



MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**EEG SİNYALLERİNİN DALGACIK DÖNÜŞÜMÜ VE
ORTAK VEKTÖR YAKLAŞIMI İLE
SINIFLANDIRILMASI**

HATİCE PINAR ÜNAL

YÜKSEK LİSANS TEZİ

Mekatronik Mühendisliği Anabilim Dalı

DANIŞMAN

Prof. Dr. Gökhan GÖKMEN

Eş-Danışman

Dr. Mehmet YUMURTACI

İSTANBUL, 2021



MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**EEG SİNYALLERİNİN DALGACIK DÖNÜŞÜMÜ VE
ORTAK VEKTÖR YAKLAŞIMI İLE
SINIFLANDIRILMASI**

HATİCE PINAR ÜNAL
523517011

YÜKSEK LİSANS TEZİ
Mekatronik Mühendisliği Anabilim Dalı

DANIŞMAN
Prof. Dr. Gökhan GÖKMEN
Eş-Danışman
Dr. Mehmet YUMURTACI

İSTANBUL, 2021

TEŞEKKÜR

Tez çalışmam boyunca yol gösterici oldukları için, sundukları katkılar için danışmanlarım Prof. Dr. Gökhan GÖKMEN ve Dr. Mehmet YUMURTACI hocalarıma; tez konumu belirlediğim ilk zamanlardan beri mentörlüğüyle destek olan Prof. Dr. Tahir Çetin AKINCI hocama saygılarımla teşekkürlerimi sunarım.

Tez sürecimde manevi desteklerinin yanı sıra takıldığım teknik konularda destek olan değerli arkadaşlarım S. Engin BAĞLAYICI 'ya, Ferzender VARLI'ya, Beytullah NALBANT'a, Abdullah KILIÇASLAN'a; tez yazım sürecinde yazım kuralları, içerik uyumu vb. konularda destek olan değerli arkadaşlarım Fatma Nur KAPTANOĞLU'na, M. Burak BİLGİÇ'e, Kardelen A. ALMASULU'ya; tez sürecimde destekleriyle motivasyon kaynağı olan değerli arkadaşlarım Nihan MUTLU'ya, Elif ŞEN'e, Nazife KOCA'ya, F. Zehra ÜNAL'a ve Şevin DİZİN'e teşekkürlerimi sunarım.

Maddi ve manevi her türlü desteği vererek, her daim yanımda olan değerli dayılarım Şahin- Latif ÇELİK'e, teyzem Gülseven SÖKER'e ve kuzenim Hilal SÖKER'e teşekkürlerimi sunarım.

Hayatım boyunca aldığım her karara saygı duyarak benimle çabalayan, maddi ve manevi her türlü ihtiyacımda destek olan, büyük bir sabır ve özveri ile bu süreçte de yanımda olan değerli babam Orhan ÜNAL'a, değerli annem Gülşen ÜNAL'a ve değerli kardeşim Elif Pelin ÜNAL'a sonsuz minnetimi ve teşekkürlerimi sunarım.

İÇİNDEKİLER

	Sayfa
TEŞEKKÜR.....	i
ÖZET	iv
ABSTRACT	v
SEMBOLLER.....	vi
KISALTMALAR	vii
ŞEKİL	viii
TABLO LİSTESİ.....	ix
1. GİRİŞ.....	1
1.1. Literatür Taraması	3
2. MATERYAL VE YÖNTEM.....	10
2.1. Elektroensefalogram(EEG).....	10
2.1.1.DEAP Veri Seti	12
2.2. Duygu Analiz Yöntemleri.....	15
2.2.1.Ayrık Duygu Modeli	16
2.2.2.Çok Boyutlu Duygu Uzay Modeli	17
2.3. Sinyal İşleme Metotları.....	17
2.3.1.Dalgacık Analizi.....	19
2.3.1.1. Dalgacık Paket Dönüşümü.....	19
2.3.2.İstatistiksel Metotlar	21
2.3.3.Enerji	22
2.3.4.Entropi.....	22
2.3.4.1. Shannon Entropisi	23
2.3.5.Hjorth Parametresi.....	23
2.4. Sınıflandırma Yöntemleri	24
2.4.1.Destek Vektör Makineleri	24
2.4.1.1. Doğrusal Destek Vektör Makineleri	25
2.4.1.2. Doğrusal Olmayan Destek Vektör Makineleri.....	26
2.4.2.Ortak Vektör Yaklaşımı	27
2.4.2.1. Yetersiz Veri Durumu	28
2.4.2.2. Yeterli Veri Durumu	29

3. BULGULAR VE TARTIřMA.....	32
4. SONUÇ	43
KAYNAKLAR	45
EKLER	51
ÖZGEÇMİř	



ÖZET

EEG SİNYALLERİNİN DALGACIK DÖNÜŞÜMÜ VE ORTAK VEKTÖR YAKLAŞIMI İLE SINIFLANDIRILMASI

Duygular, insanların psikolojik durumunu oluşturan, buna bağlı olarak günlük yaşantısında yaptığı faaliyetlerin verimini etkileyen en önemli kavramlardandır. Duygu işleme yeteneği olmayan bilgisayarların ve robotların, doğal şekilde insanlarla iletişim kurması beklenemez. Son yıllarda yapılan araştırmalarda insan bilgisayar etkileşimine diğer bir ifadeyle bilgisayarların duyguları analiz etmesine odaklanılmıştır.

Duygu analiziyle insan makine etkileşiminin artırılması; beyin kontrolüyle çalıştırılabilecek sistemler için geliştirilen beyin bilgisayar arayüzleri, e- ticaret, oyun endüstrisi, güvenlik, sağlık gibi farklı alanların gelişimine katkı sağlayacaktır. Ancak duyguların kişiden kişiye değişmesi, insanların aynı görsele farklı duygusal tepkiler verebilmesi gibi sebepler duygu analizini zorlaştırmaktadır. Duygu tahmini yüz ifadelerinin, mimiklerin, seslerin kullanılmasıyla ilk olarak 1990'lı yıllarda yapılmıştır. Bu verilerin elde edilmesi kolay olsa da manipüle edilmeye yatkın olduklarından yanıltıcı tahminlere neden olabilmektedir. Fizyolojik sinyaller daha güvenilir olduğundan duygu tahmini için tercih edilmektedir. Son yıllarda EEG cihazlarının gelişimi, kanal sayısının azaltılmasıyla taşınmasının ve veri alımının kolaylaşması gibi etkenlerden dolayı EEG verileri daha çok tercih edilmektedir.

Bu tez çalışmasında duygu analizi aşamalarında kullanılan çeşitli yöntemlerin sınıflandırma başarımına etkisi incelenmiştir. EEG sinyali analizinde ilk defa Ortak Vektör Yaklaşımı yöntemi kullanılmıştır. Duygu analizi konusunda tercih edilen en popüler açık kaynak veri seti olan DEAP veri seti kullanılmıştır. İlk olarak 4. seviye daubuchies4 dalgacığı ile frekans bantlarına ayrılan EEG sinyallerinin örneklemleri çeşitli sinyal işleme metotları aracılığıyla tek boyuta indirgenmiş ve enerji metodunun daha başarılı sonuç verdiği gözlemlenmiştir. Ardından 32 kanal ve 10 kanal için; Ortak Vektör Yaklaşımı, Destek Vektör Makineleri yöntemleriyle toplu ve bireysel olarak analiz edilerek sınıflandırma sonuçları tablolar ile sunulmuştur. Sınıflandırmaların çoğunluğunda Ortak Vektör Yaklaşımı yöntemi daha başarılı olmuştur.

ABSTRACT

EEG SIGNALS CLASSIFICATION WITH WAVELET TRANSFORMS AND COMMON VECTOR APPROACH

Emotions are one of the most important concepts that constitute the psychological state of people and therefore affect the efficiency of the activities they do in their daily life. Computers and robots that do not have the ability to process emotions cannot be expected to communicate with humans naturally. Recent research has focused on human-computer interaction, in other words, computers to analyze emotions.

Increasing human-machine interaction with sentiment analysis; Brain-computer interfaces developed for systems that can be operated with brain control will contribute to the development of different fields such as e-commerce, game industry, security, and health. However, the reasons such as the change of emotions from person to person and the fact that people can give different emotional reactions to the same visual make it difficult to analyze the emotions. Emotion prediction was first made in the 1990s by using facial expressions, gestures, and voices. Although these data are easy to obtain, they can lead to misleading estimates as they tend to be manipulated. Physiological signals are preferred for emotion prediction because they are more reliable. In recent years, EEG data are more preferred due to factors such as the development of EEG devices, the reduction in the number of channels, and the ease of transportation and data acquisition.

In this thesis, the effect of various methods used in emotion analysis stages on classification performance was examined. The common Vector Approach method was used for the first time in EEG signal analysis. The DEAP data set, which is the most popular open-source data set for sentiment analysis, was used. First, the samples of EEG signals divided into frequency bands with level 4 daubuchies4 wavelet were reduced to one dimension by means of various signal processing methods and it was observed that the energy method gave more successful results. Then for 32 channels and 10 channels; By analyzing the Common Vector Approach and Support Vector Machines methods collectively and individually, the classification results are presented in tables. The Common Vector Approach method has been more successful in most of the classifications.

SEMBOLLER

δ : Delta Bant Aralıđı

θ : Teta Bant Aralıđı

α : Alfa Bant Aralıđı

β : Beta Bant Aralıđı

γ : Gama Bant Aralıđı

Hz : Hertz



KISALTMALAR

ADD	: Ayrık Dalgacık Dönüşümü
AO	: Aritmetik Ortalama
CLT	: Classification Learner Tool
db	: Daubuchies
DPD	: Dalgacık Paket Dönüşümü
DVM	: Detek Vektör Makinesi
EEG	: Elektroensefalogram
EKG	: Elektrokardiyagram
EMG	: Elektromiyogram
EOG	: Elektrookülogram
EYB	: En Yüksek Başarım
GDR	: Galvanik Deri Tepkisi
K-nn	: En Yakın Komşu Algoritması
OB	: Ortalama Başarım
Ort	: Ortalama
OVY	: Ortak Vektör Yaklaşımı
Pleths.	: Pletismograf
RSP	: Solunum
SAM	: Kişisel Değerlendirme Anketi
SS	: Standart Sapma
T	: Sıcaklık

ŞEKİL

Şekil 2. 1.	Uluslararası 10/20 EEG kanal yerleşim sistemi.	10
Şekil 2. 2.	EEG sinyali: (a) İşlenmemiş sinyal örneği; (b) Tepeden tepeye sinyal değeri ölçme tekniği.	11
Şekil 2. 3.	Fizyolojik sinyallerin alındığı sensörlerin yerleşimi.	14
Şekil 2. 4.	Bir katılımcının deneyden önceki görüntüsü.	14
Şekil 2. 5.	Kişisel değerlendirme için kullanılan resimler. Yukarıdan aşağıya Değerlik SAM, Uyarılma SAM, Baskınlık SAM, Beğenme	15
Şekil 2. 6.	İki boyutlu duygu modeli.	17
Şekil 2. 7.	db4 dalgacığı.	20
Şekil 2. 8.	db4 4. seviye DPD.....	21
Şekil 2. 9.	Doğrusal DVM modeli.....	25
Şekil 2. 10.	Doğrusal olmayan DVM modeli.	26
Şekil 3. 1.	EEG sinyalini frekans bantlarına ayırıştırma aşamaları.....	33
Şekil 3. 2.	32. Kullanıcının 1. video verisi için 1. kanaldan DPD analiziyle oluşturulan alt bant verileri.....	34
Şekil 3. 3.	Uyaranların değerlendirme aşamaları.	35
Şekil 3. 4.	CLT analiz örneği.	36
Şekil 3. 5.	Özellik vektörlerinin sınıflandırılma aşamaları.	37
Şekil 3. 6.	32. kullanıcının 1. video için 32. kanaldan alınan verilerden enerji yöntemi ile oluşturulan özellik vektörleri.....	39
Şekil 3. 7.	OVY ve DVM sınıflandırma aşamaları.	40

TABLO LİSTESİ

Tablo 2. 1.	Beyin dalgalarının frekans bant aralıkları.	11
Tablo 2. 2.	DEAP veri seti içerik özeti.	13
Tablo 2. 3.	EEG öznitelikleri ve formülleri.	21
Tablo 3. 1.	Özellik vektörlerinin değişimiyle elde edilen sınıflandırma başarımları oranları	38
Tablo 3. 2.	DVM ve OVY yöntemi ile 32 kanal için değerlik düzleminde yapılan sınıflandırma sonuçları.	41
Tablo 3. 3.	DVM ve OVY yöntemi ile 32 kanal için uyarılma düzleminde yapılan sınıflandırma sonuçları.	41
Tablo 3. 4.	DVM ve OVY yöntemi ile 10 kanal için değerlik düzleminde yapılan sınıflandırma sonuçları.	42
Tablo 3. 5.	DVM ve OVY yöntemi ile 10 kanal için uyarılma düzleminde yapılan sınıflandırma sonuçları.	42
EK 1-Tablo 1.	OVY yöntemi ile değerlik düzleminde yapılan bireysel sınıflandırma sonuçları	51
EK 1-Tablo 2.	OVY yöntemi ile uyarılma düzleminde yapılan bireysel sınıflandırma sonuçları	52
EK 1-Tablo 3.	DVM yöntemi ile değerlik düzleminde yapılan bireysel sınıflandırma sonuçları	53
EK 1-Tablo 4.	DVM yöntemi ile uyarılma düzleminde yapılan bireysel sınıflandırma sonuçları	54

1. GİRİŞ

Elektroensefalogram (EEG), saç derisine yerleştirilen birkaç elektrot ile insan beyninin ürettiği elektriksel aktiviteyi kaydetmek için kullanılan bir cihazdır. EEG sinyali, insan beyninde akan elektrik akımının bir göstereimidir. Beyinde meydana gelen elektriksel aktivitelerin farklı duygu durumlarında; psikolojik, nörolojik çeşitli hastalıklarda farklılık gösterdiği ve yaşam süresince her düşüncede farklı sinyaller ürettiği düşünülmektedir. Bu sinyal farklılığının sınıflandırılması ile epilepsi, alzheimer, uyku bozukluğu gibi nörolojik hastalıkların; anksiyete, depresyon vb. psikolojik hastalıkların teşhisi ve duygu durum analizi yapılabilmektedir.

Duygu kişinin biyokimyasal ve çevresel etmenlerle etkileşiminden ötürü ruh halinde meydana gelen psiko-fizyolojik bir değişimdir [1]. Duygular, günlük hayatta insanlarla iletişimimizi, psikolojimizi etkilemesinin yanında fizyolojik değişimlere de sebep olur ve kararlarımızı etkiler. Olumlu duygular sağlığını ve çalışma verimimize pozitif katkı sağlarken olumsuz duygular sağlık sorunlarına sebep olabilmektedir [2], [3]. Bu sebeplerle insan etkileşiminde son derece önemli olan duyguların tanınması önem teşkil etmektedir. Reklamların analizini ve etkinliğini EEG aracılığıyla ölçümleyen nöropazarlama, oyun sektörü gibi çeşitli ticari alanlar, girişimcilik alanı, sorgulama sırasında yalan tespiti için güvenlik alanı, duygularını ifade edemeyen engelli kişilerle iletişim kurabilmek ve psikolojik analizlere katkı sağlamak gibi sebeplerle sağlık alanı, duygu tanıma sistemleri aracılığıyla öğrenme faaliyetlerinin incelenmesi ile e-egitim alanı gibi birçok alanı ilgilendirmektedir [3] – [5]. Duygu tanıma üzerine yapılan çalışmaların çoğunluğunda farklı yöntemler denenerek sınıflandırma başarımlarının yükseltilmesi amaçlanmaktadır.

Duyguları tanıyabilmek amacıyla fiziksel sinyallerin ve fizyolojik sinyallerin kullanılma durumuna göre ikiye ayrılabilir. Fiziksel sinyaller; ses, duruş, jest ve mimikler gibi kamera, mikrofon vb. araçlar ile verilerin alınması daha kolay olmaktadır. Ancak bu sinyallerin değiştirilmesi daha kolay olduğu için güvenilirliği düşmektedir. Örnek vermek gerekirse, normalde üzgün olan kişi çalışma ortamında fiziksel olarak bu durumu gizleyebilir. EEG, elektrokardiyogram (EKG), elektromiyogram (EMG), solunum (RSP), vücut sıcaklığı (T), Galvanik Deri Tepkisi (GDR) gibi sinyallerden oluşan fizyolojik

sinyallerin deęiřtirilmesi ise daha zordur [3]. Bu nedenle, fizyolojik sinyaller ile daha gvenilir duygu tahmini yapılabilmektedir [2]. Bundan dolayı, EEG sinyalleri aracılığıyla duygu sınıflandırma gncel ve araştırılması gereken bir konudur.

