



**EEG VERİLERİNDEN İŞARET İŞLEME VE SINIFLANDIRMA
TEKNİKLERİ KULLANILARAK DUYGU TAHMİNİ**

Talha Burak ALAKUŞ

Yüksek Lisans Tezi

Yazılım Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. İbrahim TÜRKOĞLU

TEMmuz-2018

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EEG VERİLERİNDEN İŞARET İŞLEME VE SINIFLANDIRMA
TEKNİKLERİ KULLANILARAK DUYGU TAHMİNİ

YÜKSEK LİSANS TEZİ

Talha Burak ALAKUŞ

(161137111)

Tezin Enstitüye Verildiği Tarih: : 02.07.2018

Tezin Savunulduğu Tarih : 23.07.2018

Tez Danışmanı : Prof. Dr. İbrahim TÜRKOĞLU (Fırat Ü.)

Diğer Jüri Üyeleri : Dr. Öğr. Üyesi Özal YILDIRIM (Munzur Ü.)

Dr. Öğr. Üyesi Seda ARSLAN TUNCER (Fırat Ü.)

TEMMUZ-2018

TEŞEKKÜR

Bu tez çalışması süresince, engin bilgilerini benimle paylaşarak tez boyunca bana destek olan, sürekli çalışmaya teşvik eden ve araştırmanın, okumanın önemini bana sürekli hatırlatan çok değerli ve saygıdeğer danışman hocam olan Prof. Dr. İbrahim Türkoğlu'na, beni yetiştirerek bu günlere gelmemde büyük emekleri olan, hayatımın her anında yanımda olarak beni sürekli sabır ve özveri ile destekleyen aileme, gerek tez gerekse akademik hayatım boyunca yanımda olarak beni sürekli sakinleştiren, karşıma çıkan sorunları düşünerek çözmemde yardımcı olan, bana sabrı öğreten ve bir ömür boyu yanımda olacak olan çok değerli ve sevgili eşim, hayat arkadaşım Dilan Onat Alakuş'a, teze destek vererek projenin gerçekleştirilmesinde payı olan Fırat Üniversitesi Bilimsel Araştırma Projeleri Birimini'ne teşekkürlerimi sunarım.

Talha Burak ALAKUŞ
ELAZIĞ – 2018

İÇİNDEKİLER

Sayfa No

TEŞEKKÜR.....	I
İÇİNDEKİLER.....	II
ÖZET	V
SUMMARY	VI
ŞEKİLLER LİSTESİ	VII
TABLolar LİSTESİ	IX
KISALTMALAR LİSTESİ	XI
SEMBOLLER LİSTESİ	XIII
1. GİRİŞ.....	1
1.1. Amaç.....	1
1.2. Yönelim Gerekçeleri.....	2
1.3. Tezin Organizasyonu	4
2. EEG VE DUYGU ANALİZİ	6
2.1. Beyin Kavramı ve Sinir Sistemi	6
2.2. Elektroensefalografi.....	9
2.3. EEG İşaretleri	11
2.4. EEG Elektrot Sistemi	12
2.5. Duygu Kavramı ve Duygu Analizi	13
2.6. Duygu Modelleri	13
2.7. Duygu Analizi Üzerine Yapılan Çalışmalar	17
2.8. Beyin Bilgisayar Arayüzü	21
2.9. Örüntü Tanıma.....	23
3. GELİŞTİRİLEN DUYGU ANALİZİ YÖNTEMİ	25
3.1. Kullanılan Veritabanı ve Elde Edilme Yöntemi.....	25
3.2. Özellik Çıkarım Süresince Kullanılan Yöntemler.....	29
3.2.1. Dalgacık Dönüşümü	30
3.2.2. Eğimden Arındırılmış Dalgalanma Analizi	33
3.2.3. Hjorth Tanımlayıcılar	34
3.2.4. Dalgacık Katsayı İşaretlerinin Ortalama Enerjisi	35
3.2.5. Entropi	35
3.2.6. Shannon Entropi	36

3.2.7.	Logaritmik Enerji Entropi	36
3.2.8.	Örnek Entropi	36
3.2.9.	Çok Ölçekli Entropi.....	37
3.2.10.	Standart Sapma.....	38
3.2.11.	Varyans	38
3.2.12.	Sıfır Geçişleri.....	39
3.3.	Sınıflandırma İşlemi için Başvurulan Sınıflandırıcılar.....	39
3.3.1.	K En Yakın Komşu Sınıflandırıcısı.....	39
3.3.1.1.	Mahalanobis Uzaklığı.....	41
3.3.2.	Destek Vektör Makineleri Sınıflandırıcısı.....	42
3.3.2.1.	Doğrusal Destek Vektör Makineleri.....	44
3.3.2.2.	Doğrusal Olmayan Destek Vektör Makineleri	47
3.4.	Yapay Sinir Ağları Sınıflandırıcısı	48
3.4.1.	Yapay Sinir Hücresinin Yapısı ve Elemanları.....	48
3.4.2.	Yapay Sinir Ağının Yapısı ve Elemanları	52
3.4.3.	Yapay Sinir Ağının Özellikleri.....	53
3.4.4.	Yapay Sinir Ağları Sınıflandırıcı Modelleri.....	54
3.4.5.	Çok Katmanlı Yapay Sinir Ağları	54
3.4.5.1.	İleri Beslemeli Hesaplama.....	55
3.4.5.2.	Geri Beslemeli Hesaplama	56
3.4.6.	Yapay Sinir Ağlarının Eğitilmesi	58
4.	BULGULAR VE TARTIŞMA	60
4.1.	DEAP Verisetinden Elde Edilen Bulgular.....	60
4.1.1.	KNN Sınıflandırıcısı ile Sınıflandırma.....	61
4.1.2.	DVM Sınıflandırıcısı ile Sınıflandırma	63
4.1.3.	YSA Sınıflandırıcısı ile Sınıflandırma	65
4.2.	Taşınabilir EEG Cihazı ile Elde Edilen Bulgular	68
4.2.1.	KNN Sınıflandırıcısı ile Sınıflandırma.....	69
4.2.2.	DVM Sınıflandırıcısı ile Sınıflandırma	71

4.2.3. YSA Sınıflandırıcısı ile Sınıflandırma	72
4.3. Öneriler.....	76
4.4. Yayınlar	77
KAYNAKLAR.....	78
EKLER	91
ÖZGEÇMİŞ	



ÖZET

EEG VERİLERİNDEN İŞARET İŞLEME VE SINIFLANDIRMA TEKNİKLERİ KULLANILARAK DUYGU TAHMİNİ

Talha Burak ALAKUŞ

Yüksek Lisans Tezi

Yazılım Mühendisliği Anabilim Dalı

TEMMUZ-2018

Örüntü tanıma, teknolojinin gelişmesiyle önemini arttırmış ve günümüzde sadece mühendislik alanında değil ayrıca endüstri, otomotiv, fizik, astronomi, biyoloji, tıp ve güvenlik sistemleri olmak üzere hemen hemen her alanda etkisini göstermektedir. Örüntü tanımanın amacı örüntü uzayında bilinmeyen şekilleri, örüntüleri ve işaretleri sınıflandırarak örüntüyü bulmaktır. Örüntülerin hangi sınıflara ait olduğu belirlenirken, örüntüler karar mekanizmasından geçerler. Bu mekanizmanın en önemli iki aşaması özellik çıkarım ve sınıflandırma aşamasıdır. Anahtar özelliklerin elde edilmesi sınıflandırma işleminin sonucunu etkilediğinden, özellik çıkarım örüntü tanıma için en önemli kısım olarak düşünülmektedir.

Bu tez çalışmasında, EEG işaretleri örüntü tanıma tekniği kullanılarak incelenmiş ve pozitif-negatif duyguların sınıflandırılması amaçlanmıştır. Karar sürecinin oluşturulmasında, dalgacık dönüşümü, entropi değerleri, zaman-frekans analizi ve istatistiksel yöntemler kullanılarak özellik vektörü elde edilmiştir. Anahtar özellikler YSA , DVM ve KNNsınıflandırıcılarına verilerek pozitif-negatif duyguların tanınması gerçekleştirilmiştir. Yöntemin geliştirilmesinde, DEAP veri tabanından elde edilen EEG işaretleri kullanılmıştır. Ayrıca önerilen yöntem, bilgisayar oyunlarının insanın duygusal durumuna etkisini inceleme amaçlı olarak da 25 farklı denekten elde edilen EEG işaretleri üzerinde denenmiştir. Geliştirilen yöntemin duygu analizinde, %85 – %90 aralığında başarımla değerine ulaştığı tespit edilmiştir.

Anahtar Kelimeler: EEG işareti, Örüntü tanıma, Duygu tahmini, Dalgacık dönüşümü, Yapay sinir ağları, Destek vektör makineleri, K en yakın komşu, Özellik çıkarımı.

SUMMARY

Emotion Detection Based on EEG Signals by Applying Signal Processing and Classification Techniques

Talha Burak ALAKUS

Master's Thesis

Department of Software Engineering

JULY-2018

Pattern recognition has applied in many areas in order to find unknown patterns, signs and figures through pattern space. In our day, it was used not only in engineering areas but also in industry, automotive, physics, astronomy, biology, healthcare services and security systems to specify the patterns. Pattern recognition consists of two parts which are feature extraction and classification. Feature extraction is the vital part of the recognition since it affects the performance and the accuracy of the classification process.

In this thesis, EEG based emotions were classified with pattern recognition techniques to determine the positive-negative emotions. To collect the key features, wavelet decomposition, entropy values, time-frequency analysis and statistical methods were applied. In the last part of the process, three different classifier algorithms –artificial neural network, support vector machines and k nearest neighbour were used discriminate emotions depending upon collected key features. EEG signals were collected from well-known and publicly available dataset from DEAP. Besides, the proposed method was used on 25 different subjects to observe the performance and accuracy of the discrimination process. The accuracy ratio designated between 85,0%- 90,0% with the recommended technique.

