2003. Yapay Sinir Ağları. Papatya Yayıncılık, Sayfa: 238, İstanbul

Petrantonakis, P. C., Hadjileontiadis, L. J. 2010. Emotion Recognition from Brain Signals Using Hybrid Adaptive Filtering and Higher Order Crossing Analysis. IEEE Transactions on Affective Computing, 1 (2): 81-97.

Polat, H., Ozerdem, M.S. 2015. Reflection emotions based on different stories onto EEG signal. 23th Signal Processing and Communications Applications Conference, Malatya, 2618-2618.

Polikar, R. 2006. The Engineer's Ultimate Guide to Wavelet Analysis. Erişim: [http://person.hst.aau.dk/enk/ST8/wavelet_tutotial.pdf], Erişim Tarihi: 05.11.2015

Rumelhart, D. E., Hinton, G. E., Williams, R. 1986. Learning internal representations by error propagation. Rumelhart, D. E. McClelland, J. L. Parallel Distributed Processing. MIT Press, 318-362, United Kingdom.

Sanei, S., Chambers, J. A. 2007. EEG Signal Processing. John Wiley and Sons Ltd, 289, United Kingdom.

Schaaff, K., Schultz, T. 2009. Toward Emotion Recognation from Electroencephalographic Signals. 3th İnternational Conference on Affective Computing and Intelligent Interaction and Workshop, Netherlands, 1-6.

Subaşı, A. 2007. Signal Classification using Wavelet Feature Extraction and A Mixture of Expert Model. Expert System with Applications, 32: 1084-1093.

Subaşı, A., Erçelebi, E. 2005. Classification of EEG signals using neural network and logistic regression. Computer Methods and Programs in Biomedicine, 78: 87-99.

Tepe, C. 2009. EKG Sinyalinde Gürültü Gidermede Dalgacık Dönüşümü Kullanılması. Yüksek Lisans Tezi, Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü, Samsun, 152.

Uusberg, A., Thiruchselvam, R., Gross, J. 2014. Using distraction to regulate emotion: Insights from EEG theta dynamics. International Journal of Psychophysiology, 91: 254-260.

Übeyli, E. D., Güler, İ. 2004. Dalgacık Dönüşümü ile EEG İşaretlerinden Çıkarılan Öznitelik Vektörleri Üzerine İstatistiksel İşlemlerin Gerçekleştirilmesi. Elektrik Elektronik- Bilgisayar Sempozyumu, Bursa, 230-234.

Wada, Y., Nanbu, Y., Kikuchi, M., Koshino, Y., Hashimoto, T., Yamaguchi, N. 1998. Abnormal functional connectivity in Alzheimer's disease: intrahemispheric EEG coherence during rest and photic stimulation. Eur Arch Psychiatry Clin Neurosci, 248: 203-208.

Wang, X. W., Nie, D., Lu, B. L. 2014. Emotional state classification from EEG data using machine learning approach. Neurocomputing, 129: 94-106.

Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., Vaughan, T. M. 2002. Brain-computer interfaces for communication and control. Clinical Neurophysiology, 113: 767-791.

Wolpaw, J. R., McFarland, D. J., Vaughan, T. M., Schalk, G. 2003. The Wadsworth Center Brain-Computer Interface (BCI) Research and Development Program. IEEE Transction on Neural Systems and Rehabilitation Engineering, 11 (2): 204-207.

Yazgan, E. Korurek, M. 1996. Tıp Elektroniği. İTÜ Matbaası, 220, Türkiye.

6. KAYNAKLAR

ÖZGEÇMİŞ

Adı Soyadı: Hasan POLAT

Doğum Yeri: Bingöl

Doğum Tarihi: 01.07.1989

Medeni Hali: Bekar

Yabancı Dili: İngilizce

Eğitim Durumu (Kurum ve Yıl)

Lise: Bingöl Anadolu Öğretmen Lisesi / Bingöl, 2007

Lisans: SDÜ, Elektronik ve Haberleşme Mühendisliği / Isparta, 2012

Çalıştığı Kurum / Kurumlar ve Yıl:

Muş Alparslan Üniversitesi

Araştırma Görevlisi (2014 - Halen), Muş

Ulusal ve Uluslar Arası Kongre ve Sempozyumlarda Sunulmuş Bildiriler

1- Dalgacık Katsayıları ve Yapay Sinir Ağları Kullanılarak EEG İşaretlerinin Sınıflandırılması, TIPTEKNO 2014, Nevşehir

2- Farklı Hikayelerden Kaynaklı Oluşan Duyguların EEG İşareti Üzerine Yansıması, SİU 2015, Malatya

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

ÖĞRENCİ BİLGİLERİ	
ADI VE SOYADI	Hasan Polat
ÖĞRENCİ NO	13805004
EĞİTİM – ÖĞRETİM YILI	2015-2016
YARIYIL	☒Güz☐Bahar
ANABİLİM DALI	Elektrik – Elektronik Mühendisliği Anabilim Dalı
PROGRAM	☒ Yüksek Lisans ☐ Doktora☐Tezsiz Yüksek Lisans (Dönem Projesi)
TEZ KONUSU	Görsel-İşitsel Uyaranlar Kaynaklı Oluşan Duyguların EEG İşaretleri ile Sınıflandırılması
İNTİHAL RAPORU BİLGİLERİ	
RAPOR TÜRÜ	☒Tez Savunma Sınavı Öncesi☐Tez Savunma SınavıSonrası
SAYFA SAYISI	90
BENZERLİK ORANI	%15
RAPORLAMA TARİHİ	07 / 01 / 2016

Yukarıda başlığı/konusu gösterilen tez çalışmamın kapak sayfası, giriş, ana bölümler, sonuç ve tartışma kısımlarından oluşan toplam **90** sayfalık kısmına ilişkin, **07/01/2016** tarihinde şahsım/tez danışmanım tarafından ***Turnitin*** adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı %15 'dir.

Uygulanan filtrelemeler:

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

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

Gereğini saygılarımla arz ederim.

Hasan Polat

07./01./2016	.07./01./2016
Doç. Dr. Mehmet Siraç Özerdem **Tez Danışmanı**	Prof. Dr. İbrahim Kaya **Anabilim Dalı Başkanı**