EEG sinyali ile duygu sınıflandırması konusunda yapılan alıřmalarda, akademik e-posta ile ulařılabilen aık kaynak veri setleri ya da alıřma sırasında alınan veriler kullanılmıřtır. Aık kaynak veri setleri ile yapılan dięer alıřmalarda kullanılan yntemlerin kıyaslanabilmesi, laboratuvar masrafının olmaması, katılımcı ya da denek ihtiyacının olmaması, deney srecinde geen zamandan tasarruf edilebilmesi, maliyetinin az olması gibi nedenlerle aık kaynak veri setleri ilgi grmektedir. EEG sinyalli ile duygu sınıflandırma arařtırmaları iin oluřturulan aık kaynak veri setleri; Monhab HCI veri set, EMDb, DECAF, SJTU Duygu EEG veri seti ve DEAP veri setidir [4], [6] – [8]. Bu veri setleri arasında en ok tercih edilen veri seti DEAP veri setidir [4],[6].

EEG sinyallerinin analizi ve yorumlanması iin verilerin alınması, zellik ıkarımı ve sınıflandırma yntemi nem arz etmektedir. Dřk frekans bandında olan EEG sinyallerinin yorumu iin zellik ıkarım ynteminin seimi, sınıflandırmanın doęruluęunu byk lde etkileyecektir. Bu alanda yapılan pek ok arařtırma mevcuttur [3] ve duraęan olmayan EEG sinyallerinin zellik ıkarımı iin dalgacık dnřm ynteminin daha bařarılı sonu verdięi grlmřtr. Bu nedenle, tez alıřmasında dalgacık dnřm kullanılacaktır. Literatre gre sınıflandırma yntemi olarak; K En Yakın Komřu(k -NN), Destek Vektr Makineleri (DVM), Karesel Diskriminant Analizi (KDA), Doęrusal Diskriminant Analizi (DDA), İleri Kademeli Sinir Aęları, Rastgele Orman (RO), Yapay Sinir Aęları (YSA), Radyal Tabanlı Sinir Aęları yntemlerinin kullanıldıęı grlmřtr. Bu yntemlerden farklı olarak, bu tez alıřmasında Ortak Vektr Yaklařımı (OVY) kullanılacaktır. Bu yntem ile yapılacak sınıflandırma bařarısı deęerlendirilecektir.

Bu tez alıřmasında, DEAP veri seti ile yapılan alıřmaların incelenmesinin ardından sınıflandırma ařamalarında kullanılan materyal ve yntemler aıklanıp sonular sunulmuřtur ve gelecek alıřmalarda yeniliki yaklařımlar oluřturulmasına katkı saęlanması hedeflenmiřtir.

1.1. Literatür Taraması

Tez çalışmasında kullanılacak olan DEAP veri seti ile yapılan duygu sınıflandırmaları ile ilgili incelen çalışmalardan bazıları bu bölümde kısaca özetlenmiştir.

Li M. ve diğerleri, deneye katılan herkes için sınıflandırma yapmıştır. EEG alt bant aralıklarını oluşturmak için daubuchies4 dalgacık ailesi ile Ayrık Dalgacık Dönüşümü (ADD) yöntemini uygulamıştır. Yapılan çalışmada Alfa (α), Beta (β), Gama (γ), ve Teta (θ) frekanslarına enerji ve entropi metotlarını uygulanarak özellik vektörleri oluşturulmuştur. Kanal seçimlerinin sınıflandırmaya etkisini gözlemek amacıyla 32, 18, 14, 10 EEG kanalı için ayrı ayrı sınıflandırma yapılmıştır. Çıkış etiketlerinden değerlik ve uyarılmayı seçerek 4.5 eşik değere göre 0 ve 1 etiketlerini oluşturmuşlardır. 3 eşik değeri ile K En Yakın Komşu (k -NN) yöntemini kullanarak çapraz doğrulama ile sınıflandırmayı gerçekleştirmişlerdir. En başarılı sınıflandırmaya γ bandında ulaşılmıştır. 32, 18, 14, 10 kanal için uyarılma düzlemindeki başarımlar oranları sırasıyla %95.70, %93.72, %92.28, %89.54; değerlik düzleminde ise sırasıyla %95.69, %93.69, %92.24 ve %89.81 olarak bulunmuştur. Uyarılma ve değerlik düzlemlerinde yapılan sınıflandırmalarda kanal sayısı azalmasıyla sınıflandırma başarımlarını düşüğü gözlemlenmiştir [1].

Menzeles M.L.R. ve diğerleri, deneye katılan herkes için sınıflandırma yapmıştır. α , β , γ , θ bant aralıklarını Chebyshev Finite Impulse Response filtresi ve Parks–McClellan algoritması aracılığıyla elde etmişlerdir. F3, F4, FP1 ve FP2 kanallarını seçmişlerdir. Spektral Güç Analizi (SGA), Yüksek Katmanlı Kesit (HOC) metotları ve istatistiksel metotlarla özellik vektörlerini oluşturmuşlardır. Çıkış etiketlerinden değerlik ve uyarılma için üçlü ve ikili uyaran değerlendirmesini kullanarak -1,0,1 ve 0,1 etiketlerini oluşturmuşlardır. Sınıflandırıcı olarak Destek Vektör Makineleri (DVM) ve Rastgele Orman (RO) metotlarını kullanmışlardır. Çalışmada; ilk önce SGA yöntemiyle tüm bant aralıklarını tek olarak, ikili olarak, üçlü olarak ve dördü olarak sınıflandırılmıştır. Bant aralıklarının tek olarak değerlendirilmesinin sınıflandırma başarımlarını arttırdığı gözlemlenmiş ve HOC için bant aralıkları tek olarak değerlendirilmiştir. HOC ile yapılan sınıflandırmaların sonucunda θ ve δ bant aralıklarının sınıflandırma sonuçlarının daha başarılı olduğu ifade edilmiştir [5].

Al-Qammaz A. Y. ve diğerleri, 6 katılımcı seçmişlerdir (7., 8., 10., 16., 17., 20. Katılımcılar). 32 EEG kanalının hepsini db4 dalgacık ailesi ile 5. seviyeden Ayırık Dalgacık Paket Dönüşümü (ADPD) ve çalışmada önerilen Enhance ADPD (eAdpd) olarak adlandırdıkları metodu uygulayarak EEG alt bantlarını oluşturmuşlardır. Entropi yöntemi ile özellik vektörlerini oluşturmuşlardır. Çıkış etiketlerinden değerlik ve uyarılmayı seçerek, üçlü uyaran değerlendirmesine göre -1,0,1 etiketlerini oluşturmuşlardır. En küçük kareler DVM metodu aracılığıyla sınıflandırmayı gerçekleştirmişlerdir. Değerlik düzleminde standart ADPD ile yapılan sınıflandırmada en yüksek başarımlar %56.94, ortalama başarımlar %42.9; eADPD ile en yüksek başarımlar %59.15 ortalama başarımlar %43.17 olmuştur. Uyarılma düzleminde standart ADPD ile yapılan sınıflandırmada en yüksek başarımlar %68.06, ortalama başarımlar %52.63; eADPD ile en yüksek başarımlar %68.06 ortalama başarımlar %53.29 olmuştur [9].

Jadhav N. ve diğerleri, deneye katılan herkes için sınıflandırma yapmışlardır, 32 EEG kanalının hepsini sınıflandırmada değerlendirmişlerdir. Çalışmalarında Gri Seviye Eş Oluşum Matrisi (GSEOM) yöntemi ile özellik vektörlerini oluşturmuşlardır. Bu çalışma ile GSEOM ilk defa EEG sinyallerinin analizinde kullanılmıştır. Çıkış etiketlerinden değerlik ve uyarılmayı seçerek 5 eşik değere göre 0 ve 1 etiketlerini oluşturmuşlardır. Sınıflandırmayı k -NN metoduyla gerçekleştirmişlerdir. Sınıflandırma sonucuna göre ortalama başarımlar %79.59 bulunmuştur [10].

Liu J. ve diğerleri, deneye katılan herkes için sınıflandırma yapmışlardır, 32 EEG kanalının hepsini sınıflandırmada değerlendirmişlerdir. Frekans, zaman ve frekans-zaman domenleri ve çok kanallı özellik çıkarım metodlarını kullanarak 12 özellik vektörü oluşturmuşlardır. Çıkış etiketlerinden değerlik ve uyarılmayı seçerek 5 eşik değere göre 0 ve 1 etiketlerini oluşturmuşlardır. 5 eşik değeri ile k -NN ve RO yöntemlerini kullanarak, çapraz doğrulama ile sınıflandırmayı gerçekleştirmişlerdir. En yüksek uygunluk, en düşük yedeklilik yöntemiyle özellik seçimi yapmışlardır. Bu yöntemi kıyaslamak adına karesel tutarlılık büyüklük tahmini yöntemini uygulamışlardır. Karesel tutarlılık, büyüklük tahmini yöntemiyle belirlenen özellik vektörlerinin değerlik düzlemindeki en yüksek başarımlar oranı %65.7, uyarılma düzlemindeki en yüksek başarımlar oranı %66.17 olmuştur. En yüksek uygunluk, en düşük yedeklilik yöntemiyle seçilen 12 özellik vektörünün değerlik düzleminde en yüksek %69.97 ve uyarılma düzleminde en yüksek başarımlar %71.23 olmuştur [11].

Zhang Y. ve diğerkleri, deneye katılan herkes için sınıflandırma yapmışlardır. Görgül Kip Ayırışımı (GKA) yöntemiyle EEG sinyalinin alt bantlarını oluşturmuşlardır. Ardından entropi yöntemi ile özellik vektörlerini oluşturmuşlardır. β bandı ile F3 ve F4 kanallarını sınıflandırma için seçmişlerdir. DEAP veri setindeki 8064 veri noktasından 34-42 saniye aralığındaki 9s için 1152 veri noktası kullanılmıştır. DVM metodu aracılığıyla sınıflandırma gerçekleştirmişlerdir. Sınıflandırma sonucunda bireysel sınıflandırmalarda ortalama %94.98 başarıml oranı ve çoklu sınıflandırmada en yüksek %93.20 başarıml oranı elde edilmiştir [12].

Rakibul M. ve diğerkleri, çalışmalarında 2020 Mart ayında Google Akademik Sayfasında yaptıkları taramada DEAP veri seti ve duygu sınıflandırması konusunda 170'ten fazla çalışma olduğunu, bu çalışmaların içinde yer alan 30 civarında yayının istatistiksel değerde olduğunu ifade etmişlerdir. Çıkış etiketlerinden değerklik, uyarılma, baskınlığı seçerek 5 eşik değere göre 0 ve 1 etiketlerini oluşturmuşlardır. Deneye katılan herkesin 32 EEG kanalı için sınıflandırma yapmışlardır. Verileri FIR filtresi ile 4-45.0 Hz aralığına getirmişlerdir. Daha sonra CSD olarak adlandırılan MATLAB aracı ile laplace yüzy tahmini yapmışlardır. 17 özellik vektörü oluşturarak, k-NN ve DVM metotlarını kullanarak çapraz doğrulama ile sınıflandırma yapmışlardır. Sınıflandırma sonucu en iyi ortalama başarıml β bant aralığının güç vektörü ile %60.2 olarak, dengeli doğruluk ise %57.3 olarak bulunmuştur [13].

Ayata D. ve diğerkleri, deneye katılan herkesin 32 EEG kanalı için sınıflandırma yapmışlardır. EEG sinyallerini özelliklerini iki şekilde çıkarmıştır. Birinci yöntemde db4 ve db2 dalgacık aileleri ile ADD metodu kullanarak bant aralıklarını oluşturmuşlardır. İkinci yöntemde ise oto enkoder metoduyla Denetimsiz Özellik Çıkarma (DÖÇ) metodunu kullanılmıştır. Özellik çıkarımı yapıldıktan sonra, istatistiksel metotlar kullanarak 8 adet özellik vektörü oluşturmuşlardır. Çıkış etiketlerinden değerklik, uyarılma, baskınlığı seçerek 4.5 eşik değere göre 0 ve 1 etiketlerini oluşturmuşlardır. k-NN, RO ve J48 KA metotları aracılığıyla sınıflandırma yapmışlardır. Analizler sonucu DÖÇ yöntemiyle oluşturulan özellik vektörlerinin en başarılı sınıflandırma oranı k-NN metoduyla %98.95, db2 dalgacık ailesi ile ADD yöntemiyle oluşturulan özellik vektörlerinin en başarılı sınıflandırma oranı k-NN metoduyla %80.82 olmuştur [14].

Tripathi S.ve diğerkleri, deneye katılan herkes için sınıflandırma yapmışlardır. DEAP veri setinde yer alan 40 kanalın her biri 8064 veri noktasına sahiptir. Bu çalışmada, veri noktaları 10 gruba ayrılarak her grup için 9 adet istatistiksel metot uygulanıp 90 tane işlenmiş veri oluşturuluyor. Daha sonra ortalama, medyan, en büyük değerk, en küçük değerk, standart sapma (SS), varyans, çarpıklık, basıklık ve aralık metotları aracılığıyla oluşturulan veriler de eklenerek 101 adet giriş verisi elde edilmiştir. Bu işlem sonucu katılımcıların 40 video için 4040'ar verisi oluşturulmuştur. Çıkış etiketlerinden değerklik ve uyarılmayı seçerek üçlü uyaran değerklendirmesine göre -1,0,1 etiketlerini, 5 eşik değerkli ikili uyaran değerklendirmesine göre 0 ve 1 etiketlerini oluşturmuşlardır. Derin Sinir Ağı (DSA) ve Evrişimsel Sinir Ağı (ESA) yöntemleri aracılığıyla çapraz doğrulamayla sınıflandırma yapmışlardır. Değerklik düzleminde ikili uyaran değerklendirmesiyle ESA yöntemiyle yapılan sınıflandırma sonucu %81.41 başarıml oranı, DSA yöntemiyle yapılan sınıflandırma sonucu %75.78 başarıml oranı elde edilmiştir. Değerklik düzleminde ikili uyaran değerklendirmesiyle ESA yöntemiyle yapılan sınıflandırma sonucu %73.36 başarıml oranı, DSA yöntemiyle yapılan sınıflandırma sonucu %73.13 başarıml oranı elde edilmiştir [15].

Bazgir O. ve diğerkleri, deneye katılan herkes için sınıflandırma yapmışlardır. F3-F4, F7-F8, FP1-FP2, FC1-FC2, FC5-FC6 kanalları olmak üzere toplamda 10 kanal için sınıflandırma yapmışlardır. EEG alt bantlarını oluşturmak için db4 dalgacık ailesiyle ADD yöntemi kullanılmıştır. Ardından enerji ve entropi metotları aracılığıyla elde edilen verilere temel bileşen analizi uygulamışlardır. Çıkış etiketlerinden değerklik ve uyarılmayı seçerek 4.5 eşik değerkli ikili uyaran değerklendirmesine göre 0 ve 1 etiketlerini oluşturmuşlardır. Sınıflandırma için DVM, YSA ve *k*-NN metotlarını kullanmışlardır. Çapraz doğrulama ile yapılan sınıflandırma sonuçlarına göre en yüksek aşarım oranı uyarılma düzleminde ve β bandında %91.3 oranında olmuştur [16].