Key Words: EEG signals, Pattern recognition, Emotion estimation, Wavelet decomposition, Artificial neural newtorks, Support vector machines, K nearest neighbors, Feature extraction.

ŞEKİLLER LİSTESİ

	<u>Sayfa No</u>
Şekil 1.1. Örüntü tanıma sistemi	1
Şekil 2.1. Beyin yapısı ve kısımları.....	6
Şekil 2.2. Tipik sinir hücresi	7
Şekil 2.3. a) Taşınabilir 14 kanallı EEG cihazı, b) Taşınabilir 5 kanallı EEG cihazı, c) Taşınabilir tek kanallı EEG cihazı.....	10
Şekil 2.4. EEG işaretleri ve alt frekansları	11
Şekil 2.5. 10 – 20 elektrot sisteminin yerleşim planı	12
Şekil 2.6. Valans-uyarılma duygu düzlemi	14
Şekil 2.7. Duygu çemberi.....	15
Şekil 2.8. BBA akış diyagramı.....	22
Şekil 2.9. Örüntü tanıma adımları	24
Şekil 3.1. Deneysel sürecin adımları	26
Şekil 3.2. Elektrotların yerleştirildiği bölgeler	27
Şekil 3.3. Öz değerlendirme formu örneği	28
Şekil 3.4. Önerilen yöntemin akış şeması	30
Şekil 3.5. 4 seviyeli dalgacık dönüşümü	31
Şekil 3.6. KNN algoritma örneği	40
Şekil 3.7. İki farklı sınıf için çizilebilecek farklı hiper-düzlemler	43
Şekil 3.8. Hiper-düzlem ve en iyi hiper-düzlem	43

Şekil 3.9. Verilerin doğrusal ayrılamama durumu	47
Şekil 3.10. Yapay sinir hücresi yapısı	49
Şekil 3.11. Yapay sinir ağı modeli	52
Şekil 3.12. ÇKYSA modeli	54
Şekil 3.13. ÇKİBYSA öğrenme süreci.....	55
Şekil 3.14. ÇKGBYSA öğrenme süreci	58
Şekil Ek-1: Elektrotların yerleşim bölgesi	91



TABLÖLAR LİSTESİ

	<u>Sayfa No</u>
Tablo 2.1. İşaretlerin tekniksel ve davranışsal bilgisi.....	11
Tablo 2.2. Temel ve karşıt duygular	16
Tablo 2.3. Gelişmiş ve karşıt duygular	16
Tablo 3.1. Elektrotların yerleştirildiği bölgeler	26
Tablo 3.2. Dalgacık katsayılarına karşılık gelen frekans değerleri.....	32
Tablo 3.3. Kullanılan çekirdek fonksiyonları ve formülleri	48
Tablo 3.4. Toplama fonksiyonu için yaygın olarak kullanılan formüller	50
Tablo 4.1. 4 çıkış değeri ile elde edilen doğruluk sonuçları	61
Tablo 4.2. 2 çıkış değeri ile elde edilen doğruluk sonuçları	61
Tablo 4.3. 4 çıkış değeri ile elde edilen doğruluk sonuçları	62
Tablo 4.4. 2 çıkış değeri ile elde edilen doğruluk sonuçları	62
Tablo 4.5. 4 çıkış değeri ile elde edilen doğruluk sonuçları	63
Tablo 4.6. 2 çıkış değeri ile elde edilen doğruluk sonuçları	63
Tablo 4.7. 4 çıkış değeri ile elde edilen doğruluk sonuçları	64
Tablo 4.8. 2 çıkış değeri ile elde edilen doğruluk sonuçları	64
Tablo 4.9. 4 çıkış değeri ile elde edilen doğruluk sonuçları	65
Tablo 4.10. 2 çıkış değeri ile elde edilen doğruluk sonuçları	65
Tablo 4.11. 4 çıkış değeri ile elde edilen doğruluk sonuçları	66
Tablo 4.12. 2 çıkış değeri ile elde edilen doğruluk sonuçları	66
Tablo 4.13. EEG kanalları ile gerçekleştirilen tüm sınıflandırıcıların başarımlarının kıyaslanması	67
Tablo 4.14. EEG kanal çiftleri ile gerçekleştirilen tüm sınıflandırıcıların başarımlarının kıyaslanması	67
Tablo 4.15. 50x10x2 YSA modeli ile gerçekleştirilen sınıflandırmanın başarımlarının kıyaslanması	68

Tablo 4.16. 4 çıkış değeri ile elde edilen doğruluk sonuçları	69
Tablo 4.17. 2 çıkış değeri ile elde edilen doğruluk sonuçları	70
Tablo 4.18. 4 çıkış değeri ile elde edilen doğruluk sonuçları	71
Tablo 4.19. 2 çıkış değeri ile elde edilen doğruluk sonuçları	72
Tablo 4.20. 4 çıkış değeri ile elde edilen doğruluk sonuçları	73
Tablo 4.21. 2 çıkış değeri ile elde edilen doğruluk sonuçları	73
Tablo 4.22. EEG kanalları ile gerçekleştirilen tüm sınıflandırıcıların başarımlarının kıyaslanması	74
Tablo 4.23. 50x10x2 YSA modeli ile gerçekleştirilen sınıflandırmanın başarımlarının değeri ...	75
Tablo Ek-1: EEG cihazı hakkında teknik bilgiler.....	92

KISALTMALAR LİSTESİ

- ADD** : Ayrık Dalgacık Dönüşümü
- AKA** : Ampirik Kip Ayrışımı
- ART** : Adaptif Rezonans Teorisi
- BBA** : Beyin-Bilgisayar Arayüzü
- BT** : Bilgisayarlı Tomografi
- ÇKA** : Çok Katmanlı Algılayıcı
- ÇKGBYSA** : Çok Katmanlı Geri Beslemeli Yapay Sinir Ağı
- ÇKİBYSA** : Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı
- ÇKYSA** : Çok Katmanlı Yapay Sinir Ağı
- DDA** : Doğrusal Diskriminant Analizi
- DEAP** : Database for Emotion Analysis using Physiological Signals
- DGF** : Düşük Geçiren Filtre
- DPD** : Dalgacık Paket Dönüşümü
- DUNV** : Düşük Uyarılma Negatif Valans
- DUPV** : Düşük Uyarılma Pozitif Valans
- DVM** : Destek Vektör Makineleri
- EADA** : Eğitimden Arındırılmış Dalgalanma Analizi
- EEG** : Elektroensefalografi
- EKG** : Elektrokardiyografi
- EKoG** : Elektrokortikografi
- EMG** : Elektronöromiyografi
- fMRG** : Fonksiyonel Manyetik Rezonans Görüntüleme
- GA** : Genetik Arama
- GDT** : Galvanik Deri Tepkisi
- HFD** : Hızlı Fourier Dönüşümü
- İBE** : İnsan Bilgisayar Etkileşimi
- İKE** : İşletim Karakteristiği Eğrisi
- İKEA** : İşletim Karakteristiği Eğrisi'nin Alanı

KDA : Karesel Diskriminant Analizi
KDVM : Karesel Destek Vektör Makineleri
KFDA : Kernel Fischer Diskriminant Analizi
KNN : K En Yakın Komşu
MEG : Magnetoensefalografi
MRG : Manyetik Rezonans Görüntüleme
NB : Naive Bayes
NIRS : Near Infrared Spectroscopy - Yakın Kızılötesi İşaretleme Yöntemi
OA : Olasılıksal Ağlar
ÖDF : Öz Değerlendirme Formu
ÖVK : Öğrenmeli Vektör Kuantumlama
PET : Pozitron Emisyon Tomografisi
PSO : Parçacık Sürü Optimazasyonu
RO : Rastgele Orman
RTFA : Radyal Tabanlı Fonksiyon Ağları
SDY : Sonsuz Dürtü Yanıtı
TMS : Transkranial Manyetik Stimülasyon
UDRS : Uluslararası Duygusal Resim Sistemi
UEDS : Uluslararası Etkili Dijital Ses
YGF : Yüksek Geçiren Filtre
YSA : Yapay Sinir Ağları
YUNV : Yüksek Uyarılma Negatif Valans
YUPV : Yüksek Uyarılma Pozitif Valans

SEMBOLLER LİSTESİ

α : Alfa Dalgası

β : Beta Dalgası

δ : Delta Dalgası

γ : Gama Dalgası

μV : Mikrovolt

θ : Teta Dalgası

1. GİRİŞ

İşaret işleme ve örüntü tanımanın teknolojiye paralel olarak kullanılması biyomedikal alanında yapılan çalışmaları arttırmakta ve geliştirmektedir. Biyomedikal işaretlerin EEG (Elektroensefalografi) EKG (Elektrokardiyografi), EMG (Elektronöromiyografi) yorumlanması zor, uzun ve dikkat gerektiren bir iş olmasından dolayı makinelerle bağlı sistemlerin ihtiyacı doğmuştur. Geliştirilen sistemler sayesinde işaretler işlenerek sağlık alanında başarılı uygulamalar gerçekleştirilmektedir. Literatür incelendiğinde, EEG işaretleri aracılığıyla epilepsi, uyku bozuklukları, duygu tahmini, EKG verileriyle kalp ve ritim bozuklukları, EMG sinyalleriyle ise kas ağrıları üzerine çalışmalar olduğu görülmekte ve bunlara bağlı olarak bilgisayar tabanlı uygulamalar yapılmaktadır.