Wang Z. ve diğerkleri, deneye katılan herkes için sınıflandırma yapmışlardır. Çalışma içerisinde önerdikleri İkili Adaptif Diferansiyel Gelişim Algoritması (BADEBA) yöntemi ile kanal seçimini yapmışlardır. Bu yöntemin kıyaslanması için Genetik Algoritma (GA), ikili parçacık sürüşü optimizasyonu ve bath algoritması aracılığıyla da sınıflandırmalara yapmışlardır. Kanal seçiminin ardından db4 dalgacık ailesi ile ADPD yöntemi kullanılarak EEG sinyalinin alt bantlarını elde etmişlerdir. Sınıflandırmada β ve γ bantları kullanmışlardır. Bu bant aralıklarını teker teker ve ikisi birlikte olacak şekilde

sınıflandırmalar yapmışlardır. Ortak uzay modeli yöntemi özellik vektörlerini oluşturmuşlardır. Çıkış etiketlerinden değerlik ve uyarılmayı seçerek 5 eşik değerli ikili uyarın değerlendirilmesine göre 0 ve 1 etiketlerini oluşturmuşlardır. Sınıflandırmayı DVM yöntemi aracılığıyla yapmışlardır. Sınıflandırma sonucunda β ve γ bantlarının birlikte değerlendirilmesinin sınıflandırma başarımını arttırdığını ifade etmişlerdir. Değerlik düzleminde yapılacak sınıflandırma için; BADEBA uygulamasının 8 kanal seçmiştir ve sınıflandırma başarımları oranı %75.26 olmuştur, GA 15 kanal seçmiştir ve başarımları oranı %61.63 olmuştur. Uyarılma düzleminde yapılacak sınıflandırma için; BADEBA uygulamasının 7 kanal seçmiştir ve sınıflandırma başarımları oranı %75.98 olmuştur, GA 15 kanal seçmiştir ve başarımları oranı %61.63 olmuştur. BADEBA aracılığıyla kanal seçimi yapılan sınıflandırmaların diğer kanal seçimlerine göre daha başarılı sonuç verdiği ifade edilmiştir [18].

Mert A.ve diğerleri, deneye katılan herkes için sınıflandırma yapmışlardır. Sağ frontal lobdan 8 kanal (Fp2, AF4, F4, F8, FC2, FC6, T8, C4), sol frontal lobdan 8 kanal (Fp1, AF3, F3, F7, FC1, FC5, T7, C3), sağ frontal lob ve sol frontal lob için seçilen kanalların farkı (Fp1-Fp2, AF3-AF4, F3-F4, F7-F8, FC1-FC2, FC5-FC6, T7-T8, C3-C4) ve merkez bölgesinden 2 kanal (Fz, Cz) olmak üzere seçilen 26 giriş verisi sınıflandırmada kullanmışlardır. GKA metodunu geliştirerek Çoklu Görgül Kip Ayrışımı (ÇGKA) metodu önermişlerdir. Önerdikleri yeni metotla özellik çıkarımı yapmışlardır. ÇDKA metodu aracılığıyla temel fonksiyonlara ihtiyaç duyulmadan sinyaller İç Mod Fonksiyonları (IMF) olarak adlandırılan salınım kümelerine ayrışabildiklerini ifade etmişlerdir. Oluşan IMF değerlerinden Hjorth parametreleri, entropi, güç spektral yoğunluğu, korelasyon gibi çeşitli zaman ve frekans domeni metotlarıyla özellik vektörleri oluşturmuşlardır. Ardından ICA yöntemiyle 7419 boyutlu veri 250 boyutlu hale getirmişlerdir. Sınıflandırma için çıkış etiketlerinden değerlik ve uyarılmayı seçmişlerdir. 40 video için oluşan 40 farklı durumu çapraz doğrulamayla YSA ve k -NN ile sınıflandırma yapmışlardır. Çalışma sonucunda DPD ve ÇDKA uygulandıktan sonra özellik vektörleri belirlenen sinyallerin daha başarılı sonuç verdiğini ifade etmişlerdir. Değerlik düzleminde YSA ile yapılan sınıflandırmada %75 doğruluk oranına, k -NN ile yapılan sınıflandırmada %51.01 doğruluk oranına ulaşmışlardır. Uyarılma düzleminde YSA ile yapılan sınıflandırmada %72.87 doğruluk oranına, k -NN ile yapılan sınıflandırmada %67 doğruluk oranına ulaşmışlardır [19].

Asghar M. A. ve diğerkleri, deneye katılan herkes için sınıflandırma yapmışlardır. 32 EEG kanalından alınan sinyallere Sürekli Dalgacık Dönüşümü (SDD) metodunun ardından AlexNet DSA metodu uygulayarak özellik çıkarımı gerçekleştirmişlerdir. Daha sonra Derin Özelliklerin Paketlenmesi (DÖP) olarak adlandırdıkları yöntemi önermişler ve bu yöntem aracılığıyla özellik boyutlarını azaltmışlardır. DÖP metodunu, görüntü işleme çalışmalarında özellik boyutunu azaltmak için kullanılan özelliklerin paketlenmesi metodunu geliştirerek oluşturmuşlardır. Özellik boyutunu azaltarak sınıflandırmadaki eğitim aşamasının hızlanmasını sağlamışlardır. Çıkış etiketlerinden değerlik ve uyarılmayı seçerek 5 eşik değerli ikili uyarın değerlendirilmesine göre 0 ve 1 etiketlerini oluşturmuşlardır. Sınıflandırma için k -NN ve DVM metotlarını kullanmışlardır. Analizler sonucunda en yüksek başarıml oranını DVM yöntemi ile yapılan sınıflandırmada ve % 77.4 olarak bulmuşlardır [20].

Özel P. ve diğerkleri, deneye katılan herkes için sınıflandırma yapmışlardır. Referans [19]'un seçtiğı 26 giriş verisini kullanmışlardır. 40 video için kanallarda oluşan 8064'er veri noktasının ilk 4032 adedini kullanmışlardır. SDD yöntemi aracılığıyla EEG sinyallerinin alt bantlarını elde etmişlerdir. Çoklu değişkenli senkro sıkıştırma dönüşümü adını verdikleri yeni özellik vektörü oluşturma yöntemi önermişlerdir. Bu metotla özellik vektörlerini oluşturdukları EEG sinyalleri sınıflandırıcıya giriş verisi olarak vermişlerdir. Yöntemin başarımlını kıyaslamak amacıyla senkro sıkıştırma metoduyla da özellik vektörlerini çıkartmışlardır. Çıkış etiketlerinden değerlik, uyarılma ve baskınlığı seçerek 5 eşik değerli ikili uyarın değerlendirilmesine göre 0 ve 1 etiketlerini oluşturmuşlardır. Değerlik ve uyarılmanın birlikte değerlendirdiğı iki boyutlu duygu modelini ve baskınlık verilerini de ekleyerek oluşturdukları üç boyutlu duygu modelini kullanmışlardır. MATLAB araçlarından olan Classification Learner Tool aracılığıyla DVM, karar ağaçları, topluluk sınıflandırıcıları ve k -NN metotlarıyla sınıflandırma yapmışlardır. Çalışma sonucunda en yüksek başarıml oranını DVM metodu aracılığıyla yapılan sınıflandırmada, üç boyutlu duygu modelinde %93 olarak bulmuşlardır [21].

Yang H. ve diğerkleri, deneye katılan herkes için sınıflandırma yapmışlardır. 32 EEG kanalından alınan sinyalleri çok sütunlu ESA metodu aracılığıyla sınıflandırmışlardır. Çıkış etiketlerinden değerlik ve uyarılmayı seçmişlerdir. Deneye katılan 32 kişi içerisinde 22 tanesini eğitim verisi olarak, 5 tanesini değerlendirme verisi olarak ve 5 tanesini de test verisi olarak kullanmışlardır. Sınıflandırma sonucunda değerlik düzleminde başarıml


oranını %90.01, uyarılma düzleminde ise başarımlar oranını %90.65 olarak bulmuşlardır. Kullanılan ESA metodunun diğer metotlara göre sınıflandırmada daha başarılı olduğunu vurgulamışlardır.[22].

Baghdadi A.ve diğerleri, deneye katılan herkesin 32 EEG kanalı için sınıflandırma yapmışlardır. EEG sinyallerinin özellik vektörlerinin oluşturmak için sırasıyla ortalamaların karekökü (RMS), Hjorth parametresi, Kantitatif EEG özellikleri(kEEG) ve güç yöntemleri kullanmışlardır. RMS ve güç ile özellik vektörleri oluşturmadan önce sinyaller db5 dalgacık ailesi ile 5.seviyeden ADD metodu uygulanarak EEG alt bantlarını elde etmişlerdir. Sparce AutoEncoder ve *k*-NN yöntemleri aracılığıyla sınıflandırmaya yapmışlardır. Çıkış etiketlerinden değerlik, uyarılma ve baskınlığı seçerek 5 eşik değerli ikili uyaran değerlendirmesine göre 0 ve 1 etiketlerini oluşturmuşlardır. Sınıflandırma sonuçlarına göre en yüksek başarımlar oranını %60.60 olarak, RMS metodu aracılığıyla oluşturulan özellik vektörü ile Sparce AutoEncoder sınıflandırıcısı aracılığıyla bulmuşlardır [23].

2. MATERYAL VE YÖNTEM


2.1. Elektroensefalogram (EEG)

EEG beyindeki elektriksel aktiviteleri kaydeden müdahalesiz bir elektrofizyolojik ölçüm aracıdır. Literatüre geçen ilk kayıt Alman psikiyatrist Hans Berger'in öncülüğünde 1924'te olmuştur [4, 24]. EEG sinyalleri elektroensefalogram adı verilen özel cihazlarla kaydedilir. Bu cihazlar ana olarak kafa derisine yerleştirilen metal elektrotlardan oluşur. Elektrotların direkt kafatasına yerleştirildiği uygulamalarda mevcuttur. Genellikle 8, 16, 32 elektrotla sahip olan cihazlar vardır. Elektrotların yerleşiminde Şekil 2.1'deki uluslararası 10/20 EEG kanal yerleşim sistemi baz alınır. F, T, C, P ve O harfleri sırasıyla Frontal, Temporal, Central, Parietal ve Occipital lobları temsil eder. Çift sayılar (2,4,6,8), elektrotların sağ yarım küredeki konumlarını, tek sayılar (1,3,5,7) sol yarım küredeki elektrotların konumlarını temsil eder. A ve Fp harfleri sırasıyla kulak lobu ve Frontal kutpu temsil eder [46].



Şekil 2. 1. Uluslararası 10/20 EEG kanal yerleşim sistemi [4].

EEG sinyalleri, iki elektrot arasındaki voltaj değişimidir ve sinyal genliği Şekil 2.2'de örneklendiği gibi tepeden tepeye tekniği ile ölçülür.



Şekil 2. 2. EEG sinyali: (a) İşlenmemiş sinyal örneği [4]; (b) Tepeden tepeye sinyal değeri ölçme tekniği [4].

EEG sinyalleri çoğunlukla 0.5- 4 Hz aralığındaki sinyaller Delta(δ), 4- 8 Hz aralığındaki sinyaller Teta(θ), 8- 16 Hz aralığındaki sinyaller Alfa(α), 16- 32 Hz aralığındaki sinyaller Beta(β), 32 Hz ve üstündeki sinyaller Gama(γ) olmak üzere beş frekans bandına ayrılmaktadır. EEG sinyallerinin bant aralıkları sınıflandırma hedefine göre farklı başarımlarına sebep olmaktadır. Bu alanda yapılan araştırmalar sayesinde duygu durumlarının aktif oldukları bant aralıkları ile genelde etkin olan beyin aktiviteleri gruplandırılabilir [4, 25]. Tablo 2.1’de bant aralıkları ve duyguların aktif olduğu sinyaller hakkında genel bilgiler sunulmuştur [4, 42].

Tablo 2. 1. Beyin dalgalarının frekans bant aralıkları.

Dalga Çeşidi	İlgili Duygusal Durum	Kısa Tanım
Delta (δ) (0.5- 4 Hz)	Güçlü empati ve sezgi duygusu	Genellikle uyku ile ilişkilendirilen en yavaş beyin dalgaları. Bu aralıktaki çoklu frekanslara, iyileşmede yararlı olan insan büyüme hormonunun salınması eşlik eder. Uyuma durumunda üretilen bu dalgalar, bilinçaltı aktiviteye erişme fırsatı gösterir.
Teta (θ) (4- 8 Hz)	Derin rahatlama, Meditasyon	Ana olarak yetişkinler hafif uykuda ya da rüyadayken teta dalgası oluştururlar. Bu dalgalar normalde gözler kapalıyken oluşur, gözler açıkken kaybolur. Bu dalga frekansı genellikle stres uzaklaştırma ve anıların hatırlanmasıyla ilişkilidir.

Dalga Çeşidi	İlgili Duygusal Durum	Kısa Tanım
Alpha (α) (8- 16 Hz)	Yaratıcılık, Rahatlama	Bu dalgalar, çoğunlukla gözler kapalıyken uyanık gevşeme durumunda ortaya çıkar. Uyku durumunda yok olurlar. Alfa, beynin dinlenme halidir. Alfa dalgalarının aktivitesi, her tür motor aktiviteye yanıt olarak azalır. Alfa dalgaları genel zihinsel koordinasyona, sakinliğe, uyanıklığa, zihin / vücut bütünleşmesine ve öğrenmeye yardımcı olur
Beta (β) (16- 32 Hz)	Dikkat, Konsantrasyon	Kişiler uyanıkken ya da endişe durumunda ortaya çıkar. Genellikle ön ve merkez bölgelerle ilişkilendirilir. Bu frekans bandında beyin sinyallerinin analizi için bilginin hazırlanması, çözümler üretilmesi ve yeni fikirler üretilmesi için kolaylıkla bilgi edinilebilir.
Gama (γ) (32 Hz- +)	Bölgesel öğrenme, Hafıza ve Dil, İşleme ve Fikir oluşturma	En hızlı dalgalardır ve farklı beyin bölgelerindeki işlemlerin anlık değişimleriyle ilgilidir. Algılama ve bilinçle ilişkilidir. Gama bandının beyin fonksiyonuyla ilişkili olduğunu ortaya koyan pek çok çalışma olsa da bazı çalışmalar ağ aktivitesini yan ürünü olarak daha iyi görüleceğini ifade etmektedir.

Araştırmacılar, genellikle duygu tanıma metotlarını geliştirmek üzere araştırma yapmaktadır. Bu amaçla deney verisini çalışma içerisinde alan uygulamalar ve hazır veri seti üzerinden sınıflandırma basamaklarını geliştirmeye yönelik çalışmalar vardır. Laboratuvar ve katılımcı ihtiyacının olmaması, maliyetin daha az olması, yöntemlerin kıyaslanabilir olması gibi sebeplerle açık veri kaynakları tercih edilmektedir. EEG ile yapılan duygu analizi için tercih edilen en popüler veri seti DEAP veri setidir [4, 26, 27]. Bu nedenle, bu tez çalışmasında DEAP veri seti kullanılmıştır.

2.1.1. DEAP Veri Seti


DEAP veri setinde müzik video klipleri farklı duyguları ortaya çıkarmak için görsel uyaran olarak kullanılmıştır. Bu veri seti, fizyolojik sinyallerden spontane duyguları analiz eden en yüksek katılımcı sayısına sahip veri setidir. Buna ek olarak, müzik videolarını duygusal veri olarak kullanan tek veri tabanıdır [6, 28]. Tablo 2.2' de DEAP veri setinin içerik özeti verilmiştir.

Tablo 2. 2. DEAP veri seti içerik özeti.

Fizyolojik Deney	
Katılımcı Sayısı	32
Video Sayısı	40
Seçme Metodu	
	Uyarılma
	Değerlik
Ölçüm skalası	Baskınlık
	Beğenme (Videoyu ne kadar beğendiniz?)
	Benzerlik (Video ne kadar tanıdık geldi?)
Ölçüm Değerleri	Benzerlik: ayrık ölçek 1-5
	Diğerleri: sürekli ölçek 1-9
Kaydedilen Sinyaller	32 Kanal 512 Hz EEG
	Çevresel fizyolojik sinyaller
	Yüz videosu (22 Katılımcı İçin)

Deneyde kullanılan uyaranlar birkaç adımda seçilmiştir. İlk olarak, yarısı yarı otomatik, diğer yarısı manuel olacak şekilde 120 video belirlenmiştir. Ardından her uyaran için birer dakikalık kısımlar belirlenmiştir. Son olarak, web tabanlı bir öznel değerlendirme deneyi aracılığıyla 40 uyaran seçilmiştir.

19 ve 37 yaş aralığında yarısı kadın, yarısı erkek 32 katılımcının verileri kaydedilmiştir. Uluslararası standart olarak belirlenen 10-20 sistemine göre yerleştirilen 32 kanallı EEG cihazı aracılığı ile EEG verileri alınmıştır. Bunlara ek olarak, Şekil 2.3'te gösterildiği şekilde yerleştirilerek; 4 kanal **EMG**, **Elektrooculography(EOG)**, **BVP**, **GDR**, **BT** fizyolojik verileri olmak üzere toplam 40 kanal verisi kaydedilmiştir.




Şekil 2. 3. Fizyolojik sinyallerin alındığı sensörlerin yerleşimi [6].

20 video izlendikten sonra, dileyen katılımcıların kurabiye ve alkolü olmayan içecekler içebileceği kısa bir ara verilmiştir, ardından deneye devam edilmiştir. Şekil 2.4'te bir katılımcının deney başlamadan önceki görüntüsü verilmiştir.



Şekil 2. 4. Bir katılımcının deneyden önceki görüntüsü [6, 63].

Her deney sonunda katılımcılar videoların; uyaran, değerlik, beğenme-beğenmeme ve baskınlık seviyelerini Şekil 2.5'te verilen kişisel değerlendirme mankenleri (Self Assesment Manikin-SAM) ölçeğine göre değerlendirmiştir. Beğenme için başparmak yukarı ve aşağı sembolleri kullanılmıştır. SAM içerisindeki mankenler 1-9'a kadar ekranın ortasına sıralanarak oynatılmıştır. Katılımcılar, kişisel değerlendirme seviyesine fare imlecini getirerek tıklamıştır.



Şekil 2. 5. Kişisel değerlendirme için kullanılan resimler. Yukarıdan aşağıya Değerlik SAM, Uyarılma SAM, Baskınlık SAM, Beğenme [6]

Değerlik ölçeği, mutsuz ve üzgünden mutlu ve eğlenceliye derecelendirilmiştir. Uyarılma ölçeği sakin, sıkılmıştan heyecanlı ve sinirliye; baskınlık ölçeği zayıftan güçlüye derecelendirilmiştir. Dördüncü ölçek olan beğenme katılımcıların kişisel beğenisini içeren değerlik ölçeğini göstermektedir. Katılımcıların zevkleri ile ilgilidir hisleri ile değil. Örneğin beğenilen bir videonun sinirlendirmesi ya da üzmesi mümkün olabilir. Son olarak deney sırasında katılımcılardan her bir videonun benzerliğini 1 ve 5 aralığında değerlendirmeleri istenmiştir (1 daha önce şarkıyı hiç görmedi, 5 şarkıyı çok iyi biliyor).

512 Hz olarak kaydedilen bütün fizyolojik tepkiler işlemlerin hızlanması adına 256 Hz olacak şekilde alt örnekleme yapılmıştır. DEAP veri setine eecs.qmul.ac.uk/mmv/datasets/deap/index.html adresinde yer alan ilgili sekmeleri ve yönlendirmeleri takip ederek akademik e-posta adresiyle talep oluşturulduktan sonra ulaşılabilmektedir. Kullanıcıların sinyallerin ilk kayıt hali, sınıflandırmaya hazır 128 Hz seviyesine indirilmiş .mat ve .py uzantılı versiyonları ile deneyde kullanılan videolar, öz değerlendirme formları ve 22 kişinin ön yüz video görüntüleri indirilebilmektedir.

2.2. Duygu Analiz Yöntemleri

Duygu sınıflandırma için, duygular tanımlanmalı ve nicel olarak erişilmelidir. Temel duyguların tanımı ilk olarak on yıllar önce önerilmesine rağmen psikologlar tarafından

geniş çapta kabul edilen kesin bir tanım yoktur. Psikologlar, duygu modellerini ayrık model ve boyutsal model olmak üzere ikiye ayırmaktadır. Duyguyu açığa çıkarmak için hedefe yönelik pek çok duygusal çağrıştırmacı materyal deneklere verilir. Geçtiğimiz birkaç yılda resim, müzik ve film uyaranlar en çok tercih edilen materyaller olmuştur. Ayrıca son yıllarda durumsal uyarım adı verilen bazı yeni yöntemlerde kullanılmaktadır. Duygu uyandırmak için bilgisayar oyunları veya hatıralar kullanılır. Bu yöntemler arasında duygusal sanal gerçeklik daha fazla ilgi görmektedir.

2.2.1. Ayrık Duygu Modeli

Ekman, duyguları ayrık, ölçülebilir ve fizyoloji ile ilgili olarak kabul etmiştir. Temel duygulara yönelik bir dizi özellik önermiştir [3].

- 1) İnsanlar duygularla doğarlar, öğrenmezler.
- 2) İnsanlar aynı durumlara karşı benzer fizyolojik özellik gösterirler.
- 3) İnsanlar bu duyguları benzer yollarla gösterir.
- 4) İnsanlar aynı duyguları gösterirken benzer fizyolojik özellik gösterirler.

Bu özelliklere göre; mutlu, üzgün, sinirli, korku, şaşkın ve iğrenme olmak üzere 6 temel duygu özetlemiştir ve diğer duyguların tepkisinin ürünü olduğunu ve bu temel duyguların kombinasyonu olduğunu kabul edilmiştir.


1980’de Plutnick eğlence, güven, korku, şaşkın, üzüntü, iğrenme, sinir ve kaygı olmak üzere 8 temel duyguyu içeren çark modelini öne sürmüştür [3]. Bu çark modeli, duyguları yoğunluğa göre tanımlar, daha güçlü duygular merkezde iken daha zayıflar etrafındadır. Renkler gibi temel duygular karıştırılarak karmaşık duygular oluşturulabilir. Izard, bunu şu şekilde tanımlamıştır:

- 1) Temel duygular insan duygularının seyrine göre şekillenir.
- 2) Her temel duygu basit bir beyin çevrimine denk gelir ve karmaşık bilişsel bileşen yoktur.

Bunun ardından ilgi, eğlenme, şaşırma, üzüntü, korku, utanma, suçluluk, sinir, iğrenme ve nefret olmak üzere 10 temel duyguyu sunmuştur. Ayrık duygu modelleri, nicel analiz yerine duygular için kelime tanımları kullanmıştır. Bu nedenle kelimelerle vurgulanamayan nicel çalışma gerektiren bazı karmaşık duyguları analiz etmek zordur.

2.2.2. Çok Boyutlu Duygu Uzay Modeli

Yapılan araştırmalarda nefret ve kin, keyif ve beğenme gibi ayrı duygular arasında belli bir dereceye kadar korelasyon olduğu bulunmuştur. Bunun yanında aynı tanımlara sahip duyguların farklı yoğunlukları olabilir. Örneğin; mutlu, biraz mutlu veya çok mutlu olarak tarif edilebilir. Bu nedenle, psikologlar çok boyutlu duygu uzay modelleri yapılandırmıştır. Lang 2 boyutlu değerlik, uyarılma düzleminde duygu kategorilendirmesi geliştirmiştir. Bu teoriye göre değerlik hoş olmayandan(negatif) hoş olana(pozitif) ve uyarılma aralığı pasiften(düşük) aktive(yüksek) insanların hislerinin yoğunluğuna göre yerleştirilmektedir. Farklı duyguların yerleşimi Şekil 2.6'da gösterilmiştir. Örneğin; sınırlı negatif değerlik ve yüksek uyarılma iken üzüntü negatif değerlik ve zayıf uyarılmaya sahiptir.



Şekil 2. 6. İki boyutlu duygu modeli [21].

2.3. Sinyal İşleme Metotları

Sinyal işleme metotları, sinyallerin gürültülerden arındırılması, istenilen frekans aralığına getirilmesi, işlem kolaylığı sağlanması gibi pek çok amaçla kullanılır. Fizyolojik sinyaller alındıktan sonra ön işleme aşaması olur. Bu aşamada gözler kapalıyken alınan ilgili aktif değişkenli sinyaller işlem(deney) sırasında alınan sinyallerden çıkartılarak ön işlenmiş sinyal ortaya konur. Ardından bu sinyallerin özellik çıkarımı yapılır.

Özellik çıkarma işlemi, ham bilgilerden istenen veriye ait ayrıntıları çıkarma işlemidir. Özellik çıkarımı, duygu tanıma sistemlerinde önemli rol oynar. EEG sinyalindeki birçok özelliğin analizi sonucunda duygu tanımlanabilmektedir. Özellik çıkarmak amacıyla zaman domeninde, frekans domeninde ve zaman-frekans domeninde çeşitli yöntemler uygulanabilir.

En iyi ve eski sinyal işleme yöntemlerinden olan fourier dönüşümü sinyali dönüştürürken frekans bölgesine taşır, sinyalin zaman bilgisi kaybolur. Durağan, kendini sürekli tekrar eden sinyallerde, bu sorun teşkil etmez; ancak birçok veri sinyali, önemli sayılabilecek durağansızlık veya geçici özellikler (eğim, ansızın değişim, kırılma ve olayların başlangıç ve bitişleri) içerebilir. Bu beklenmedik özellikler ve durağansızlıklar, veri sinyalinin en önemli kısımları olabilmektedir. EEG gibi ne zaman ne değer alacağı belli olmayan sinyallerin analizinde zaman bilgisi önem taşımaktadır [29]. EEG sinyal sınıflandırmasının hem fourier hem de dalgacık analizi ile yapıldığı bir çalışma sonucunda dalgacık analizi yönteminin daha başarılı olduğu gözlemlenmiştir [30].

Dalgacık dönüşümünde veriler bir ana dalgacık ile birleştirilir ve elde edilen sinyal özellik katsayısı dediğimiz bir katsayı ile zaman ölçek boyutunda ifade edilir. Burada bizim istediğimiz zaman ölçek boyutunda gösterilen eğride esasında frekans bilgisi de mevcuttur. Bu durum sinyallerin sadece frekans domeninde incelenemediği fourier analizine göre bir avantaj sağlar.

Dalgacık dönüşümü farklı frekanslarda durağan olmayan güce sahip zaman serisi sinyallerinin analizinde kullanılabilir. Tıp alanında sinyalleri sadece frekans olarak değil; aynı zamanda zaman bölgesinde genliklerini görebilmek aranan bir durumdur. Bu haliyle dalgacık analizi son zamanlarda özellikle tıp alanında kullanılan popüler bir sinyal işleme metodu olarak karşımıza çıkar [31].

Özellik seçimi ile özellik vektörü içerisinde etkin olan özellikler belirlendiği gibi etkisiz veya olumsuz etkiye neden olan özelliklerde tespit edilebilmektedir. Özellik seçimi etkili özelliklerin nasıl korunacağını ve gereksiz olanların orijinal özellik kümesinden nasıl kaldırılacağını araştırır.

DPD ile karakteristik özellikleri çıkartılan verilerin öznitelik vektörleri oluşturularak sınıflandırma için en belirleyici özellik vektörleri bulunmaya çalışılır. Bu sayede SD performansları artar [32].

Özellik vektör algoritmaları, büyük boyutlu verileri eşdeğer bilgi içeriği ile daha küçük boyutlu verilere dönüştürmek için gerekli araçlardır. Bu nedenle özellik vektörü sınıflandırma ve regresyon şemalarının karmaşıklığı azaltmak için genellikle veri boyutlarının azaltılmasında kullanılır [33].

DPD ile alt bantlarına ayrılan EEG sinyallerinin özellik vektörlerini çıkarmak için istatistiksel hesaplama yöntemleri, enerji, entropi ve hjorth parametresi kullanılmıştır.

2.3.1. Dalgacık Analizi


Yaygın olarak kullanılan sinyal işleme tekniklerinden Fourier Dönüşümleri durağan olmayan sinyallerde güvenilir sonuçlar vermemektedir. Dalgacık analizi yöntemleri ile sinyaller hem zaman domeninde hem de frekans domeninde analiz edilebilmektedir. Bu özelliği sayesinde uygulamalı matematik, işaret işleme, ses ve görüntü sıkıştırma, tıbbi uygulamalar, fizyolojik uygulamalar, psikolojik uygulamalar, akustik, veri sıkıştırma gibi pek çok alanda kullanılmaktadır [34]. Zaman aralıklarına göre ani değişimler gösteren EEG, EMG, EKG gibi fizyolojik sinyallerin yorumlanmasını gerektiren hastalık tespiti, duygu analizi gibi çalışmalarda avantaj sağlamaktadır. Frekans aralığı istenilen düzeye getirilirken zaman değişikliğinden ötürü oluşan farklılıkların aynı şekilde gözlemlenebilmesi sağlanabilmektedir.

SDD ve ADD olmak üzere iki ana başlıkta incelenir. ADD yönteminin alt başlığı olan Dalgacık Paket Dönüşümü (DPD) EEG gibi durağan olmayan sinyallerin analizi için daha uygun olduğu gözlemlenmiştir. Sinyal frekanslarının analizinde genellikle DPD, SDD ve ADD' ye göre zamana bağlı değişikliklerin daha yüksek çözünürlüğünü göstermektedir [35]. Bu nedenle bu tez çalışmasında DPD yöntemi kullanılmıştır.

2.3.1.1. Dalgacık Paket Dönüşümü

DPD dalgacık spektrumunun her bir oktav sıklık bandında dalgacığın genişletilmesidir. DPD her çözünürlükte aynı sıklık bant aralığına sahiptir. Ayırıştırma işlemleri sırasında sinyal bilgisini artırma veya azaltma işlemi yapılmadığı için sinyal alt bileşenleri de aynı bilgiyi içerir. Hem yüksek hem de alçak frekans bantlarının analizini gerçekleştirmeye uygundur. Detay alt bantları ve yaklaşım alt bantlarının her ikisini de ayırıştırma işlemine tabi tutarak özellik çıkarımına daha etkili olmaktadır [33].

DPD analizinde kullanılacak dalgacık ailesinin seçimi ve uygulanacak dönüşümün seviyesi önem arz etmektedir. Pek çok dalgacık ailesi mevcuttur. EEG sinyal analizinde kullanılanların en önemlileri Haar, Daubuchies(db), Symlet, Coiflets ve Biorthogonal'dir. Bu dalgacık ailelerin içinde db ailesi ortogonellik özelliği ve verimli filtre uygulaması ile bilinir, EEG sinyallerine daha benzerdir. Bu nedenle EEG sinyali ile yapılan çalışmalarda daha başarılı sonuç verdiği gözlemlenmiştir [36, 37]. Db dalgacık ailesi içerisinde de db4 nin daha başarılı olduğu gözlemlenmiştir [38]. Bu nedenle bu tez çalışmasında Şekil 2.7'de verilen db4 dalgacık ailesi kullanılmıştır [39].




Şekil 2. 7. db4 dalgacığı.

DPD analizinin fonksiyon ifadeleri Denklem 2.1'deki gibidir.

$$\psi_{j+1}^{2i-1}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} g(k) \psi_j^i(2t - k) \quad (2.1)$$

$\psi(t)$ birimlik temelde oluşturulan ana dalgacık fonksiyonudur. $h(k)$ ve $g(k)$ ölçekleme fonksiyonu ve ana dalgacık fonksiyonuyla ilişkili olan sırasıyla alçak geçiren ve yüksek geçiren filtre katsayılarıdır.

128 Hz olarak sunulan DEAP veri setini δ , θ , α , β , γ alt bant aralıklarına ayırmak için 4.seviyeden DPD uygulanmıştır. Uygulanan DPD analizinin ağaç modeli Şekil 2.8'de verilmiştir. DPD ile yapılan analizlerde k . seviyede yapılan ayrıştırmanın 2^k adet bileşeni olur.



Şekil 2. 8. db4 4. seviye DPD

2.3.2. İstatistiksel Metotlar

Literatürde kullanılan istatistiksel metotlar aracılığıyla özellik vektörleri oluşturulmuştur. Her bir metot sınıflandırmada ayrı olarak değerlendirilerek karşılaştırılmıştır. Kullanılan metotların matematiksel ifadeleri Tablo 2.3'te verilmiştir [40, 25, 41].

Tablo 2. 3. EEG öznitelikleri ve formülleri.