BBA (Beyin-Bilgisayar Arayüzü) insan ile beyin arasında doğrudan iletişimi sağlamaktadır. Daha çok çevresiyle ilişki kurmakta zorluk çeken ve kas ile sinir sistemi rahatsızlığı olan insanlar için geliştirilen BBA, EEG işaretlerini işleyerek arayüz aracılığıyla hastaların gerçekleştirmek istediği eylemleri yerine getirir. Arayüzün temelinde örüntü tanıma yatmaktadır ve Şekil 1.1’de görüldüğü gibi özellik çıkarma ve sınıflandırma olmak üzere iki adımdan meydana gelmektedir.



Şekil 1.1. Örüntü tanıma sistemi

1.1. Amaç

Bu tezin amacı, hazır EEG veritabanından (DEAP - Database for Emotion Analysis using Physiological Signals) elde edilen işaretlere dayalı pozitif-negatif duygularının ayrımı yapmak ve ileride geliştirilecek olan BBA uygulamalarına referans sağlamaktır. Bu doğrultuda örüntü tanıma ve işaret işlemeye dayalı yöntemler kullanılmıştır. EEG işaretleri dalgacık dönüşümüne tabi tutulup, her bir dalgacık katsayı işaretler bileşenlerinden istatistiksel ve entropiye dayalı özellikler elde edilmiş ve melez bir sistem geliştirilmiştir.

Geliştirilen sistemin son aşamasında ise özelliklerin etkinliğinin test edilmesi ve duyguların ayrımı işlemi için yapay sinir ağı, k en yakın komşu ve destek vektör makineleri olmak üzere üç farklı sınıflandırıcı kullanılmıştır. Tez çalışmasının diğer bir amacı ise, literatürde kullanılan hazır EEG verileri üzerinde geliştirilen uygulamanın, farklı karakteristikteki bilgisayar oyunları oynayan 25 kişiden elde edilen farklı EEG verileri kullanılarak, sistemin başarısının değerlendirilmesi şeklindedir.

1.2. Yönelim Gerekçeleri

Son zamanlarda bilgisayar oyunlarının popüleritesinin artması bu alana eğilimi arttırmış ve oyunlar artık sadece eğlence amaçlı değil aynı zamanda tıp alanında da kullanılmaya başlanmıştır. Günümüzde video oyunları aracılığıyla rehabilitasyon tedavisi gören hastaların ihtiyaçları giderilmekte [1, 2], felçli kişilerin engelleri giderilmeye çalışılmakta [3] ve beyin ameliyatı sonrası görme bozukluğu yaşayan kişilerin tedavileri yapılmaktadır [4]. Ancak bilgisayar oyunlarının yararı olduğu kadar zararları da olduğu ortaya çıkmaktadır. Dünya Sağlık Örgütü'ne göre genç nüfusta yaygın olan ikinci ölüm nedeni intihardır [5]. Son yıllarda popüler bir çevrimiçi oyun olan Mavi Balina (Blue Whale Challenge) oyununda oyuncuların yapması gereken görevler bulunmakta ve oyunun son görevinde kişilerden intihar etmeleri istenmektedir [6]. Ülkemizde de oynanan ve çocukların intihar etmelerine neden olan bu oyun [7-8], yalnızca ülkemizde değil aynı zamanda dünya üzerinde çok sayıda kişinin ölümüne neden olmuştur. Sadece Rusya'da yüzlerce kişi bu oyun yüzünden vefat etmiştir [9].

Kişiler herhangi bir aktiviteyi yerine getirirken, televizyon izlerken, kitap okurken, bilgisayar oyunları oynarken duygularını kullanmaktadırlar. Oyunların tarzına göre kişilerde açığa çıkan duygular farklılık göstermektedir. Korku oyunlarında korku duygusu, eğlenceli oyunlarda mutluluk duygusu ve macera oyunlarında heyecan duygusu ön plandadır. Bundan dolayıdır ki oyunlara bağlı duygu analizinin önemi büyüktür. Mavi Balina ve türevleri oyunlarda, intihar gibi girişimlerin önüne geçilmesi için duygu tahmini işleminin yapılması öngörülmüş ve buna bağlı olarak ileride BBA'ya dayalı bir uygulamanın yapılması amaçlanmıştır. Bu tez çalışmasında örüntü tanımayla dayalı bir sistem tasarlanılarak duygu tahmini yapılmış ve gelecekte oyunlarla beraber kullanılmak üzere akıllı sistemler geliştirilerek intihar vb. girişimlerin önüne geçilmesine zemin hazırlanması hedeflenmiştir.

Literatürde örüntü tanıma tekniğinin yaygın kullanılmasının en önemli nedenlerinden birisi, öğrenme tabanlı olmaları ve kendi kendilerine eksik bilgi dahi olsa karar verebilmeleridir. Dolayısıyla enerji yönetimi [10], sağlık [11], farmakoloji [12], güvenlik uygulamaları [13], gibi birçok farklı alanda etkin bir şekilde kullanılmaktadır. Aynı zamanda örüntü tanıma ile BBA ve İBE (İnsan Bilgisayar Etkileşimi) uygulamaları daha sağlıklı sonuçlar vermektedir. EEG, EKG gibi durağan olmayan işaretlerin yorumlanmasında ve sınıflandırılmasında önemli derecede başarı elde edildiği [13, 15, 78] için tez çalışmasında örüntü tanıma başvurulmuştur.

Örüntü tanımayla beraber tez çalışmasında dalgacık dönüşümü de kullanılmıştır. EEG verileri zaman serilerinden meydana gelmekte ve içeriğinde eğim, ani değişim vb. durumlar bulunmaktadır [14]. Kimi zaman bu olağan olmayan kısımlarda önemli bilgiler bulunabilmekte ve bunların analiz edilebilmesi için gerekli donanımın olması gerekmektedir. Dalgacık dönüşümü farklı pencerelere sahip olduğu için tüm zaman-frekans değerleri aralığında en uygun durumu bulmaya imkân tanımaktadır. Bu şekilde ana dalgayı, taban fonksiyonları olan alt bileşenlere ayırmakta [15] ve durağan olmayan işaretleri bileşenleri aracılığıyla durağan hale getirmektedir. Bu tez çalışmasında da EEG işaretlerinin analizinin sağlıklı yapılabilmesi ve anahtar özelliklerin çıkarılması için dalgacık dönüşümüne başvurulmuştur.

Örüntü tanıma sürecinin son ayağı olan sınıflandırma işlemi için, yapay sinir ağları, destek vektör makineleri ve k en yakın komşu sınıflandırıcıları tercih edilmiştir. Yapay sinir ağları, insanlardaki sinir hücrelerinden esinlenmiş olan ve çoğu problemlerin çözümünde kullanılan matematiğe dayalı bir modeldir. Değişen durumlara karşı çabuk tepki vermeleri, hızlı öğrenmeleri, genelleme yapabilmeleri ve başarılı sonuç vermeleri birçok alanda tercih edilmesine sebep olmaktadır. Bu bilgilerden dolayı, bu tez çalışmasında da yapay sinir ağları kullanılmıştır.

DVM (Destek Vektör Makineleri) istatistiksel yöntemlere dayalı öğrenme tabanlı bir yöntem olup, örüntü tanıma sistemlerinde kullanılan bir modeldir. Genelde iki ve çok sınıflı problemlerin çözümünde tercih edilmektedir. KNN (K En Yakın Komşu) sınıflandırıcısı eğitilmediği, uygulaması kolay, gürültülere karşı toleransa sahip olduğu için işaret işleme ve örüntü tanıma alanında tercih edilen sınıflandırma metotlarının bir diğeridir. Duygu analizi üzerine yapılan çalışmalar incelendiğinde, DVM ve KNN komşu sınıflandırıcılarının, bazı EEG kanallarının sınıflandırılmasında etkili bir sınıflandırma aracı olduğu belirlenmiş [45,

57] ve bundan dolayı, tez çalışmasında da YSA'nın başarısı ile karşılaştırılmak üzere bu sınıflandırıcılara da başvurulmuştur.

Yukarıda bahsi geçen tüm metotlar kullanılarak hazır EEG verisetinden ve bilgisayar oyunu oynayan kişilerin EEG işaret verilerinden duygu analizi yapılarak pozitif/negatif duyguların ayrımı yapılmıştır. Dalgacık dönüşümüne uğrayan işaretlerden anahtar özellikler elde edilmiş ve üç farklı sınıflandırıcıya gömülerek başarımları değerlendirilmiştir.

1.3. Tezin Organizasyonu

Birinci kısımda yönelim nedenlerinden ve literatürden bahsedilerek yapılan çalışmaya dair genel bilgiler verilmiştir. Tezin diğer bölümlerine ait bilgiler aşağıdaki gibidir;

İkinci bölümde, beyin ve yapısı incelenerek sinir sisteminden bahsedilmiştir. Sinir sisteminin kavramlarının açıklanmasıyla EEG verilerinin anlamları daha açık olacağından EEG işaretleriyle bağlantıları ve içerdiği bilgilere değinilmiştir. EEG işaretlerinin tarihçesinden bahsedilmiş ve geçmişten günümüze hangi amaçlarla kullanıldığı ve elde edilme yöntemleri irdelenmiştir. EEG verileri kendi içlerinde alt frekanslara ayrılmakta ve bu alt frekansların kendine ait bilgileri bulunmaktadır. Bu bilgilerin literatürdeki yerleri incelenmiş ve hangi alt bantların hangi çalışmalar için değerlendirildiği gösterilmiştir. Daha sonra duygu kavramının tanımı yapılmış ve EEG işaretlerine duygu analizine yönelik yapılan çalışmalar irdelenmiştir. Bu bölümün son kısmında ise, ileride geliştirmesi amaçlanan beyin bilgisayar arayüzüne dayalı sistemlerin günümüz teknolojisinde kullanım alanlarından bahsedilerek akademik çalışmalarda önemi belirtilmiş ve örüntü tanıma tekniği açıklanarak bileşenleri gösterilmiştir.

Üçüncü kısımda, duygu analizi işlemi için kullanılan metotlardan ve EEG verilerinden bahsedilmiştir. Verilerin nasıl elde edildiği ve elde edilmesinde kullanılan sistem hakkında teknik bilgiler incelenmiştir. Özellik çıkarım aşamasına geçilmeden önce, değerlendirilen EEG verilerinin hangi ön işleme tabi tutulduğu gösterilerek özellik çıkarım aşamasında başvuru bilgi ölçüm yöntemleri, istatistiksel metotlar ve entropiler tek tek açıklanmıştır. Örüntü tanıma işlemin son ayağı olan sınıflandırıcılardan üç tanesi üzerinden durulmuş ve hangi amaçlarla kullanıldıkları açıklanmıştır.

Dördüncü bölümde, geliştirilmiş olan örüntü tanıma uygulamasının değerlendirilmesi için yapılmış olan deneysel çalışmalardan bahsedilmiştir. Bu kısımda, önerilen metot, farklı kişilerden elde edilen EEG verileri kullanılarak test edilmiştir. Verilerin elde edilmesinde

kullanılan cihaz hakkında tekniksel bilgiler verilmiştir. Duyguların açığa çıkarılmasında kullanılan bilgisayar oyunları, tercih edilme nedenleri ve hangi duyguları tetiklediği gösterilmiştir. Son olarak, önerilen yöntem, bilgisayar oyunları oynayan kişilerin EEG işaret verileri üzerinde denenmiş ve kıyaslama işlemi yapılmıştır. Ayrıca bu bölümde tezin sonuçları irdelenmiş, teze ve gelecekte yapılabilecek uygulama alanlarına dayalı öneriler yapılarak tartışılmıştır.


Bu tez çalışması, Fırat Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından TEKF.17.21 nolu proje ile desteklenmiştir.



2. EEG VE DUYGU ANALİZİ

2.1. Beyin Kavramı ve Sinir Sistemi

Yapı maddesi protein olan ve çevreden gelen uyarılara görme, koklama, tat alma vb. eylemleri sergileyerek tepki veren, canlıların tüm vücut etkinliklerini kontrol eden sisteme beyin denir. Şekil 2.1’de gösterildiği gibi beyin beyinsapı, beyincik, orta beyin ve beyin zarı olmak üzere dört parçadan meydana gelmektedir.



Şekil 2.1. Beyin yapısı ve kısımları [16].

Beyin sapı: Otonom işlemlerden ve reflekslerden sorumludur. Merkezi sinir sistemini kontrol ederek uyku düzenini sağlamada önemli rol oynar. Kan basıncı, kalp atışı gibi hayati derecede önemli faaliyetleri düzenlemekle yükümlüdür.


Beyincik (Serebellum): Vücudun dengesini oluşturmada kilit rol oynamaktadır. Vücuttaki koordinasyonu düzenleyerek kişilerin hareket etmesini ve ayakta durabilmesini sağlar.

Orta beyin: Vücut sıcaklığını düzenler. İçgüdüsel faaliyetlerin ve duyguların kontrolünü sağlar.

Serebrum: Hafızadan sorumludur. Motor fonksiyonların kontrolünü gerçekleştirir. Ayrıca duygular bu kısımda işlenir.

Beyin, önden arkaya doğru iki ayrı kısma ayrılmış ve her birine yarıküre (hepifere) adı verilmiştir. Her yarıküre dört ayrı lobdan meydana gelir ve sırasıyla bu loblar, şakak lobu, artkafa lobu, yan tepe lobu ve ön lob olacak şekilde ifade edilirler. Her lobun vücuttaki görevi farklılık göstermektedir. Beynin ön kısmında bulunan ön lob planlama, problem çözme, sosyal faaliyetlerde bulunma gibi davranışa dayalı eylemleri kontrol ederken, yan tepe lobu daha çok hissetme, algılama, dokunma gibi faaliyetlerden sorumludur. Beynin arka kısmında bulunan lob olan artkafa lobu, görme duyusuyla ilgili görevleri yerine getirmektedir. Hasar görmesi durumunda kişilerde sanrı ve görme bozukluklarına neden olmaktadır. Beynin son lobu olan şakak lobu ise, ses ve kokudan sorumludur. Beynin kulak hizasında bulunurlar ve konuşma, işitme gibi eylemleri yerine getirirler.

Sinir sistemi nöronlardan (sinir hücrelerinden) meydana gelmektedir. Her sinir hücresinin hücre gövdesi, akson, dentrit, miyelin kılıf, çekirdek ve akson uçları olmak üzere altı farklı elemanı bulunmaktadır. Tipik bir sinir hücresinin yapısı Şekil 2.2’de verilmiştir.



Şekil 2.2. Tipik sinir hücresi [17].

Nöron (sinir hücresi): Dış dünyadan almış oldukları bilgileri hücrenin bir kısmından başka bir kısmına veya başka bir hücreye iletmekle görevlidir. Bu veriler nöron tarafından dentrit aracılığıyla elde edilmektedir. Bilgilerin taşınması tek yön olacak şekilde gerçekleşir.

Hücre gövdesi: Sinir hücresinin gerçekleştirmiş olduğu tüm işlemlerin merkezidir. Dentritten almış olduğu bilgileri işleyerek bilgilerin aktarılmasında önemli rol oynamaktadır. Ayrıca, vücuttaki metabolik faaliyetlerden sorumludur.

Dentrit: Başka hücrelerden gelen bilgileri veya uyarıları hücre gövdesine ileten dal şeklindeki yapıdır.

Akson: Sinir hücrelerine bilgilerin iletilmesinde aktif rol oynarlar. Hücre gövdesinde işlenen veriler, nöronlara aksonlar aracılığıyla gönderilir.

Miyelin Kılıf: Aksonları koruyan özel yapıya denmektedir. Miyelin kılıfın en önemli ve en belirgin özelliği, verilerin ya da uyarıların hızlı şekilde iletilmesini sağlar ve kayıpların olmasını engeller.

Sinir sistemin kontrol mekanizması olan beyin, tüm bu faaliyetleri vücuda elektiksel uyarılar (beyin işaretleri) göndererek yerine getirmektedir. Günümüzde beyin işaretleri elde edilirken çeşitli yöntemler kullanılmaktadır. Bu yöntemlerin bazıları ameliyat gerektirirken bazıları ise ameliyatsız, belirli bir müdahale gerektirmeyen yollarla gerçekleştirilir. Müdahale gerektirmeyen yöntemlerin işlenmesi daha kolay olduğu için ve çalışma süresi çok karmaşık olmadığından bu yöntemler daha çok tercih edilmektedirler. EKG (Elektrokortikografi) [18], MEG (Magnetoensefalografi) [19], MRG (Manyetik Rezonans Görüntüleme) [20], fMRG (Fonksiyonel Manyetik Rezonans Görüntüleme) [21], PET (Pozitron Emisyon Tomografisi) [22], TMS (Transkranial Manyetik Stimülasyon) [23], BT (Bilgisayarlı Tomografi) [24], EEG [25] ve NIRS (Yakın Kızılötesi İşaretleme Yöntemi) [26] beyin aktivitelerinin izlenmesinde ve sinyallerinin toplanmasında kullanılan yöntemlerin başında gelmektedirler.

EKG beyinde gerçekleşen elektriksel aktivitelerin toplanmasını sağlar. Daha çok sağlık alanında, hastalıkların tespitinde tercih edilen bir yöntemdir. İşaretler kortikal yüzeye (beyin kabuğu üzerine) yerleştirilen elektrotlar aracılığıyla elde edilir [27]. Beyin kabuğuna yerleştirildikleri için operasyon gerekmektedir. MEG, kafanın etrafına yerleştirilen süper iletken sensörler aracılığıyla, beyinin elektiriksel aktiviteleri sonucu ortaya çıkan manyetik alanı ölçmek için kullanılmaktadır.

Zamansal çözünürlüğü yüksek olduğu için doğrudan beyin aktivitelerini içeren işaretleri elde etmektedir. MRG yöntemi müdahale gerektirmeyen yöntemlerin başında gelmektedir. Bu yöntemde beyin işaretleri manyetik bir alana yerleştirilen kişilerden hidrojen atomlarının parçalanmasıyla toplanmaktadır. Atomların parçalanmasıyla dalgalar açığa çıkmakta ve bu dalgalar beyin elektriksel aktiviteleri hakkında önemli derecede bilgi içermektedir. fMRG ise aynı işlemleri yerine getirmekte ancak MRG yönteminden farkı oksijenli ve oksijensiz kandaki manyetik dalgaları ölçmesidir. PET onkoloji, nöroloji ve kardiyoloji alanında kullanılan ve tercih edilen başarılı bir görüntüleme yöntemidir. Bu yöntemde, kişilere önce Florodeoksiglukoz (F18) adı verilen madde enjekte edilmekte ve ardından otuz dakika boyunca belirli uyaranlarla (işitsel, görsel, işitsel ve görsel) veya görevlerle deneklerden beyin işaretleri elde edilmektedir. TMS beyindeki nöronları uyararak, beyinde oluşan elektriksel aktiviteyi ölçmek için kullanılmaktadır. Bu metot kapsamında, kısa süreli ancak etkisi yüksek olan manyetik alan oluşturulur ve beyinde gerçekleştirilen eylemler değiştirilmektedir. Müdahale gerektirmeyen bir yöntemdir. NIRS, uygulaması kolay, ucuz ve taşınabilir aletlere sahip olmasından dolayı tıp alanında ve çalışmalarda yaygın olarak kullanılmaktadır. Bu yöntemin uygulaması diğer yöntemlerden tamamen farklıdır. Beyinde yer alan kan oksijenlerinin değerlendirilmesine yöneliktir. Kafanın yüzeyinden gönderilen ve kızılötesi değeri 700-900nm arasında değişiklik gösteren ışıklar kullanılarak beyin aktiviteleri izlenmektedir [28]. Son olarak EEG, kafatası ve çevresine elektrotların yerleştirilmesiyle beyin işaretlerinin elde edilmesine yönelik geliştirilmiş olan bir tekniktir. Aynı zamanda çalışmalarda en çok EEG işaretleri kullanılmaktadır. Bu tez çalışmasında da uygulaması kolay, maliyeti düşük ve taşınabilir olduğu için EEG işaretlerinin kullanımı tercih edilmiştir.