Özellik (Öznitelik)	Formül
En Küçük	$\min\{X_1, X_2, X_3, \dots, X_n\}$
En Büyük	$\max\{X_1, X_2, X_3, \dots, X_n\}$
Ortalamaların Mutlak Değeri	$\frac{1}{N} \sum_{n=1}^N X_n $
Ortalama Karekök	$\sqrt{\frac{1}{N} \sum_{n=1}^N X_n^2}$
Aritmetik Ortalama (AO)	$\frac{1}{N} \sum_{n=1}^N X_n$

Özellik (Öznitelik)	Formül
Standart Sapma (SS)	$\sqrt{\frac{1}{N} \sum_{n=1}^N (X_n - AO)^2}$
Çarpıklık	$\sum_{n=1}^N (X_n - AO) \frac{3}{(N-1)SS^3}$
Basıklık	$\sum_{n=1}^N (X_n - AO) \frac{4}{(N-1)SS^4}$

Her ne kadar dalgacık analizi EEG, EKG gibi durağan olmayan sinyaller hakkında bilgi verse de katsayıların çok olması sınıflandırma aşaması için bilgilerin özellik olarak kullanılamamasına sebep olmaktadır. Bundan dolayı yüksek seviyeli özelliklerin elde edilebilmesi için enerji, entropi, hjorth parametresi gibi çeşitli sinyal işleme metotları kullanılmaktadır [26].

2.3.3. Enerji

Her sinyalin kendine has bir enerji değeri olduğu gibi onu oluşturan bileşenlerinin de enerji değerleri değişkenlik göstermektedir. Yüksek boyuttaki verilerle işlem yapmak yerine sinyalin bileşenlerinin enerji değerlerini kullanmak veri noktalarının azaltılması gibi birçok açıdan avantaj sağlamaktadır. EEG sinyal analizinde de çokça tercih edilen sinyal işleme metotlarından [16,1,11]. Denklem 2.2’de enerjinin matematiksel ifadesi verilmiştir [33].

$$E_j = \sum_{k=1}^N (D_j(k)^2), \quad k = 1, 2, \dots, N \quad (2.2)$$

Denklem 2.2’de bulunan E sinyalin enerjisini, N sinyaldeki veri sayısını, D enerjisi bulunacak sinyal bileşenini ve j bileşenin numarasını göstermektedir. Bu tez çalışmasında kullanılacak sinyallerin veri sayısı 8064’tür.

2.3.4. Entropi

Entropi bir sinyalin rastgeleliğinin sayısal ölçüsüdür [9]. Yüksek seviyeli özelliklerin elde edilebilmesi için entropilerden yardım alınmaktadır. Sinyal işleme, örüntü tanıma, bilgi teorisi, tahmin, sınıflandırma vb. pek çok alanda kullanılan entropi bilgideki belirsizliği

ölçmek için kullanılmaktadır [1,26]. Sinyal işleme alanında entropiye durağan ya da durağan olmayan işaretin bünyesinde ne kadar bilgi taşıdığını hesaplamak için başvurulmaktadır.

EEG verileri gibi psikolojik zaman serilerini analiz etmek için de kullanılabilen bir özelliktir. Buna ek olarak duygu sınıflaması için güçlü bir özellik olan entropi EEG sinyali içindeki değişkenliğin istatistiksel tanımlanmasıdır. Entropi denklem 2.3'e göre hesaplanmaktadır [43].

$$H(p) = - \sum_{i=0}^{N-1} (p_i) (\log_2(p_i)) \quad (2.3)$$

Denklem 2.3'te bulunan $H(p)$ sinyalin entropisi, N sinyaldeki veri sayısını, p enerjisi bulunacak sinyal bileşenini ve i bileşenin numarasını göstermektedir. Bu tez çalışmasında kullanılacak sinyallerin veri sayısı 8064'tür.

2.3.4.1. Shannon Entropisi

Shannon tarafından bulunmuştur. Verilerin rastgele dağılmış olduğu sistemdeki ya da dizideki belirsizliği ölçmek için kullanılmaktadır. Shannon entropi denklem 2.4' te verilen formül ile hesaplanmaktadır [44].

$$H_{shannon}(x) = - \sum_{i=0}^{N-1} ((s_i)^2 (\log_2(s_i)^2)) \quad (2.4)$$

Denklem 2.4'te bulunan $H_{shannon}(x)$ sinyalin shannon entropisini, N sinyaldeki veri sayısını, s enerjisi bulunacak sinyal bileşenini ve i bileşenin numarasını göstermektedir. Bu tez çalışmasında kullanılacak sinyallerin veri sayısı 8064'tür.

2.3.5. Hjorth Parametresi

Hjorth parametresi Bo Hjorth tarafından 1970 yılında EEG sinyal işleme metodu olarak ortaya konulmuştur [44]. Hjorth parametresi etkinlik, hareketlilik ve karmaşıklıktan oluşur [45,19].

Hjorth aktifliği zaman işlevinin varyansı olarak sinyalin gücünü temsil eder [47]. Denklem 2.5' te verilen eşitlikle hesaplanır.

$$\sigma_X = \sqrt{\frac{\sum_{i=0}^N (X(i) - \bar{X})^2}{N}}, \text{Aktiflik} = \sigma_X^2 \quad (2.5)$$

Denklem 2.5'te bulunan σ_X sinyal varyansının karekökünü, N sinyaldeki veri sayısını ve i bileşenin numarasını göstermektedir. $\bar{X}$ sinyal değerlerinin aritmetik ortalamasını ifade etmektedir.

Hjorth hareketliliği sinyalin ortalama frekansını temsil eder. Denklem 2.6'da verilen elitlik ile hesaplanır.

$$Hareketlilik = \frac{\sigma_X'}{\sigma_X} \quad (2.6)$$

Denklem 2.6'da bulunan σ_X' , σ_X 'in birinci türevidir.

Hjorth karmaşıklığı sinyal frekansındaki değişikliği ifade eder. Denklem 2.7'deki şekilde hesaplanır.

$$Karmaşıklık = \frac{Hareketlilik'}{Hareketlilik} = \frac{\sigma_X''/\sigma_X'}{\sigma_X'/\sigma_X} \quad (2.7)$$

Denklem 2.7'de bulunan σ_X'' , σ_X' 'in ikinci türevidir, σ_X' , σ_X 'in birinci türevidir.

2.4. Sınıflandırma Yöntemleri


2.4.1. Destek Vektör Makineleri

DVM denetimli öğrenme algoritma temelli bir makine öğrenme yöntemidir. Sınıflandırma ve regresyon problemleri için güçlü bir algoritmadır [33]. Görüntü işleme, ses işleme, zaman serisi tahmini, veri madenciliği, güç sistemlerin, proses kontrol, otomotiv sektörü, güvenlik, biyoinformatik, çevre bilimleri, yüksek enerjili fizik, kaos teori gibi pek çok alanda kullanımı mevcuttur [49]. DVM amacı bir veri setini iki sınıfa ayıran bir hiper düzlem veya bir karar yüzeyi bulmaktır [33, 50]. Alt düzlemi belirleyen veri noktaları 'destek vektörleri' olarak adlandırılır.

İki sınıfa ait veri noktalarını ayırmak için pek çok alt düzlem kullanılabilir. Temel amaç en fazla marjı olan n boyutlu uzayda bir hiper düzlem bulmaktır. Bir marj giriş özelliklerinin sayısı ile ilgili olan hiper düzlemin boyutuna bağlı olan iki sınıf arasındaki mesafedir [49]. DVM verilerin doğrusal olarak ayrılabilmesi ve ayrılamamasına göre ikiye ayrılır [33,50,51].

2.4.1.1. Doğrusal Destek Vektör Makineleri

Doğrusal DVM ile iki özelliğe sahip veri noktalarını Şekil 2.9’da gösterildiği gibi +1 ve -1 olarak etiketlenmiş iki sınıf arasına düz bir çizgi çizilebilmektedir.



Şekil 2. 9. Doğrusal DVM modeli [50].

Denklem 2.8 ‘de verilen eşitlikle kısaca ifade edilebilir.

$$S = \{(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n), (X_i, Y_i) \in R^n \times \{+1, -1\}\} \quad (2.8)$$

Burada n özellik vektör sayısını, Y_i ise hem -1 hem +1 etiketlerini ifade eder. Denklem 2.8’den yola çıkarak, matematiksel ifadesi denklem 2.9 ve denklem 2.10 ‘de verilen eşitliklerle H_1 ve H_2 isimli iki paralel düzlem oluşturalım.

$$H_1: w \cdot X_i + b \quad Y_i = +1 \quad (2.9)$$

$$H_2: w \cdot X_i + b \quad Y_i = -1 \quad (2.10)$$

Bu denklemlerde w alt düzlemin normal vektörü, X_i giriş vektörü ve b skalerdir. Bu eşitlikler üzerinden H_1 ve H_2 doğruları arasındaki uzaklık denklem 2.11’ de verilen eşitlikler aracılığıyla hesaplanır.

$$w \cdot X_1 + b = +1$$

$$w \cdot X_2 + b = -1$$

$$w \cdot (X_1 - X_2) + b = 2$$


$$\frac{w}{\|w\|} (X_1 - X_2) + b = \frac{2}{\|w\|} = -\frac{2}{\sqrt{w \cdot w}} \quad (2.11)$$

Denklem 2.11 sonucu H_1 ve H_2 doğruları arası uzaklık $\frac{2}{\|w\|}$ olarak formülize edilir.

Şekil 2.9 'da H_1 ve H_2 düzleminin medyanı H_0 olarak ifade edelim. Alt düzlemin pozitif girişten en kısa uzaklığı diğer bir ifadeyle H_0 ve H_1 arası uzaklık d^+ , alt düzlemin negatif girişe en kısa mesafesi diğer bir ifadeyle H_0 ve H_2 arası uzaklık d^- olarak gösterilmiştir. Her ikisi de $\frac{2}{\|w\|}$ uzunluğundadır.

2.4.1.2. Doğrusal Olmayan Destek Vektör Makineleri

Doğrusal olarak ayrılamayan veri setlerinin sınıflandırılmasında doğrusal olmayan DVM yöntemleri kullanılır. Kernel temelli ayırma düzlemi ile sınıflandırma yapılır. Ana amaç farklı değerlerle ölçülen düzlemleri Şekil 2.10' da gösterildiği şekilde lineer olarak ayrılabilir yeni düzleme taşımaktır.



Şekil 2. 10. Doğrusal olmayan DVM modeli [51].

Bu yeni düzlemde veriler doğrusal olarak ayrılmış olur. Eğri oluşturmak yerine iki sınıfı sorunsuz ayıran bir hiper düzlem seçimi yapılması gerekir. Bu yöntem 'Kernel Hilesi' olarak adlandırılır. Kernel hilesi matematiksel olarak denklem 2.12'te verildiği şekilde ifade edilebilir.

$$K(X_i, Y_i) = \phi(X_i) \cdot \phi(Y_i) \quad (2.12)$$

Burada K Kernel fonksiyonunu, $\phi(X_i)$ ve $\phi(Y_i)$ iç çarpımın eğitim demetleri biçimini temsil etmektedir. Eğitim demetleri sadece iç çarpımın formlarıdır. Ama doğrusal DVM' de en yüksek mesafe uzayını bulmak veri setinin iç çarpımına ihtiyaç duyulmaz. Çok fazla kernel fonksiyonu vardır. Farklı seçimler DVM sınıflandırıcı performansını etkiler. En önemli popüler kernel fonksiyonları lineer, polinomial ve Gaus Radyal Temelli(GRT) fonksiyonudur. Bu tez çalışmasında DVM sınıflandırmaları GRT fonksiyonu aracılığıyla yapılmıştır. Kullanılan GRT fonksiyonunu matematiksel ifadesi denklem 2.13'te verilmiştir.

$$K_{GTF}(X_i, Y_i) = \exp(\|X_i - Y_i\|^2) \quad (2.13)$$

2.4.2. Ortak Vektör Yaklaşımı

OVY çevresel etkiler, kişisel ve faz farklılıkları, konuşulan kelimenin geçici değişimleri gibi istenmeyen bilgileri ortadan kaldıran bir alt uzay yöntemidir. OVY yönteminde kelime sınıfının ortak özelliklerini veya değişmez özelliklerini temsil eden ortak bir vektör hesaplanır. Özellik çıkarma yöntemi olan ortak vektör yaklaşımı yalnızca verilerin sınıf içi dağılımı dikkate alınarak her sınıfa ayrı ayrı uygulanır [52].

OVY özellik uzayının boş uzay ve aralıklı uzay olmak üzere iki alt uzaya ayrılmasına dayanan bir sınıflandırma yöntemidir. Bu yöntem genellikle yüz tanıma [53], kelime tanıma [54], konuşmacı tanıma [55], görüntü sınıflandırma [56], elektrik motorlarının arıza tespitinde [57], kısa devre arızalarının tespiti [58], görüntüden kenar tanıma [59], istenmeyen (spam) e-posta tanıma [60] ve otomobil sürücülerinin stres seviyelerinin belirlenmesi [61] gibi çeşitli problemlerinin çözümü için tercih edilmiştir. Ana amaç sınıfın doğal özelliklerini koruyan özgün bir ortak vektör bulmaktır [58].

OVY kavramını ses üzerinden açıklayacak olursak aynı kelimenin değişik konuşmacılar tarafından söylenmesi sırasında oluşan farklılıkların çıkarılmasıyla oluşan ve söylenen kelimenin özelliklerini içeren vektördür. Ortak vektör metodu her bir sınıfın eğitiminde kullanılacak olan özellik vektörü boyutuna eşit ya da daha az olduğu durumda konuşmacıdan bağımsız ayrık kelime tanıma problemleri için önerilen başarılı bir metottur. Bu metot her bir sınıf için ortak değişinti matrisinin sıfır olmayan öz değerlerine

karşılık gelen öz vektörlerinin yönünde olan tüm bileşenlerinin çıkarımını önerir. Bu işlemden sonra elde edilen özellik vektörü her bir sınıf için tek olup ortak vektör olarak adlandırılır. Bu işlemden sonra elde edilen özellik vektörü her bir sınıf için tek olup ortak vektör olarak adlandırılır. Ortak vektörün çıkartımı sırasında her bir sınıf için n özellik vektör boyutu ve m özellik vektör sayısına bağlı olmak üzere olası iki durum vardır. Eğer $n < m$ ise yeterli veri durumu; $n \geq m$ ise yetersiz veri durumu söz konusudur [33].

2.4.2.1. Yetersiz Veri Durumu

Bir örüntü sınıfının eğitim kümesinde bulunan öznitelik vektörleri sırasıyla $a_1, a_2, \dots, a_m$ olsun. Doğrusal bağımsız olarak kabul edilen bu öznitelik vektörleri denklem 2.14'te verilen eşitlikle ifade edilebilir:

$$a_i = a_{i,fark} + a_{ortak} + \varepsilon_i \quad i = 1, 2, \dots, m \quad (2.14)$$

Burada, $a_{i,fark}$ vektörü, örüntü sınıfındaki herhangi bir öznitelik vektörünün diğer öznitelik vektörleri ile arasındaki farkların yanı sıra, faz veya geçici farklılıkları gösterir. a_{ortak} , bir örüntü sınıfına ait ortak vektörü ε_i de hata vektörünü gösterir. Denklem 2.14'te, $(2m + 1)$ adet bilinmeyen vektörle beraber, m adet vektör denklemi vardır. Buradan $a_{i,fark}$, a_{ortak} ve ε_i için sonsuz sayıda çözüm olduğu söylenebilir.

a_{ortak} 'ı elde etmek için, öncelikle, bir örüntü sınıfına ait fark vektörlerini denklem 2.15'te verilen eşitlikle (b_j) tanımlayalım:

$$b_j = a_{j+1} - a_1 \quad j = 1, 2, \dots, m - 1. \quad (2.15)$$

Denklem 2.15'te a_i , örüntü sınıfında seçilen eksilen (subtrahend) vektördür.

Bu tanımlamanın ardından, Gram-Schmidt dikgenleştirme yöntemi kullanılarak, fark vektörlerinden birimdik taban vektör kümesi $\{z_1, z_2, \dots, z_{m-1}\}$ oluşturulur. Bu birimdik taban vektörlerin gerdiği altuzay, o örüntü sınıfı için farklılık altuzayıdır. Örüntü sınıfına ait herhangi bir a_i öznitelik vektörünün, o örüntü sınıfına ait farklılık alt uzayına izdüşümü hesaplanırsa, $a_{i,fark}$ bulunmuş olur. Denklem 2.16'da $a_{i,fark}$ 'ın matematiksel ifadesi verilmiştir.

$$a_{i,fark} = (a_i, z_1)z_1 + (a_i, z_2)z_2 + \dots + (a_i, z_{m-1})z_{m-1} \quad \forall i = 1, 2, \dots, m. \quad (2.16)$$

Bu hesaplamadan sonra a_{ortak} , herhangi bir öznitelik vektörünün taban vektör kümesi üzerindeki izdüşümlerinin kendisinden çıkartılmasıyla denklem 2.17’de verilen eşitlik ile elde edilir.

$$a_{ortak} = a_i - a_{i,fark} \quad \forall i = 1, 2, \dots, m. \quad (2.17)$$

a_{ortak} , ‘ i ’ indisinden ve eksilen vektörden bağımsızdır.