2.2. Elektroensefalografi

Beyin işaretlerinin tarihçesi incelendiğinde, bu alanda gerçekleştirilen ilk çalışmanın 1887 yılında, Richard Caton tarafından yapıldığı görülmüştür. Caton, beyinde gerçekleşen elektriksel aktiviteleri ölçmek için, galvanometre kullanarak çeşitli hayvanlar üzerinde deneyler yapmıştır [29]. Aynı şekilde 1890 yılında, Adolf Beck, bazı hayvanlar üzerinde çeşitli uyaranlar kullanmış ve beyinde meydana gelen dalgalanmaların kaybolduğunu gözlemlemiştir.

1912 yılında, Pravdich-Neminsky'nin köpekler üzerinde gerçekleştirmiş olduğu çalışma sonunda beyinden işaretler elde edilmiştir [30]. Bu gelişmelerin ardından Birinci Dünya Savaşı sırasında yaralanan kişiler üzerinde elektrotlar denenmiş ve ilk EEG kaydı işaretleri elde edilmiştir [31].

EEG kafa derisine yerleştirilen elektrotlar aracılığıyla beyindeki elektriksel aktiviteyi ölçmek ve değerlendirmek amacıyla kullanılan ve müdahale gerektirmeyen yöntemdir. Hücrelerin birbiriyle etkileşim halinde olması, beyinde elektriksel etkinliğinin devamlı olmasına sebebiyet vermekte ve işaretin değişken olmasına (durağan olmayan) neden olmaktadır. Geçmişte EEG verilerinin toplanması, elde edilme işlemlerinin zor olması ve büyük makinelerle yapılması teknolojiyi bu yönde olumlu derecede etkilemiştir. Günümüzde artık EEG verileri taşınabilir cihazlarla Wi-Fi ve Bluetooth aracılığıyla elde edilebilmektedir. Şekil 2.3'de çalışmalarda en çok tercih edilen taşınabilir EEG cihazları verilmiştir. Bu durum EEG ile yapılan çalışmaların artmasına ve çok sayıda BBA uygulamalarının gelişmesine yol açmıştır. Sadece sağlık alanında değil, akademik çalışmalarda da kullanılmakta ve önemli derecede bilgiler sağlamaktadır. EEG ile duygu analizi ve tahmini [32], uyku bozuklukları ve düzeni [33], epilepsi [34], gürültülerin sınıflandırılması [35], elektrot kanal seçimi [36] gibi çalışmalar yapılmaktadır.



Şekil 2.3. a) Taşınabilir 14 kanallı EEG cihazı, b) Taşınabilir 5 kanallı EEG cihazı, c) Taşınabilir tek kanallı EEG cihazı [37, 38].


2.3. EEG İşaretleri

EEG işaretleri, frekans değerleri 0.5 Hz ve 30 Hz arasında değişiklik gösteren alt işaretlerden meydana gelmektedir. Bu işaretler sırasıyla delta, teta, alfa, beta ve gama olarak ifade edilirler. Tablo 2.1’de her bir işaretin frekans ve genlik bilgisi ile görüldüğü durum verilmiştir.

Tablo 2.1. İşaretlerin tekniksel ve davranışsal bilgisi

Dalga İsmi	Frekans Değeri	Genlik Değeri	Görülme Anı
Delta Dalgası (δ)	0.5 Hz – 3.5 Hz	20 μ V – 400 μ V	Derin uyku anı Anestezik hal
Teta Dalgası (θ)	4 Hz – 7 Hz	5 μ V – 100 μ V	Normal uyku Gerginlik hali
Alfa Dalgası (α)	8 Hz – 12 Hz	2 μ V – 10 μ V	Hafif hipnoz
Beta Dalgası (β)	13 Hz – 22 Hz	1 μ V – 5 μ V	Uyanıklık hali
Gama Dalgası (γ)	22 Hz – 30 Hz	2 μ V’den az	Aşırı aktif


Şekil 2.4’de orijinal EEG işareti ve bu işarete ait dalgalar gösterilmiştir.



Şekil 2.4. EEG işaretleri ve alt dalgaları

2.4. EEG Elektrot Sistemi

Beyin işaretlerine dayalı gerçekleştirilen çalışmalarda, EEG verileri kafa derisine yerleştirilen elektrotlar aracılığıyla elde edilmektedir. Elektrotlar, Uluslararası EEG Federasyon Birliği'nin tanımladığı 10-20 sistemine göre kafa yüzeyine yerleştirilmektedirler. Bu sistemde elektrotlar, burun, başın arka kısmı ve iki kulak olmak üzere kafanın dört ana bölgesine aralarında %10-20-20-20-20-10 cm mesafe olacak şekilde yerleştirilir. Şekil 2.5'de kullanılan sistemin görüntüsü yandan ve üstten olacak şekilde verilmiştir.



2.5. Duygu Kavramı ve Duygu Analizi


Dış etkenlere karşı gösterilen tepkiler duygu olarak ifade edilmektedir. Duygu, bilgi, algı, hafıza, davranış ve yaratıcılık mekanizmasını etkilediği için günlük hayatta önemli rol oynamaktadır. Duygu psikolojik olarak değil aynı zamanda fizyolojik olarak da toplumsal yaşamı etkilemektedir. Pozitif duygulara sahip kişiler negatif düşüncelerle yaşayan insanlara nazaran toplum içerisinde daha sağlıklı yaşamakta ve daha başarılı olmaktadır.

Duygu analizine yönelik ilk çalışma 1990'lı yıllarda, ses işaretleri ve yüz mimikleri kullanılarak gerçekleştirilmiştir [41, 42]. EEG işaretlerinin kullanılmadığı çalışmalarda duygu analizi bedensel etkileşimlerle ve hareketlerle (mimikler, ses işaretleri ve vücut dili) yapılmakta ve veriler daha kolay elde edilmektedir. Ses işaretleri mikrofon, mimik ve vücut dili kameralar yardımıyla toplanmaktadır. Ancak bu yöntemle elde edilen işaretler, sürekli manipüle edilebilir ve uğradıkları için sağlıklı olmamaktadır. Bu nedenden dolayı, araştırmacılar bedensel yolla edilen işaretler yerine, fizyolojik ölçümlere dayalı duygu analizi gerçekleştirmişlerdir. Fizyolojik sinyal olarak EKG, EMG, EEG ve GSR (Galvanik Deri Tepkisi) kullanılmakta ancak duygu analizinde en iyi sonucu EEG işaretleri verdiği için EEG ön plana çıkmaktadır [43]. Duyguların ayırımında ve sınıflandırılmasında en iyi sonucun düşük genlikli dalgaların (beta ve gama) verdiği gözlemlenmiştir [44, 45].

2.6. Duygu Modelleri

Duygu analizine yönelik gerçekleştirilen çalışmalarda iki çeşit model kullanılmaktadır. Birincisi ayırık duygulardan (pozitif-negatif duygular) oluşurken ikinci tür ise boyutsal (uyarılma-valans) modelidir. Ayırık duygu yapısında altı farklı ana duygu bulunmaktadır. Bu duygular, sinir, korku, hüzn, nefret, sürpriz ve mutluluktur [46]. Boyutsal model yapısında ise uyarılma – valans düzlemi ve duygu çemberi, duygu tahmini çalışmalarında en çok kullanılan yöntemlerdendir [47]. Uyarılma-valans koordinat düzleminde duygular dört ayrı düzleme ayrılmıştır. Düzlemin sol tarafı negatif duyguları, sağ tarafı ise pozitif duyguları temsil etmektedir. Alt tarafı düşük etkili duygulardan oluşurken, düzlemin üst tarafında ise yüksek etkili duygular bulunmaktadır.

Uyarılma, düzlemin ordinat ekseniniyle ifade edilmekte ve duygular bu eksen üzerinde düşük (sakin) durumdan yüksek (heyecan) durumuna göre sıralanmışlardır. Valans ise düzlemin apsis ekseninde bulunmakta ve bu eksen de duygular negatif-pozitif olacak şekilde yerleştirilmiştir. Şekil 2.6’da Russel’in tanımlamış olduđu valans-uyarılma düzlemi verilmiştir [48].




Şekil 2.6. Valans-uyarılma duygu düzlemi

Uyarılma, bireylerin herhangi bir uyarana karşı göstermiş olduđu fizyolojik durumu belirtir. Tepki aralığı düşük (pasif) ve yüksek (aktif) olacak şekilde değışiklik göstermektedir. Valans ise bir duruma, olaya karşı gösterilen ya da nesneye karşı verilen kötü veya iyi tepkileri ifade etmektedir.

Boyutsal modelde kullanılan diğer bir yöntem ise Plutchick'in 1980 yılında geliştirmiş olduğu duygu çemberidir [49]. Şekil 2.7'de görüldüğü üzere bu duygu modelinde, Plutchick sekiz temel ve gelişmiş duyguyu karşıt duygularıyla beraber toplam otuz iki tane olacak biçimde bir çember içine yerleştirmiştir. Plutchick'in geliştirmiş olduğu çember sisteminde;

- Duygular kendi içerisinde yoğunluk ve şiddet değerlerine göre sıralanmaktadır.
- Komşu olan duyguların birbirlerine benzerliği diğer duygulara nazaran daha fazladır.
- Duygular bir araya gelerek çember üzerinde farklı ve daha gelişmiş duyguları oluştururlar.
- Çember üzerinde birbirine karşıt olan duygular zıt duyguları ifade etmektedir.



Şekil 2.7. Duygu çemberi

Tablo 2.2’de temel ve ona karşıt duygular verilmiştir. Tablo 2.3’te ise gelişmiş ve bu duygulara karşıt duygular gösterilmiştir

Tablo 2.2. Temel ve karşıt duygular

Temel Duygu	Temel Karşıt Duygu
Neşe	Üzüntü
Güven	İğrenme
Öfke	Korku
Üzüntü	Neşe
Şaşırma	Beklenti
Korku	Öfke
İğrenme	Güven
Beklenti	Şaşırma

Tablo 2.3. Gelişmiş ve karşıt duygular

Gelişmiş Duygu	Hisler	Karşıt Gelişmiş Duygu
İyimserlik	Beklenti + Neşe	Hayal kırıklığı
Pişmanlık	Üzüntü + İğrenme	Sevgi
Huşu	Korku + Şaşırma	Agresiflik
Hor görme	Öfke + İğrenme	İtaat
Sevgi	Neşe + Güven	Pişmanlık
Hayal kırıklığı	Üzüntü + Şaşırma	İyimserlik
Agresiflik	Öfke + Beklenti	Huşu
İtaat	Güven + Korku	Hor görme

Ayrık duygu modeli belirli duyguları sınıflandırdığı için yapısal olarak uygulanması kolay bir modeldir ve zahmet gerektirmemektedir. Fakat ayrık duygu modeli evrensel olarak tanımlanamamaktadır. Bunun en büyük nedeni ise bazı dillerde telaffuz edilen duygu terimlerinin, bazı dillerde çevrilememesidir [50]. Bu durumun aynısı duygu çemberi içinde geçerli olduğundan çalışmalarda valans-uyarılma düzlemi tercih edilmektedir. Bu model yapısında duygular isimleriyle değil, koordinat düzlemindeki konumlarıyla ifade edilmektedirler. Örneğin heyecan ayrık duygusu heyecan şeklinde değil, YUPV (Yüksek Uyarılma Pozitif Valans) şeklinde belirtilmektedir. Aynı şekilde, rahat duygusu DUPV (Düşük Uyarılma Pozitif Valans) biçiminde tanımlanmaktadır. Bu durum bu yapının evrensel olmasına ve çalışmalarda tercih edilmesine sebebiyet vermektedir.

Duygu tahmini üzerine yapılan çalışmalarda duyguların açığa çıkarılması ve etkilenen duygunun analizinin yapılması için çeşitli uyaranlar kullanılmaktadır. Uyaranlar görsel, işitsel ve hem işitsel hem görsel olmak üzere üç çeşittir. Görsel uyaranlar fotoğraf veya resimlerden oluşmaktadır.

Kişilere belirli aralıklarla fotoğraf ya da resimler gösterilir ve deneklerden o an EEG işaretleri toplanarak, görsele karşılık gelen duygu verileri elde edilmektedir. Çalışmalarda görsel uyaran olarak en çok UDRS (Uluslararası Duygusal Resim Sistemi) veritabanındaki resimler kullanılmaktadır [51]. Veritabanı halka açık olmakla birlikte, ancak gerekli izinlerle ve kullanım koşullarıyla elde edilebilmektedir. İşitsel uyaran olarak ise müzikler ya da belirli sesler tercih edilmektedir. Deneklere belirli süre kapsamınca ses dosyaları dinletilerek duyguları uyarılmakta ve EEG verileri elde edilmektedir. İşitsel uyaran olarak ise UEDS (Uluslararası Etkili Dijital Ses) veritabanındaki sesler kullanılmakta ve akademik çalışmalar gerçekleştirilmektedir [52]. Aynı UDRS veritabanında olduğu gibi UEDS halka açık bir veritabanıdır ve kullanımı için gerekli izinlerin alınması gerekmektedir. Video klipleri, bilgisayar oyunları, kısa filmler vb. uyaranlar hem görsel hem işitsel uyaran olarak değerlendirilmektedir. Literatür incelendiğinde hem görsel hem işitsel uyaranların kullanılmasıyla gerçekleştirilen çalışmalarda en çok tercih edilen veritabanının DEAP veritabanı olduğu gözlemlenmiştir [44]. Diğer veritabanlarında olduğu gibi, bu veritabanının da kullanımı için gerekli izinlerin alınması şarttır. Bu tez çalışmasında, DEAP veritabanından yararlanılmış ve gerekli dokümanlar ile formlar imzalanarak veriler internet üzerinden elde edilmiştir.

2.7. Duygu Analizi Üzerine Yapılan Çalışmalar

Duygu analizi üzerine yapılan çalışmalar incelendiğinde, çok sayıda farklı örüntü tanıma metotlarının ve sınıflandırma algoritmalarının kullanıldığı gözlemlenmiştir. ADD (Ayrık Dalgacık Dönüşümü), AKA (Ampirik Kip Ayrışımı), HFD (Hızlı Fourier Dönüşümü), DPD (Dalgacık Paket Dönüşümü) tekniklerinin işaretin alt frekansa ayrıştırılmasında en çok tercih edilen yöntem oldukları belirlenmiştir. Özellik çıkarım aşamasında ise bilgi ölçüm yöntemlerinin ve istatistiksel sonuçların ön planda olduğu anlaşılmıştır. Sınıflandırma aşamasında ise başvuru sınıflandırma algoritmalarının başında YSA, KNN ve DVM algoritmalarının geldiği fark edilmiştir. Bu kısımda yapılan çok sayıda çalışmadan bazılarını yer verilmiş ve kullanılan yöntemlere değinilmiştir. Çalışmaların başarımları sonuçları belirlenmiş ve tezin bulgular ve tartışma kısmında bu başarımların karşılaştırılması yapılmıştır.

Kaynak [53]'te belirtilen çalışmada duygu analizi işlemi için tek elektrotlu cihaz kullanılarak veriler elde edilmiştir. Valans-uyarılma düzleminden ziyade ayrık duygular üzerinde gerçekleştirilen çalışmada korku, hüznün ve komedi duygularının ayrımı yapılmıştır. Derin öğrenmenin kullanıldığı yöntemde sınıflandırma ve özellik çıkarım işlemi için RO (Rastgele Orman) ve YSA sınıflandırıcısına başvurulmuştur. %87,89 oranında başarımlar elde edilmiştir.

KFDA (Kernel Fisher Diskriminant Analizi) [54] kullanılarak gerçekleştirilen duygu analizi çalışmasında UDRS veritabanından elde edilen görselleri kullanılmış ve on denek üzerinden çalışma gerçekleştirilmiştir. Farklı farklı özelliklerin sınıflandırılarak kıyaslanması yapılan çalışmada sınıflandırıcı olarak KNN sınıflandırıcısı kullanılmıştır. Valans-uyarılma düzleminin ayrımı yapılmış ve valans için yaklaşık olarak %78 oranında, uyarılma için ise yaklaşık %82 oranında performans elde edilmiştir.

UDRS veritabanından elde edilen görsel uyaranlar aracılığıyla, çekirdek yoğunluğu tahmini ve YSA sınıflandırıcısı ile duygu analizi işlemi gerçekleştirmişlerdir. Çalışmanın sonunda elde edilen başarımlar literatürde bulunan diğer çalışmalarla kıyaslanmış ve daha etkili sonuç elde edilmiştir [55].

[56] numaralı kaynaktan gösterilen çalışmada duygu analizi yapılmış ve beyindeki hangi bölge ya da bölgelerin hangi duyguları daha yoğun yansıttığını gösterilmiştir. İşitsel uyaran kullanılarak sekiz kişi üzerinden EEG verileri toplanmış ve özellikler elde edilmiştir. Özelliklerin elde edilmesiyle dört farklı sınıflandırıcıya başvurulmuş ve sınıflandırma işlemi gerçekleştirilmiştir. DVM, KDA (Karesel Diskriminant Analizi), DDA (Doğrusal Diskriminant Analizi) ve KNN ile yapılan ayırım işleminde, en iyi sonuç pozitif duygular için %84,5 ve negatif duygular için %82,5 oranında DVM sınıflandırıcısı ile elde edilmiştir. Pozitif duygular için, ön, şakak ve yan bölgenin etkili olduğu ve negatif duygular için ise ön ve yan bölgenin aktif olduğu sonucuna varılmıştır.

İki farklı EEG kanal çiftine ait duyguların sınıflandırılmasına ait çalışma [57] numaralı kaynaktan verilmiştir. Bu çalışmada duygu olarak ayrık duygular kullanılmış ve neşe ile hüznün duyguları analiz edilmiştir. Özellik çıkarım için faz gecikme indeksine başvurularak özellik vektörü elde edilmiştir. Özellik uzayı DVM ile analiz edilmiş, hüznün ve neşe duygularının ayrımı yapılmıştır. Sonuç olarak C3-F3 EEG çiftinin duygu ayırımında başarımlar oranı %68 olacak şekilde elde edilmiştir.