Farklılık alt uzaylarının ve ortak vektörün hesaplanmasıyla, OVY yönteminin eğitim aşaması tamamlanmış olur. OVY yönteminin test (sınama) aşamasında ise, örüntünün test kümesinde yer alan ve hangi sınıfa ait olduğu bilinmeyen a_x vektörünün öncelikle örüntüdeki tüm sınıflara ait farklılık alt uzaylarına olan izdüşümleri denklem 2.18’de verilen eşitlikle ayrı ayrı hesaplanır.

$$a_x^c = (a_x, z_1^c)z_1^c + (a_x, z_2^c)z_2^c + \dots + (a_x, z_{m-1}^c)z_{m-1}^c \quad c = 1, 2, \dots, S. \quad (2.18)$$

Burada a_x^c , bilinmeyen a_x vektörünün C . Sınıfa ait farklılık alt uzayına olan izdüşümünü; z_i^c ’ler ($i = 1, 2, \dots, m - 1$), C . Sınıfa ait farklılık alt uzayını geren birimlik taban vektörlerini ve S ise tüm örüntü verisindeki sınıf sayısını göstermektedir.

Daha sonra, örüntünün test kümesinde bulunan ve hangi sınıfa ait olduğu bilinmeyen a_x vektörü, denklem 2.19’da verilen eşitlikle karar ölçütü kullanılarak sınanır ve uygun olan sınıfa ataması gerçekleştirilir.

$$S^* = \underset{1 \leq c \leq S}{\text{en küçük}} \|a_x - a_x^c - a_{ortak}^c\|^2 \quad (2.19)$$

Burada, a_{ortak}^c , C . sınıfa ait ortak vektörü ve S^* ise test işlemi sonucunda a_x vektörünün atandığı sınıfı temsil eder. Sınıflama işleminin bitirilmesiyle beraber OVY de tamamlanmış olur.

2.4.2.2. Yeterli Veri Durumu

Bu tip veri durumlarında: bir örüntü sınıfına ait ortak vektör, ortak değişinti (kovaryans) matrisi kullanılarak bulunabilir. Ortak vektör yaklaşımının ortak değişinti matrisi kullanılarak gerçekleştirilmesinde, öncelikle, bir örüntü sınıfına ait özellik vektörlerinden ortak değişinti matrisi denklem 2.20’de verilen eşitlikle tanımlanır.

$$\Phi = \sum_{i=1}^m [(a_i - a_{ort})(a_i - a_{ort})^T] \quad (2.20)$$

Burada a_{ort} , örüntünün eğitim kümesindeki bir sınıfa ait öznitelik vektörlerinin ortalama vektörünü; Φ ise o örüntünün sınıfına ait ortak değişinti matrisini göstermektedir.

Hesaplanan ortak değişinti matrisinin özdeğer- özvektör ayrıştırması yapılır ve bu işlemden sonra n adet sıfırdan büyük özdeğer elde edilir. Bu değerler, büyükten küçüğe doğru sıralanır. Özdeğerler içerisinde en büyük k tane özdeğer denklem 2.21' te eşitsizlik yardımı ile seçilir.

$$\frac{(\sum_{i=k+1}^n \lambda_i)}{(\sum_{i=1}^n \lambda_i)} \leq Y \quad (2.21)$$

Burada, k , seçilen özdeğer sayısını; λ_i , özdeğerleri ve Y de özdeğer seçiminde kullanılacak olan sabit yüzde değeri ifade etmektedir. Sabit yüzde değer, ne kadar büyükse, seçilen özdeğer sayısı o kadar küçük; ne kadar küçükse, seçilen özdeğer sayısı o kadar fazladır.

Ortak değişinti matrisinin k adet özdeğerine karşılık gelen k adet özvektör vardır. Bu özvektörler, örüntü sınıfının farklılık altuzayını gerektirir. Geriye kalan $(n - k)$ adet özvektör de o örüntü sınıfının farksızlık altuzayını gerektirir. Bu durumda, örüntü sınıfına ait herhangi bir a_i öznitelik vektörünün, o örüntü sınıfına ait farklılık alt uzayına izdüşümü $(a_{i,fark})$ denklem 2.22'de verilen eşitlikle hesaplanır.

$$a_{i,fark} = \sum_{i=1}^k [(a_i^T u_i) u_i] \quad (2.22)$$

Burada, u_i 'ler örüntü sınıfının farklılık altuzayını gerektiren özvektörlerdir. Örüntü sınıfına ait ortak vektör ise, ortalama vektörü yardımı ile denklem 2.23'te verilen eşitlikle hesaplanır.

$$a_{i,farortak} = \sum_{i=k+1}^n [(a_{ort}^T u_i) u_i] \quad (2.23)$$

Farklılık/farksızlık alt uzaylarının ve ortak vektörün hesaplanmasıyla, OVY'nin eğitim aşaması tamamlanmış olur. OVY'nin test (sınama) aşamasında ise, örüntünün test kümesinde hangi sınıfa ait olduğu bilinmeyen a_x vektörü, denklem 2.24'te matematiksel ifadesi verilen karar ölçütü kullanılarak sınanır ve uygun olan sınıfa ataması gerçekleştirilir:

$$S^* = \underset{1 \leq c \leq S}{en\ küçükle} \|\sum_{i=k+1}^n (a_x - a_{ort}^c)^T u_i^c\|^2 \quad (2.24)$$

Burada S , tüm örüntü verisindeki sınıf sayısını; u_i^c , C . sınıfa ait farksızlık alt uzayını geren özvektörleri; a_{ort}^c , C . sınıfa ait ortalama vektörünü ve S^* ise test işlemi sonucunda a_x vektörünün atandığı sınıf temsil eder. Sınıflama işleminin bitirilmesiyle beraber OVY de tamamlanmış olur.




3. BULGULAR VE TARTIŞMA

Bu tezde, EEG ile yapılan duygu analizi çalışmalarında en çok tercih edilen DEAP veri seti ile çalışılmıştır. DEAP veri setine eecs.qmul.ac.uk/mmv/datasets/deap/index.html adresindeki yönlendirmeler takip edilerek, akademik çalışma yapılacağına dair anlaşmanın imzalanarak gönderilmesi sonucu verilen kullanıcı adı ve şifre ile erişim sağlanmaktadır. Tez içerisinde sinyal işleme ve sınıflandırma işlemleri MATLAB programı aracılığıyla yapılacağı için .mat uzantılı 128 Hz olarak kullanıcılara sunulan veri seti indirildi.


İndirilen dosyada, 32 kişinin 40 müzik videosunu izlerken oluşan 40 kanal ile kaydedilen fizyolojik sinyaller ve her bir kanal için oluşan 8064 veri noktası yer almaktadır. Aynı zamanda her bir katılımcının videoların değerlik, uyarılma, baskınlık, beğenilme durumlarını değerlendirdiği SAM ölçeği sonuçları yer almaktadır.

EEG sinyalleri alt bantlarına ayırmak için 4. dereceden DPD kullanılmıştır. Bu dönüşüm ile Şekil 2.8’de verilen ağaçta görüldüğü gibi 4 Hz bant aralığına sahip 16 bileşen oluşmuştur. 0 – 4 Hz aralığı δ , 4-8 Hz aralığı θ , 8-16 Hz aralığı α , 16-32 Hz aralığı β ve 32-64 Hz aralığı γ olarak değerlendirilmiştir. Şekil 3.1’de EEG sinyalinin frekans bantlarına ayrıştırılma aşamaları verilmiştir.




Şekil 3. 1. EEG sinyalini frekans bantlarına ayrıştırma aşamaları

Şekil 3.2’de verilen 1.grafik; 32. Kişinin 1. videoyu izlerken 1. kanalda oluşturduğu sinyalleri diğer grafikler ise 32. Kişinin 1. videoyu izlerken 1. kanalda oluşturduğu sinyalin DPD analizi ile alt bantlarına ayrılmış verileri içermektedir. Sırasıyla δ , θ , α , β ve γ bant aralıklarının verileri gösterilmektedir.



Şekil 3. 2. 32. Kullanıcının 1. video verisi için 1. kanaldan DPD analiziyle oluşturulan alt bant verileri


Şekil 2.5’ te anlatılan SAM ölçeği ile değerlik, uyarılma, baskınlık ve beğenilme ölçeklerinde katılımcıların yaptıkları değerlendirmeler sınıflandırma çalışmalarında çıktı olarak kullanılmıştır. DEAP veri setine değerlik, uyarılma ve baskınlık 1-9 arası sürekli ölçek ile beğenilme ise 1-5 arası ayırık ölçek ile değerlendirilmiştir. Bu tez çalışmasında Şekil 2.6’da anlatılan iki boyutlu çoklu duygu uzay modeli kullanılmıştır. İncelenen akademik çalışmalara göre değerlik ve uyarılma düzleminde yapılan sınıflandırmalar daha başarılı olmaktadır. Bu nedenle bu iki düzlemde sınıflandırma yapılmıştır. Uyaran değerlendirmelerini iki boyutlu duygu uzay modeline aktarabilmek ve karar aşamalarını hızlandırabilmek için derecelendirmeler 5 eşik değere göre yapılmıştır. 5 ten küçük değerler “0” düşük olarak, 5’ten büyük olanlar “1” yüksek olarak değerlendirilmiştir. Uyaranların değerlendirilme aşamaları Şekil 3.3’te verilmiştir.



Şekil 3. 3. Uyaranların değerlendirme aşamaları.


İncelenen çalışmalarda, sınıflandırma başarımını etkileyen farklı etmenlerde olduğu için sınıflandırma başarımını arttırdığı söylenen bant aralıklarının değişkenlik gösterdiği görülmüştür. Ancak β sinyalleri daha fazla önerilmiştir. Bu nedenle ilk aşamada hangi özellik vektörünün daha etkili olduğunu ölçmek amacıyla beta sinyalleri ile sınıflandırma yapılmıştır. Bu sınıflandırma yapılırken özellik vektörleri hariç tüm parametreler aynı olacak şekilde sınıflandırma yapılmıştır. Özellik vektörlerini oluşturmak için en büyük değer, en küçük değer, ortalama mutlak değer, ortalama karekök, AO, SS, çarpıklık, basıklık, enerji, entropi ve hjorth parametresi yöntemleri kullanılmıştır.

Kullanılan özellik vektörü çıkarma yöntemlerinin hangisinin sınıflandırma başarımını daha olumlu etkilediğini gözlemlemek için MATLAB da yer alan Classification Learner Tool(CLT) aracılığıyla 5 eşik değerli çapraz doğrulama ile sınıflandırma yapılmıştır. Şekil 3.4'te yapılan sınıflandırma çalışması ile CLT aracının arayüz görüntüsü verilmiştir.



Şekil 3. 4. CLT analiz örneği.

Bu analizde 32 kişinin 40 video için oluşan 32 kanal verisi değerlik düzleminde değerlendirilmiştir. Şekil 3.5'te özellik vektörlerinin etkisini ölçmek amacıyla yapılan sınıflandırmaların işlem adımları verilmiştir.




Şekil 3. 5. Özellik vektörlerinin sınıflandırılma aşamaları.

Özellik vektörlerinin değişimiyle elde edilen sınıflandırma başarımları Tablo 3.1’de verilmiştir. Yapılan analizler sonucunda enerji yöntemiyle analizi yapılan veriler ile %63.4 başarımla en yüksek sınıflandırma başarısına ulaşılmıştır.

Tablo 3. 1. Özellik vektörlerinin değişimiyle elde edilen sınıflandırma başarımları


Özellik Vektör Yöntemi	En Büyük Değer	En Küçük Değer	Ortalama Mutlak Değer	Ortalama Karekök	Aritmetik Ortalama	Standart Sapma	Çarpıklık	Baskılık	Enerji	Entropi	Hjorth Parametresi
En Yüksek Başarı Oranı	%57.3	%58.2	%56	%55.4	%56.2	%59.8	%55.2	%55.3	%63.4	%60.1	%60.2

Şekil 3.6’da 32. Kişinin 1. videoyu izlerken oluşturduğu sinyallerin δ , θ , α , β ve γ bant aralıkları için enerji yöntemiyle oluşturulan özellik vektörleri gösterilmiştir.



Şekil 3. 6. 32. kullanıcının 1. video için 32. kanaldan alınan verilerden enerji yöntemi ile oluşturulan özellik vektörleri.

EEG sinyallerinin sınıflandırma başarısı sinyal işleme metodu, özellik vektör seçimi, sınıflandırıcı çeşidi, uyarın değerlendirilmesi, kanal seçimi gibi pek çok parametreye bağlıdır. Bu nedenle sınıflandırıcıların kıyaslanabilmesi için diğer parametrelerin aynı olması gerekmektedir. Buna istinaden OVY yönteminin performansını kıyaslayabilmek için DVM yöntemi ile sınıflandırma yapılmıştır. MATLAB CLT uygulamasıyla Fine Gaussian Kernel fonksiyonu aracılığıyla DVM modeli oluşturulmuştur. Ardından aynı eğitim ve test verileri için hem DVM hem de OVY için sınıflandırma sonuç tabloları oluşturulmuştur. OVY ve DVM ile yapılan sınıflandırmaların aşamaları Şekil 3.7’de verilmiştir.



Şekil 3. 7. OVY ve DVM sınıflandırma aşamaları.

32 kişinin 40 video için toplam 1280 veri noktası oluşmaktadır. Tüm kişilerin aynı anda değerlendirildiği sınıflandırmalarda veri noktalarının 1000 tanesi eğitimde, 280 tanesi testte kullanılmıştır. Eğitim verilerinde ilgili çıkış değerlerinin 0 ya da 1 olması durumuna göre 500'er tane olacak şekilde kullanılmaktadır. Test ve eğitim verileri rastgele seçilmektedir.

Sınıflandırma başarımları doğruluk değerine göre hesaplanmıştır. Doğruluk oranı matematiksel ifadesi Denklem 3.1’de verilmiştir [46].

$$\text{Doğruluk} = \frac{D}{D+Y} \times 100 \quad (3.1)$$

Denklem 3.1’de D eğitim sonucunda doğru tahmin edilen değerleri, Y eğitim sonucunda yanlış tahmin edilen değerleri ifade etmektedir.

OVY ve DVM yöntemleriyle 32 kanal için; değerlik düzleminde yapılan

sınıflandırmaların en yüksek ve ortalama başarımları Tablo 3.2’ de, uyarılma düzleminde yapılan sınıflandırmaların en yüksek ve ortalama başarımları Tablo 3.3’te verilmiştir.

Tablo 3. 2. DVM ve OVY yöntemi ile 32 kanal için değerlik düzleminde yapılan sınıflandırma sonuçları.

Sınıflandırma Yöntemi	Değerlik-32 Kanal									
	Delta		Teta		Alfa		Beta		Gama	
	EYB	OB	EYB	OB	EYB	OB	EYB	OB	EYB	OB
DVM	64.64	41	66.78	45.85	58.95	52.5	58.93	52.96	56.78	54.57
OVY	72.5	49.75	71.43	43.46	72.86	49.57	74.64	57.36	74.29	43.32

32 kanal tüm kullanıcı durumunda değerlik için en yüksek başarımlar β bandında %74.64 olmuştur ve ortalama başarımlar %57.36 bulunmuştur.

Tablo 3. 3. DVM ve OVY yöntemi ile 32 kanal için uyarılma düzleminde yapılan sınıflandırma sonuçları.

Sınıflandırma Yöntemi	Uyarılma-32 Kanal									
	Delta		Teta		Alfa		Beta		Gama	
	EYB	OB	EYB	OB	EYB	OB	EYB	OB	EYB	OB
DVM	71.07	54.11	62.14	41.82	70	51.25	60.71	54.54	67.86	58.04
OVY	82.5	57.32	84.64	54.96	83.57	51.69	83.93	47.64	70.36	30.61

32 kanal tüm kullanıcı durumunda uyarılma için en yüksek başarımlar θ bandında %84.64 olmuştur ve ortalama başarımlar %54.96 bulunmuştur.