Görsel/işitsel uyaranların kullanılmasıyla gerçekleştirilen çalışmada [58], veriler üç ve sekiz elektrot aracılığıyla analiz edilmiş ve duygu tahmini çalışması gerçekleştirilmiştir. Higuchi Fraktal boyutu kullanılmış ve özellikler elde edilmiştir. Sınıflandırma işlemi için ise DVM sınıflandırma algoritması kullanılmıştır. Uyarılma-valans düzlemi üzerinde yapılan çalışmanın sonucunda, 3 elektrotlu sistemin ortalama başarımlı oranı %51,94 bulunurken, sekiz elektrotlu sistemin ortalama performans değeri ise %77,38 olacak şekilde gözlemlenmiştir.

[59] numaralı kaynakta belirtilen çalışmada, DEAP verisetine ait EEG sinyalleri kullanılmış ve dalgacık dönüşümünden yararlanılmıştır. Dalgacıkların bağıl enerjileri elde edilerek özellik uzayı oluşturulmuş ve yapay sinir ağları kullanılarak sınıflandırma gerçekleştirilmiştir. Çalışmanın sonunda, denek sayısının artmasının sınıflandırma başarısını doğru yönde etkilediği gözlemlenmiştir.

Ayrık duygu modelinin kullanılmasıyla gerçekleştirilen [60] numaralı kaynaktaki çalışmada, görsel-işitsel uyaranlar kullanılmıştır. Uyaranlar aracılığıyla sakin, mutlu, sinirli ve üzgün olmak üzere 4 farklı ayrık duygu elde edilmiştir. HFD kullanılarak özellikler elde edilmiş ve YSA ile sınıflandırma işlemi gerçekleştirilmiştir. Ortalama başarımlı oran %75 olacak şekilde elde edilmiştir.

Entropiler aracılığıyla gerçekleştirilen duygu analizi çalışmasında [61], DEAP veriseti kullanılmış ve duygular uyarılma-valans düzlemine analiz edilmiştir. Önerilen metod sonunda İKE (İşletim Karakteristiği Eğrisi) ve İKEA (İşletim Karakteristiği Eğrisi Alanı) eğrileri hesaplanmış ve entropi değerlerinin duygu analizinde önemli bilgiler verdiği gözlemlenmiştir.

AKA ve ADD kullanılarak gerçekleştirilen [47] numaralı kaynaktaki duygu analizi üzerine yapılan çalışmada, önce özellik uzayı elde edilmiş ve ardından özelliklerin boyutu azaltılarak duyguların sınıflandırılması gerçekleştirilmiştir. DVM aracılığıyla yürütülen sınıflandırma işleminin sonucu diğer çalışmalarla kıyaslayarak çalışmanın başarısı değerlendirilmiştir. Çalışmada, uyarılma/valans ve baskınlık/beğeni için ortalama %67 oranında sonuç gözlemlenmiştir.

Kaynak [62]'de gösterilen çalışmada, dört (hüzün, sinir, mutluluk ve normal) ayrık duygunun tahmin işlemi gerçekleştirilmiştir. Özellik çıkarım aşamasında iki farklı dalgacık dönüşümü kullanılmış ve ardından Hjorth Özellikleri elde edilmiştir. Çalışmada hangi dalgacık katsayısının hangi duygu üzerinde baskın olduğu belirlenmeye çalışılmıştır. Elde edilen veriler kullanılmış ve ileride yapay sinir ağları ile sınıflandırma işleminin gerçekleştirilmesi amaçlanmıştır.

AKA yöntemi ile dalgaların ayrıştırıldığı [63] numaralı çalışmada, DEAP verileri kullanılmış ve her dalgacıktan özellikler elde edilmiştir. Elde edilen özellikler DVM ile sınıflandırılmış ve boyutsal modelin ayırım işlemi gerçekleştirilmiştir. Çalışmada EEG kanalları azaltılmış ve bu amaçla kanalların sınıflandırılmaya etkisi gözlemlenmiştir. Çalışmanın sonucunda valans için %69 ve uyarılma için %72 oranında sınıflandırma başarısı elde edilmiştir.

Kaynak [64]'teki çalışmada DVM sınıflandırıcısı ile sınıflandırma işlemi gerçekleştirilmiş ve duyguların ayırımı yapılmıştır. Hazır bir veritabanı kullanılmadığı için veriler önce ön işleme tabi tutulmuş ve gürültülerden arındırılmıştır. Ayrık model kullanılarak gerçekleştirilen uygulamada deneklerin duygularını yansıtan bir arayüz tasarlanmıştır.


[65] numaralı kaynakta gösterilen çalışmada 21 denek üzerinden elde edilen EEG verileri ile duygu tahmini işlemi yapılmıştır. Sürü zekâsına dayalı algoritmaların kullanıldığı çalışmada özellikler DVM ile sınıflandırılmış ve çalışma sonlandırılmıştır. Görsel uyaranlar kullanılarak duygular uyarılmış ve 14 kanallı EEG cihazı ile veriler elde edilmiştir. Çalışmanın sonunda GA (Genetik Arama) algoritmasının PSO (Parçacık Sürü Optimizasyonu) oranla daha iyi sonuç verdiği gözlemlenmiştir.

Tek EEG kanalının kullanılmasıyla gerçekleştirilen [66] numaralı kaynaktaki çalışmada, ayrık duyguların sınıflandırılması amaçlanmıştır. Mutluluk, hüzün ve normal duygular farklı dalgacık dönüşümlerine uğramış ve dalgacıklar elde edilmiştir. Dalgacıkların elde edilmesiyle istatistiksel yöntemler ile özellik vektörü oluşturulmuştur. Üç farklı sınıflandırıcıyla yapılan sınıflandırma işlemi sonucunda başarımlar karşılaştırılmıştır. Kullanılan sınıflandırıcılar KNN, RO ve KDA sınıflandırıcılarıdır. Sonuç olarak bazı duyguların ayırımında KNN ve bazılarının ayırımında ise RO yönteminin etkili olduğu gözlemlenmiştir.

2.8. Beyin Bilgisayar Arayüzü

Vücudumuzdaki çeşitli fonksiyonlardan sorumlu olan beynin, her bir kısmı belirli bir görevi yerine getirmekle yükümlüdür. Oksitipital lob görmeden sorumluyken parietal lob duyma işleminden sorumludur. Motor sinirleri ise kol ve bacak hareketlerini yerine getirmesini sağlamaktadır. Vücudun hemen hemen her işleyişinden beyin sorumlu olduğu için zarar görmesi halinde ciddi sıkıntılar doğmakta hatta çoğu zaman felce neden olabilmektedir. Bu durumda insanlar günlük ihtiyaç ve eylemlerini yerine getirememekte ve bilgisayar tabanlı bir sisteme ihtiyaç duyulmaktadır.

BBA, insan beyni ile makine arasında direkt olarak iletişim kurulmasını sağlayan sistem ya da cihaza denmektedir. Daha çok sağlık alanında karşımıza çıkan BBA, felçli haldeki insanların mental durumunu komutlara dönüştürerek çevresini kontrol etmesini ve çevresiyle etkileşim kurmasını sağlamaktadır [67]. Ancak teknolojinin gelişmesi, BBA sisteminin sadece sağlık alanında değil, eğlence, e-öğrenme, sanal gerçeklik vb. birbirinden farklı alanlarda kullanılmasına öncülük etmiştir. Geliştirilmiş olan sanal gerçeklik ve bilgisayar oyununda, denekler hareket dahi etmeden sadece düşünce gücüne yönelik cadde üzerinde gezinti işlemini gerçekleştirmişlerdir. Yukarı yöne gitmek için yukarı düşüncesi, aşağı yöne gitmek için aşağı düşüncesi ve buna benzer beyin etkinlikleri ile oyun içerisinde hareket işlemini sağlamışlardır [68, 69]. Aynı şekilde, BBA aracılığıyla tekerlekli sandalye, araç ve robotların kontrol mekanizması geliştirilmiştir [70]. BBA sistemi, beyin etkinliklerinin elde edilmesi, önışlem, özellik çıkarım, sınıflandırma, komut sistemi ve geri besleme olmak üzere altı farklı adımdan meydana gelmektedir. Şekil 2.8’de adımlar gösterilmiştir [71].



Şekil 2.8. BBA akış diyagramı

EEG tabanlı olarak geliştirilen ilk BBA sistemi 1988 yılında Farwell ve Donchin tarafından yapılmıştır [72]. Yapılan uygulamada, denekler yazı ve sembollerden oluşan 6x6 boyutunda matrise bakarak belirli aralıklarla simge ya da yazı seçmektedirler. Geliştirilen BBA sistemi, seçilen verileri inceleyip analiz ettikten sonra eğitilmiş ve ardından kişiler seçmeden önce tahmin işlemi gerçekleştirmiştir. Arkasından BBA uygulamaları beyindeki sensör motor sistemi ile birleştirilmiş ve beyin işaretleri aracılığıyla kişiler nesneleri hareket ettirmeyi başarmışlardır [73, 74].

BBA ve EEG teknolojisinin gelişmesi iki türü de olumlu yönde etkilemiş ve çalışmalar hız kazanmıştır. Buna paralel olarak taşınabilir EEG cihazları geliştirilmiştir. BBA sistemi ile EEG işaretlerine dayalı duygu analizi çalışmaları da bu gelişimden etkilenmiş ve çok sayıda duygu tahminine yönelik araştırmalar yapılmaya başlanmıştır [75-77].