Sınıflandırma başarımlarını etkileyen bir diğer faktör ise kanal seçimidir. EEG ile duygu analizi çalışmalarında karşılıklı lobların bir arada değerlendirilmesinin daha başarılı sonuç vereceği çalışmalarla ortaya konmuştur [62]. Zeynab Mohammedi ve arkadaşları (2016) DEAP veri seti ile yapılan sınıflandırma çalışmasında 10 kanal kullanımının başarımlarını olumlu etkilediğini ortaya koymuştur. Bu sonuçlar baz alınarak sınıflandırma çalışmalarında FP1-FP2, F3-F4, F7-F8, FC1-FC2, FC5-FC6 kanalları olmak üzere 10 kanal verisi ile analiz yapılmıştır.

OVY ve DVM yöntemleriyle 10 kanal için; değerlik düzleminde yapılan sınıflandırmaların en yüksek ve ortalama başarımları Tablo 3.4’te, uyarılma

düzleminde yapılan sınıflandırmaların en yüksek ve ortalama başarımları Tablo 3.5'te verilmiştir.

Tablo 3. 4. DVM ve OVY yöntemi ile 10 kanal için değerlik düzleminde yapılan sınıflandırma sonuçları.

Sınıflandırma Yöntemi	Değerlik-10 Kanal									
	Delta		Teta		Alfa		Beta		Gama	
	EYB	OB	EYB	OB	EYB	OB	EYB	OB	EYB	OB
DVM	70	53.25	75	55.4	80	58.7	75	51.75	75	48.95
OVY	90	57	90	56.25	90	53.95	70	50.7	70	51

10 kanal tüm kullanıcı durumunda değerlik için en yüksek başarımlar δ bandında %90 olmuştur ve ortalama başarımlar %57 bulunmuştur.

Tablo 3. 5. DVM ve OVY yöntemi ile 10 kanal için uyarılma düzleminde yapılan sınıflandırma sonuçları.

Sınıflandırma Yöntemi	Uyarılma-10 Kanal									
	Delta		Teta		Alfa		Beta		Gama	
	EYB	OB	EYB	OB	EYB	OB	EYB	OB	EYB	OB
DVM	85	48.95	80	49.1	70	40.35	80	47.5	85	51.9
OVY	90	52.6	95	52.7	90	52.3	95	58.55	90	52.4

10 kanal tüm kullanıcı durumunda uyarılma için en yüksek başarımlar β bandında %95 olmuştur ve ortalama başarımlar %58.55 bulunmuştur.

Bireysel değerlendirmelerde ise 40 video için 40'ar veri noktası oluşmuştur. Bireysel sınıflandırmada 40 veri noktasının 20'si eğitim verisi olarak ve 20'si test verisi olarak kullanılmıştır. Test ve eğitim verileri rastgele seçilmektedir

Literatürde EEG ile yapılan duygu sınıflandırma çalışmalarında bireysel değerlendirmeye de yer verilmiştir. OVY yönteminin bireysel değerlendirmede performansını gözlemlemek için seçilen 10 kanal verisi, analiz edilen δ , θ , α , β , γ sinyallerinin enerji yöntemi ile oluşturulan özellik vektörleri ve SAM sonuçları OVY ve DVM aracılığıyla sınıflandırılmıştır. Değerlik ve uyarılma düzlemlerinde yapılan sınıflandırmaların sonuçları EK1'de yer alan tablolarda verilmiştir.

4. SONUÇ

128 Hz frekansında 32x40x40x8064 boyutunda DEAP veri seti öncelikle db4 dalgacık ailesiyle 4. Seviyeden DPD analizi yapılarak EEG sinyalinin alt bantları elde edilmiştir.

8064 veri noktası Bölüm 2.3'te anlatılan sinyal işleme metotlarıyla tek boyuta indirgenmiştir. İncelenen çalışmaların çoğunluğunda duygu sınıflandırmasında β sinyallerinin daha etkili olduğu belirtildiği için β frekans bandı araştırmada tercih edilmiştir. Ardından 32x40x40 boyutuna indirgenen DEAP veri seti CLT aracılığıyla sınıflandırılmıştır. Tablo 3.1'de verilen sınıflandırma sonuçlarına göre enerji yöntemi ile elde edilen özellik vektörlerinin daha başarılı olduğu gözlemlenmiştir.

Literatürde yer alan bazı çalışmalarda kanal sayısının daha az olduğunda sınıflandırma başarımının arttığı ifade edilirken bazılarında tüm kanalların değerlendirilmesinin başarımı artırdığı gözlemlenmiştir. Duygu çalışmalarında insanların hisleri değişkenlik gösterdiğinden ötürü sınıflandırma eğitimlerinin bireysel yapılmasının daha başarılı sınıflandırma sonucu verdiğini ifade eden çalışmalar olmakla birlikte gerçek zamanlı kullanıma uygun sınıflandırıcı seçebilmek adına tüm kullanıcı verileriyle sınıflandırma çalışmaları yaparak başarımlarının gözlemlendiği çalışmalar da yapılmıştır. Bunlara istinaden karşılıklı loblar olmak üzere seçilen 10 kanal [62] ve 32 kanalın tamamı için hem bireysel hem de toplu olarak sınıflandırma yapılmıştır.

Bu tez çalışması ile OVY yöntemi ilk kez EEG analizinde kullanılmıştır. OVY yönteminin başarımını kıyaslayabilmek adına, incelenen çalışmalarda EEG analizi için en çok önerilen metotlardan olan DVM yöntemi seçilmiştir. MATLAB üzerinden aynı eğitim ve test verileri için hem DVM hem de OVY yöntemi ile yapılan sınıflandırma sonuçları EK1'de yer alan tablolarda verilmiştir.

32 kanal ve 10 kanal ile yapılan toplu sınıflandırmalarda en yüksek başarımlar OVY yöntemi ile sağlanmıştır. γ 32 Kanal için yapılan sınıflandırmada değerlik düzleminde, δ bandı 10 kanal için yapılan sınıflandırmada hem değerlik hem uyarılma düzleminde en yüksek başarımları vermiştir. Diğer bant aralıklarının hepsi hem 32 kanal hem de 10 kanal için uyarılma düzleminde en başarılı sonucu vermiştir.

10 Kanal ile bireysel sınıflandırmalarda en yüksek başarımlar; δ ve θ frekans

bantlarında DVM yöntemi ile uyarılma düzleminde sağlanırken α , β , γ için hem DVM hem OVY ile sağlanmıştır, duygu düzlemi değişkenlik göstermiştir.

Toplu değerlendirmelerde duygu tahmininde OVY yönteminin daha başarılı olduğu gözlemlenmiştir. Buna istinaden gerçek zamanlı değerlendirmede daha başarılı sonuç alınabileceği düşünülmektedir.

İlerleyen çalışmalarda hastalık teşhisi, motor nöron aktiviteleri vb. farklı alanlarda da EEG sinyalinin analizinde OVY yöntemi kullanılabilir. Sınıflandırma başarımını etkileyen özellik vektör seçimi, sinyal işleme yöntemleri, kullanıcıların SAM anket cevapları, başarımlarını ölçme metotları vb. pek çok etken olduğu için daha önce yapılan çalışmalarla kıyas metot hakkında yanlış yorumlamaya sebep olabilir. Bu nedenle sınıflandırma metotlarının performansını kıyaslayabilmek için başarımlarını etkileyen diğer aşamaları aynı yaparak analizler gerçekleştirilebilir. Deneysel prosedürler detaylandırılarak deney arası bekleme sürelerini, katılımcıların dinlenme süreleri gibi etmenler eşitlenerek algoritmaları daha iyi eğitilmesi sağlanıp sınıflandırıcı performansları kıyaslanabilir. Buna ek olarak ortamdaki ses, ışık gibi çevresel etmenlerinde olabildiğince aynı koşullar sağlanıp araştırmacılara sunmak için yeni veri setleri oluşturulabilir.

KAYNAKLAR

- [1] Li, M., Xu, H., Liu X., Lu, S. (2018), “Emotion recognition from multichannel eeg signals using k-nearest neighbor classification”, *Technology and health care*, 26(S1): S509 – S519.
- [2] Alakuş, T.B., Türkoğlu, İ. (2018), “Eeg tabanlı duygu analizi sistemleri”, *Türkiye Bilisim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, Cilt: 11, syf 26 – 39.
- [3] Shu L., Xie J., Yang M., Li Z., Liao D., Xu X., and Yang X. (2018), “A review of emotion recognition using physiological signals”, *Sensors*, 18(7).
- [4] Dzedzickis A., Kaklauskas A., and Bucinskas V. (2020), “Human emotion recognition: Review of sensors and methods”, *Sensors*, 20(3).
- [5] Menezes, M. L. R., Samara, A., Galway, L., Sant’Anna, A., Verikas, A., Alonso-Fernandez, F., Wang, H., Bond, R. (2017), “emotion recognition for virtual environments: an evaluation of eeg features on benchmark dataset”, *Personal and Ubiquitous Computing*, 21:1617–4917.
- [6] Koelstra, S., Muhl, 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, doi: 10.1109/T-AFFC.2011.15.
- [7] Soleymani, M., Lichtenauer, J., Pun, T., Pantic, M. (2011) “A multimodal database for affect recognition and implicit tagging”, *IEEE Transactions on Affective Computing*, 3(1):42–55.
- [8] Alarcão, S. M., Fonseca, M. J. (2017), “Emotions recognition using eeg signals: A survey”, *IEEE Transactions on Affective Computing*, 10(3):374–393.
- [9] Al-Qammaz A. Y., Yusof Y., and Ahamd F. K., “An enhanced discrete wavelet packet transform for feature extraction in electroencephalogram signals. Imaging”, *Signal Processing and Communication*, 26-28 July 2017, Penang, Maleyzsia.
- [10] Jadhav, N., Manthalkar, R., Joshi, Y. (2017),”Electroencephalography-based emotion recognition using gray-level co-occurrence matrix features”, *Proceedings of International Conference on Computer Vision and Image Processing*, pages 335–343, Springer Singapore, Singapore.

- [11] Liu, J., Meng, H., Nandi, A., Li, M. (2016), "Emotion detection from eeg recordings.", 2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD 2016), 13-15 Aug, Changsha, China.
- [12] Zhang, Y., Ji, X., Zhang, S. (2016), "An approach to eeg-based emotion recognition using combined feature extraction method", *Neuroscience Letters*, 633:152 – 157.
- [13] Mowla, Md R., Cano, R. I., Dhuyvetter, K. J., Thompson D. E. (2020), "Affective brain-computer interfaces: A tutorial to choose performance measuring metric", 6 May, Cornell University arXiv.
- [14] Ayata, D., Yaslan, Y., Kamasak, M. (2017), "Multi channel brain eeg signals based emotional arousal classification with unsupervised feature learning using autoencoders", In 2017 25th Signal Processing and Communications Applications Conference (SIU), Antalya, Türkiye.
- [15] Tripathi, S., Acharya, S., Dev Sharma, R., Mittal, S., Bhattacharya, S. (2017), "Using deep and convolutional neural networks for accurate emotion classification on deap dataset", In AAAI.
- [16] Bazgir, O., Mohammadi, Z., Habibi, S. A. H. (2018), "Emotion recognition with machine learning using eeg signals", 2018 25th National and 3rd International Iranian Conference on Biomedical Engineering (ICBME), 29-30 Nov , Qom, Iran.
- [17] Sarıkaya, M. A. (2016), "Real-Time Emotion Recognition from EEG Signals Using One Electrode Device", Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.
- [18] Wang, Z., Zhang, Z., Wang, W. (2019), "Emotion recognition based on framework of badeba-svm ", *Mathematical Problems in Engineering*, pages 1 – 9.
- [19] Mert, A., Akan, A. (2018), "Emotion recognition from eeg signals by using multivariate empirical mode decomposition", *Pattern Analysis and Applications*, 21(1):81.
- [20] Asghar M. A., Khan M. J., Fawad, Amin Y., Rizvan M., Rahman M., Badnava S., Mirhavadi S. S. (2019), "Eeg-based multi-modal emotion recognition using bag of deep features: An optimal feature selection approach", *Sensors (Switzerland)*, 19(23).

- [21] Özel P., Akan A., and Yilmaz B. (2019), “Synchrosqueezing transform based feature extraction from eeg signals for emotional state prediction”, Biomedical Signal Processing and Control, 52:152 – 161.
- [22] Yang H., Han J., Min K. (2019), “A multi-column cnn model for emotion recognition from eeg signals”, Sensors (Switzerland), 19(21).
- [23] Baghdadi A. and Aribi Y. (2019) , “Effectiveness of dominance for anxiety vs anger detection”, In 2019 Fifth International Conference on Advances in Biomedical Engineering (ICABME), pages 1–4.
- [24] Güntekin, B. (2006), “Yüz İfadesini Beyin Fizyolojik Olarak Nasıl Algılar? Beyin Dinamiği Yöntemleri Analiz”, Doktora Tezi, Dokuz Eylül Üniversitesi Sağlık Bilimleri Enstitüsü, İzmir, Türkiye.
- [25] Ayata, D. (2019), “Emotion Aware Artificial Intelligence for Cognitive Systems”, Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.
- [26] Alakuş, T. B. (2018), “EEG Verilerinden İşaret İşleme ve Sınıflandırma Teknikleri Kullanılarak Duygu Tahmini”, Doktora Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ, Türkiye.
- [27] Ünal H. P., Gökmen G., Yumurtacı M. (2020),” DEAP Veri Seti ile Yapılan Duygu Sınıflandırmaları: İnceleme”, 2020 Akıllı Sistemlerde Yenilikler ve Uygulamaları Konferansı (ASYU 2020), Ekim 15- 17, İstanbul, Türkiye.
- [28] A dataset for emotion analysis using eeg, physiological and video signals, <http://www.eecs.qmul.ac.uk/mmv/datasets/deap/download.html> ,25 Şubat 2020
- [29] Dingyin H., Wei L., Xi C.,” Feature extraction of motor imagery EEG signals based on wavelet packet decomposition”, International Conference on Complex Medical Engineering, May 22 – 25, 2011, Harbin, China.
- [30] Purnamasari P. D., Junika T. W., ” Frequency-based EEG Human Concentration Detection System Methods with SVM Classification”, 2019 IEEE International Conference on Cybernetics and Computational Intelligence (IEEE CYBERNETICSCOM), August 22- 24 2019, Banda Aceh , Indonesia.
- [31] Demir, Ö. (2008), “EEG Dalgalarının Wavelet (Dalgacık) Dönüşümü ile Değerlendirilmesi”, YL Tezi, Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü, Kütahya, Türkiye

- [32] Koçyiğit, M. (2020), “Zihinsel Aritmetik ve Motor Görüntü Tabanlı Fizyolojik Sinyallerin Değerlendirilmesi”, Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri, Türkiye.
- [33] Yumurtacı, M. (2014), “Yüksek Gerilim Enerji İletim Hattındaki Arızaların Dalgacık Paket Dönüşümü ve Ortak Vektör Yaklaşımıyla Sınıflandırılması”, Doktora Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.
- [34] Kocaman, Ç. (2010), “Yapay Us Yöntemleri Kullanılarak Enerji Kalitesi Bozucularının Belirlenmesi”, Doktora Tezi, On Dokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü, Samsun, Türkiye.
- [35] Lee B-G., Lee B.-L. and Chung W.-Y.(2014), “Mobile Healthcare for Automatic Driving Sleep-Onset Detection Using Wavelet-Based EEG and Respiration Signals”. Sensors, 14.
- [36] Polat, H. (2016), “Görsel – İşitsel Uyarılar Kaynaklı Oluşan Duyguların EEG İşaretleri ile Sınıflandırılması”, Yüksek Lisans Tezi, Dicle Üniversitesi Fen Bilimleri Enstitüsü, Diyarbakır, Türkiye.
- [37] Tanaka K., Hargens A. R. (2004), “Wavelet packet transform for R-R interval variability”, Medical Engineering & Physics, 26 (2004) 313–319.
- [38] Gül, E. (2018), “EEG Sinyallerinin Wavelet Yöntemiyle Dönüştürülerek Yapay Sinir Ağları ile Sınıflandırılması”, Yüksek Lisans Tezi, Eskişehir Osman Gazi Üniversitesi Sağlık Bilimleri Enstitüsü, Eskişehir, Türkiye.
- [39] MathWorks Help Center,
<https://www.mathworks.com/help/wavelet/gs/introduction-to-the-wavelet-families.html#f3-1009153>, 20 Mart 2020.
- [40] Afacan, Ç. (2019), “Kamu Spotlarının Etkisinin EEG Sinyalleri Ölçümü ile Değerlendirilmesi”, Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya, Türkiye.
- [41] Akıncı, H.M. (2013), “Fuzzy Cognitive Maps For Emotion Modeling”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.
- [42] Uzun, S. S. (2012), ” EEG İşaretlerinden Duygu Kestirimi”, Yüksek Lisans Tezi, Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü, Hatay, Türkiye.

- [43] MathWorks Help Center, <https://www.mathworks.com/help/wavelet/ref/wentropy.html?searchHighlight=wentropy&sid=srchtitle>, 1 Mart 2020.
- [44] Hjorth B. (1970), “Eeg analysis based on time domain properties”, *Electroencephalography and Clinic Neurophysiology*, 29(3):306–310.
- [45] Tuncer E. (2015), “Uyku Evrelemesinde Çeşitli Dalgacık ve Sınıflandırıcıların Performans Analizi”, Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli, Türkiye.
- [46] Maraş, A. (2016), “EEG Alt Bandlarının Tekil Spektrumu ile Duygu Durumları Arasındaki İlişki”, Yüksek Lisans Tezi, Bahçeşehir Üniversitesi Fen Bilimleri, İstanbul, Türkiye.
- [47] Demir S. (2009), “Sleep Stage Analysis”, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü, İzmir, Türkiye.
- [48] Wikipedia the Free Encyclopedia, https://en.wikipedia.org/wiki/Hjorth_parameters, 1 Mart 2020.
- [49] Ukil A. (2007), “Support Vector Machine”, In: *Intelligent Systems and Signal Processing in Power Engineering. Power Systems*. Springer, Berlin, Heidelberg.
- [50] Meral, B. (2019), “Breast Cancer Data Classification Using SVM, NB and KNN Algorithms”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.
- [51] Aygün A. B. (2019), “EEG Sinyalleri Kullanılarak Gerçek Zamanlı P300 Tabanlı Hecemeleme Sistemi Tasarımı”, Yüksek Lisans Tezi, Karabük Üniversitesi, Karabük, Türkiye.
- [52] Gülmezoğlu M.B., Dzhafarov V., Edizkan R., Barkana A., “The common vector approach and its comparison with other subspace methods in case of sufficient data”, *Computer Speech and Language*, 21 (2007) 266–281, 2007
- [53] Koç M. (2019), “Different Decision Fusion Methods for Modular Common Vector Approach”, 2019 IEEE 14th International Conference on Computer Sciences and Information Technologies (CSIT 2019), 17-20 September, Lviv, Ukraine.
- [54] Gülmezoğlu M.B., Dzhafarov V., Keskin M., Barkana A., “A Novel Approach to Isolated Word Recognition”, *IEEE TRANSACTIONS ON SPEECH AND AUDIO PROCESSING*, VOL. 7, NO. 6, NOVEMBER, 1999

- [55] Sadıç S. (2007), “OVY (Ortak Vektör Yaklaşımı) ve GMM (Gauss Katışım Modelleri) ile Metinden Bağımsız Konuşmacı Tanıma”, Doktora Tezi, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir, Türkiye.
- [56] Kalyoncu H.B., Ergin S., Gülmezoğlu M.B. (2020), “Block-Based Noisy/Clean Classification of Images Using the Common Vector Approach”, *Circuits, Systems, and Signal Processing* , 39:1387–1418.
- [57] Bulut S. (2018), “Asenkron Motorlardan Elde Edilen Titreşim Sinyalleri Kullanılarak Arıza Tespiti”, Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir, Türkiye.
- [58] Yumurtacı M., Gökmen G., Kocaman Ç., Ergin S., Kılıç O. (2016), “Classification of short-circuit faults in high-voltage energy transmission line using energy of instantaneous active power components-based common vector approach”, *Turkish Journal of Electrical Engineering & Computer Sciences* , 24: 1901 {1915.
- [59] Işık Ş., Özkan K. (2014), “Ortak Vektör Tabanlı Çok-Ölçekli ve Çok-Uzmanlı Yeni Bir Kenar Tanıma Methodu”, 2014 22nd Signal Processing and Communications Applications Conference (SIU 2014), 23-25 April, Trabzon, Türkiye.
- [60] Günel S., Ergin S., Gülmezoğlu M. B., Gerek N. (2006), “On Feature Extraction for Spam E-Mail Detection”, *MRCSS 2006, LNCS 4105, pp. 635 – 642, Springer-Verlag, Berlin Heidelberg, 2006*
- [61] Ergin S., Dağ G., Gülmezoğlu M. B. (2011), “Stress Level Diagnosis for Automobile Drivers Using Common Vector Approach”, 6th International Advanced Technologies Symposium (IATS’11), 16-18 May, Elazığ, Türkiye.
- [62] Mohammadi, Z., Frounchi, J., Amiri, M. (2016), “Wavelet-based emotion recognition system using EEG signal”, *Neural Comput & Applic* (2017) 28:1985–1990
- [63] A dataset for emotion analysis using eeg, physiological and video signals, <http://www.eecs.qmul.ac.uk/mmv/datasets/deap/index.html> , 25 Şubat 2020

EKLER

EK 1 BİREYSEL SINIFLANDIRMA BAŞARIM ORANLARI

EK 1-Tablo 1. OVY yöntemi ile değerlik düzleminde yapılan bireysel sınıflandırma sonuçları

Katılımcı	Değerlik-OVY									
	Delta		Teta		Alfa		Beta		Gama	
	EYB	OB	EYB	OB	EYB	OB	EYB	OB	EYB	OB
1	75	47.65	70	49.2	75	50.55	80	50.2	70	49.9
2	85	50.95	80	52.4	80	53.2	80	52.35	75	53.2
3	70	48.6	80	50.25	80	51.9	85	49.65	80	51.75
4	80	52.1	80	51.4	85	55.5	80	46.6	85	49.35
5	80	51.1	80	49.65	75	49.6	75	54.4	95	58.95
6										
7	95	49.9	90	53.15	90	54.65	90	51.25	90	50
8	75	55.5	85	54.1	70	50.15	85	51.3	70	52.95
9	75	48.65	75	51.4	75	51.55	80	52.15	70	50.75
10	75	49.45	70	52.3	70	49.85	85	60.65	95	63.55
11	85	50	85	49.9	85	48.65	80	50.3	80	49.85
12	75	51.2	80	53.8	75	48.9	80	52.9	85	53.35
13	75	50.5	85	50.8	75	51.25	90	62.25	95	62.3
14	70	50.5	85	51.1	85	51.8	95	53.55	85	52.6
15	75	50.3	75	52.25	75	48.5	80	53.9	80	53.6
16	80	50.05	75	49.7	85	55.5	85	56.1	85	57.55
17	80	51	75	50.6	75	50.9	65	47.1	75	49.35
18	80	48.45	65	43.05	80	50.35	90	54.6	85	57.45
19	80	50.45	80	50.35	85	50.45	80	54.4	75	50.6
20	75	47.8	75	48.75	80	50.75	90	53.9	80	52.8
21	80	52.4	85	51.15	80	50.4	65	47.6	75	49.5
22	70	50.5	80	49.15	80	50.25	80	54.4	75	51.85
23	95	53.5	85	52.15	85	53.95	90	55.4	90	55.4
24	75	49.75	80	50.6	70	49.7	80	48.45	75	50.15
25	70	49.7	70	48	70	48.05	70	46.8	80	50.8
26	85	46.75	80	45.85	90	44.75	80	45.45	85	47.35
27										
28	75	48.2	85	47.35	75	48	85	51.5	85	50.5
29	90	51.5	80	51.6	80	51.15	75	48.1	70	49.2
30	85	44.7	85	47.75	85	48.7	90	45.5	85	44.45
31	75	51.3	80	48.65	85	49.2	70	48.55	75	49.35
32	85	56.1	85	56.4	80	53.3	80	49.5	75	49.1

EK 1-Tablo 2. OVY yöntemi ile uyarılma düzleminde yapılan bireysel sınıflandırma sonuçları

Katılımcı	Uyarılma-OVY									
	Delta		Teta		Alfa		Beta		Gama	
	EYB	OB	EYB	OB	EYB	OB	EYB	OB	EYB	OB
1	80	52.2	85	51.6	75	50.15	80	49.8	80	49.45
2	75	49.65	70	48.6	80	50.95	75	46.65	75	47.05
3										
4	80	52.7	85	52.95	85	55.05	85	49.45	80	48.85
5	80	50.5	80	47.65	75	49.65	80	50.2	75	49.25
6	75	49.85	85	49.55	85	48.1	85	51.55	80	54.5
7	85	50.1	85	49.65	85	54.25	85	46	80	51.45
8	75	50.25	80	50.15	75	46.2	75	49	75	50.3
9	75	50	75	48.35	85	47.5	75	51.6	80	50.5
10	85	55.1	80	52.5	85	51.6	75	49.6	75	51.15
11	75	47.15	75	44.35	80	47.55	80	48.75	80	49.35
12										
13										
14	95	55.65	90	53.5	90	48.85	85	50.55	90	51.55
15	70	50.3	75	49.55	70	48.85	75	50.65	80	51.65
16	65	51.4	80	51.2	80	50.5	80	52.8	80	55.4
17	80	54.8	80	52.65	75	50.25	85	52.15	80	51.45
18	85	49.85	80	47.75	85	50.8	80	53.45	85	51.7
19	85	51.95	80	49	90	50.4	85	49.05	85	50.2
20										
21										
22	80	55.5	85	55.05	90	56.25	85	47.55	85	49.5
23										
24										
25	95	60.05	95	55.7	90	44.15	95	51.1	95	46.7
26	75	51.4	80	48.9	75	48.75	70	50.3	75	49.1
27	95	52.7	90	51.1	85	47.55	85	48.4	95	44.3
28	85	52.9	75	50.55	90	53.45	75	52.05	75	52.2
29	85	51.5	80	48.9	80	46.3	80	46.15	75	46.3
30	75	50.8	85	52.1	70	50.5	75	50.95	75	51.15
31	75	53.15	80	50.85	80	51.1	80	50.05	75	49.8
32	85	51.2	85	51.35	90	52.75	85	53.75	85	53.8

EK 1-Tablo 3. DVM yöntemi ile değerlik düzleminde yapılan bireysel sınıflandırma sonuçları

Katılımcı	Değerlik-DVM									
	Delta		Teta		Alfa		Beta		Gama	
	EYB	OB	EYB	OB	EYB	OB	EYB	OB	EYB	OB
1	70	41.8	65	45.5	65	47.25	70	51.25	65	44.9
2	75	57.2	70	50.25	80	59.2	85	62.15	85	62.65
3	65	41.15	75	51.25	85	68.5	75	52.9	85	58.1
4	75	46.95	70	45.75	75	52.65	70	49.75	85	63.35
5	75	54.1	65	50.1	70	43.3	85	67.05	85	69.55
6										
7	85	60.35	85	56.15	85	59.9	90	42.7	90	44.05
8	75	59.6	70	57.75	78	58.05	70	54.8	75	53.35
9	75	56.55	85	61.5	75	57.1	75	52.6	80	54.65
10	75	55.5	75	59.4	75	52.05	90	75.25	95	75.4
11	85	60.8	85	58.05	80	54.7	75	47.2	70	46.45
12	70	49.3	70	54.65	80	59.65	75	52.2	75	54.8
13	75	49.25	80	60.65	75	57.85	85	63.9	85	66.05
14	80	58.15	70	53.3	90	62.6	85	60.7	95	74.65
15	60	41.3	65	46.25	70	52.5	80	55.9	85	54.55
16	75	49.95	75	48.65	80	49.85	85	58.3	80	59.4
17	65	51.65	75	49.85	75	51.75	70	50.8	65	49.35
18	75	44.85	70	47.35	90	58.7	95	75.6	90	75.5
19	90	63.7	90	68.55	70	54.1	80	59	85	65.35
20	80	55.4	75	52.95	90	67.4	85	67	85	68.15
21	75	56.15	75	53.6	65	47.75	70	48.1	70	51.7
22	75	53.85	75	60.05	70	49.25	75	55.6	80	60.15
23	75	37.3	85	50.55	75	41.05	75	46.3	75	46.3
24	70	46.6	65	45	75	55.15	75	52.15	75	57.05
25	70	50.15	80	59.9	80	58.2	65	48.05	70	47.9
26	75	52.7	80	51.95	85	60.05	85	66.1	85	53.1
27										
28	65	41.95	75	40.35	85	62.2	85	63.95	95	79.15
29	90	71.2	85	63.85	80	55.7	85	66.9	75	55
30	85	49.85	75	43.45	80	45	80	48.4	80	40
31	75	55.6	85	58.75	85	54.45	85	55.65	85	56.8
32	70	54.15	80	53.05	85	60.3	70	50.6	70	48.25

EK 1-Tablo 4. DVM yöntemi ile uyarılma düzleminde yapılan bireysel sınıflandırma sonuçları

Katılımcı	Uyarılma-DVM									
	Delta		Teta		Alfa		Beta		Gama	
	EYB	OB	EYB	OB	EYB	OB	EYB	OB	EYB	OB
1	65	47.25	70	47.55	80	52.95	75	45.3	75	53.65
2	70	49.6	70	41.3	60	38.15	75	45.6	75	48.35
3										
4	70	47.6	70	42.75	80	52.95	80	55.2	80	57.45
5	70	52.3	60	43.65	75	54.4	80	55.7	75	54.9
6	70	47.45	70	47	80	52.85	70	52.7	80	56
7	70	40.4	70	43.5	75	49.7	70	43.8	85	52
8	80	56.3	70	50.55	70	41.2	65	44.4	75	50.15
9	95	59.55	80	54.05	85	51.7	85	55.25	80	52.45
10	80	60.05	80	61.8	75	54.55	75	54.5	70	51.2
11	95	71.1	85	63.7	80	56.8	80	57.7	80	56
12										
13										
14	75	52	85	52.15	85	59.55	80	44.4	90	61.6
15	70	42.15	60	43.05	75	52.4	75	54.5	80	54
16	80	58.65	75	57.5	70	55.7	80	62.1	80	63.55
17	90	59.6	75	52.65	75	45.2	80	50.6	80	52.3
18	70	50.75	80	48.75	80	43.55	75	43.9	65	41.6
19	70	47.85	75	41.65	85	51.3	80	47.95	80	50.85
20										
21										
22	75	53.95	80	59.6	70	48.4	75	47.55	80	58.95
23										
24										
25	98	57.65	90	56.95	90	51.3	80	36.8	90	50.4
26	70	50.15	65	46.7	70	53.5	80	55.25	70	51.8
27	95	69.35	95	71.25	90	62.5	75	50.6	80	41.65
28	70	54	65	46.1	65	43.55	75	53.3	70	47.55
29	85	62.95	80	53	85	49.9	85	58.2	80	53.35
30	70	51.5	80	54.25	70	51.25	75	50.5	75	57.2
31	65	43.85	70	50.75	75	52.75	75	57.45	75	55.05
32	80	46.75	75	51.2	75	42.85	80	48.55	90	55.8

ÖZGEÇMİŞ

Ad Soyad: Hatice Pınar ÜNAL

Öğrenim Durumu

Derece	Bölüm/Program	Üniversite/Lise	Mezuniyet Yılı
Lise	Fen Bilimleri	Kaynarca Şevket Sabancı Lisesi	2012
Lisans	Mekatronik Mühendisliği	İstanbul Gedik Üniversitesi	2017

Akademik Yayın

Ünal H. P., Gökmen G., Yumurtacı M. (2020),” DEAP Veri Seti ile Yapılan Duygu Sınıflandırmaları: İnceleme”, 2020 Akıllı Sistemlerde Yenilikler ve Uygulamaları Konferansı (ASYU 2020), Ekim 15- 17, İstanbul, Türkiye.