2.9. Örüntü Tanıma

Bilginin karmaşık örüntülerinin kullanılarak karar verilmesi işlemine örüntü tanıma denmektedir. Bilgi uzayında, örnekler ve onların çıktılarının işlenerek, yeni örneklerle göre çıkarım yapma işlemi olarak ifade edilmektedir [78]. Endüstri, otomotiv, tıp, finans, sağlık vb. olmak üzere çeşitli alanlarda başvurulmuş bir yöntemdir. Buna paralel olarak el yazısı ayırt etme [79], iris tanıma [80], bitki örtüsü sınıflandırma [81], araç ve plaka tanıma [82], epilepsi tahmini [83] gibi çok sayıda farklı konularda çalışma bulunmaktadır.

Örüntü tanıma işlemi, Şekil 2.9'da görüldüğü üzere 4 farklı adımdan oluşmaktadır. Bu adımlar sırasıyla, verilerin elde edilmesi, önilem, özellik çıkarım ve sınıflandırma adımlarıdır.

Verilerin elde edilmesi: Özelliklerin elde edilmesi için gerekli olan ham maddedir. Veriler cinsine göre farklı yollarla elde edilmektedir. Eğer veri işaret içerikli ise EEG, EMG, EKG vb. yöntemlerle, görüntü içeriyorsa ise fotoğraf makinesi, kamera gibi cihazlar kullanılarak toplanmaktadır.

Önilem: Ham verilerin belirli bir işlem uygulanmasıyla, özellik çıkarım için hazır hale getirilmesidir. Bu aşamada veriler çeşitli dönüşüm veya gösterim yöntemleriyle tasarlanmaktadır. Çoğu EEG'ye dayalı çalışmalarda veriler elde edilirken bu işaretlere gürültüler karışmakta ve gürültülerle beraber özelliklerin elde edilmesi başarımı olumsuz yönde etkilemektedir. Bu nedenden dolayı veriler bant geçiren filtreden süzülerek önilem sürecine tabi tutulurlar.

Özellik çıkarım: Verilerin boyutunun azaltıldığı ve anahtar özelliklerin elde edilerek sınıflandırma öncesinde özellik vektörü ya da uzayının belirlendiği kısımdır. Sistemin ve sınıflandırmanın başarısında en etkili olan kısımdır. Gereksiz özelliklerin fazla olması sistem performansını ve başarısını olumsuz yönde etkilediğinden, anahtar özelliklerin çıkarılması ve özelliklerin indirgenmesi çok önemlidir.

Sınıflandırma: Bu aşamada elde edilen özelliklerin ait olduğu küme belirlenmektedir. Aynı zamanda karar aşamasıdır.



Şekil 2.9. Örüntü tanıma adımları

Yapısal, istatistiksel ve akıllı olmak üzere üç tür örüntü tanıma sistemi mevcuttur. Yapısal örüntü tanıma sisteminde elde edilen özellikler, özelliklerin şeklinden meydana gelmektedir. Sayısal değerlerden ziyade, örüntünün geometrik şekli ayırt edici durumdadır. Örnek olarak, bir fotoğraf karesinin kenar sayısı veya köşe sayısı gösterilebilir. Yapısal örüntü tanıma sisteminde, zincir kod, poligonal yaklaşım ve otoregresif model kullanılmaktadır [84].

İstatistiksel örüntü tanıma sürecinde ise özelliklerin ayırt edilmesi istatistiksel değerlere bağlı olmaktadır. Aynı kümede sıralanan veriler, istatistiksel açıdan benzer değerler sergilemektedirler. Sınıflandırıcı bu sistemde özellik olarak sayı birimlerini ve ölçüm değerlerini kabul etmektedir. İstatistiksel örüntü tanımada kullanılan sınıflandırıcıya NB (Naive Bayes) örnek gösterilebilir.

Son olarak akıllı örüntü tanıma sistemi bulunmaktadır. Bu sistemde kendi kendine öğrenme mevcuttur. Sistem önceki verileri işleyip öğrendikten sonra karar verirken geçmiş tecrübelerinden faydalanmaktadır. Bu sistemde eğitim ve test aşamaları bulunmaktadır. Eğitim aşamasında sistem eldeki veriler kullanılarak eğitilir ve daha sonra yeni bilgiler verilerek sistemin bu verileri işlemesi beklenir. YSA kullanılarak sınıflandırma işlemi gerçekleştirilmektedir.

3. GELİŞTİRİLEN DUYGU ANALİZİ YÖNTEMİ


3.1. Kullanılan Veritabanı ve Elde Edilme Yöntemi

Bu tez çalışmasında, çoğu çalışmada da olduğu gibi DEAP verisetine ait veriler kullanılarak duygu analizi işlemi gerçekleştirilmiştir. EEG'ye ait verilerin elde edilme aşamasında sorumlu araştırmacılarla iletişime geçilerek kullanım koşullarına ve son kullanıcıya ait formlar imzalanmış ve verilere internet üzerinden erişilmiştir. Bu verisetinde sadece EEG işaretleri değil aynı zamanda diğer fizyolojik (Fotopletismografi, Elektromiyografi ve Galvanik Deri) işaretler de bulunmaktadır.

Verilerin elde edilme aşamasında görsel-işitsel uyaranlar kullanılmıştır. Her biri 1 dakika olan 120 adet videodan oluşan uyaranlardan, çalışma kapsamında sadece 40 tanesine başvurulmuştur. 32 denekten oluşan çalışmada, kişiler 40 müzik klibini belirli aralıklarla kulaklık aracılığıyla dinlemiş ve izlemişlerdir. Bu aşamada verilerin edinimi gerçekleşmiştir. Gerçekleştirilen deneysel prosedür her bir aşaması 2 dakika olacak şekilde tasarlanmış ve aşamaları şu şekilde belirtilmiştir [44];

- 40 adet video olduğundan deneysel prosedür 40 ayrı sınamadan oluşmaktadır.
- Her sınamada 2 saniye boyunca ekrana sınamanın numarası belirtilerek, deneklerin kaçınıcı sınamada oldukları gösterilmiştir.
- Ardından ekrana 5 saniye boyunca kalacak şekilde artı simgesi gösterilmiş ve deneklerin hazır olmaları sağlanmıştır.
- Son olarak 1 dakika boyunca ise uyaranlar dinletilip gösterilerek verilerin elde edilmesi sağlanmıştır.
- Her sınamanın ardından denekler öz değerlendirme formu doldurmuş ve sınama işlemi sonlandırılmıştır.

Yukarıda belirtilen adımlar toplam 40 kere her denek için gerçekleştirilmiştir. Şekil 3.1'de deneysel sürecin adımları verilmiştir.




Şekil 3.1. Deneysel sürecin adımları

EEG verileri 10-20 elektrot sistemine göre yerleştirilmiş 32 elektrottan elde edilmiştir. Bu elektrotların yerleştirildiği bölgeler Tablo 3.1 ve Şekil 3.2’de gösterilmiştir. EEG verileri önce frekans değerleri 512 Hz olacak şekilde elde edilmiş ve önışlem aşamasında gürültülerin temizlenmesiyle 128 Hz frekans değerine kadar düşürülmüştür. Tez çalışması kapsamında önışlemden geçirilmiş EEG verileri kullanılmıştır.


Tablo 3.1. Elektrotların yerleştirildiği bölgeler

Fp1	Fp2	CP1	CP2
AF3	AF4	CP5	CP6
F7	F8	P7	P8
F3	F4	P3	P4
FC1	FC2	Fz	Pz
FC5	FC6	PO3	PO4
T7	T8	O1	O2
C3	C4	Oz	Cz



Şekil 3.2. Elektrotların yerleştirildiği bölgeler

ÖDF (Öz Değerlendirme Formu), elde edilen EEG verilerinin doğruluğunu kontrol etmek amaçlı yapılan bir uygulamadır. Denekler sınamalar bittikten sonra, uyaranların kendilerine hissettirdiği duyguları derecelendirmektedirler. Bu sayede o an elde edilen EEG verilerinin hangi hisse karşılık geldiği tespit edilmekte ve test işlemi yapılmaktadır. Öz değerlendirme formunda uyarılma, valans, beğeni ve baskınlık parametreleri bulunmaktadır. Her parametrede 1-9'a kadar olacak şekilde dereceler bulunmaktadır. Şekil 3.3'te öz değerlendirme formu örneği gösterilmiştir.



Şekil 3.3. Öz değerlendirme formu örneği

Valans değişkeni, deneklerin uyarana karşısında hissetmiş oldukları durumu temsil etmektedir. Parametre değeri mutsuzluktan mutluluğa doğru tanımlanmaktadır. Değerin 5'ten düşük olması mutsuzluk halini ifade ederken 5'ten büyük olması mutluluk hissiyatı vermektedir. Değerin 5 olması ise nötr hali gösterir.

Uyarılma ise uyarana karşı gösterilen tepki olarak tanımlanabilir. Yüksek ve düşük olmak üzere iki durumu vardır. Yüksek uyarılma değeri olarak 5'in üstünde olduğunda görülür ve heyecanlı olma halidir. Değerin 5'in altında olması düşük uyarılmayı ifade eder ve karşılık gelen duygu ise sakinliktir. Değerin 5 olması ise nötr hali temsil etmektedir.


Baskınlık, hissedilen duyguya karşı gösterilen baskınlık ya da itaatlik durumdur. Önceki parametrelerde olduğu gibi, baskınlık parametresi de 1-9 arasında değer almaktadır. Değerin 1 olması kişinin hissedilen duyguya karşı baskın olmamasını (itaatkâr olması) gösterirken, değer 9 olması ise hissedilen duruma karşı baskınlığı belirtmektedir.

Beğeni ise gösterilen uyarının denekler tarafından beğenilmesiyle alakalıdır. Eğer denekler uyarıyı beğenmiş ise, başparmak yukarı olacak şekilde belirtilen ifadeyi seçmektedirler. Beğenilmemiş ise başparmağın işareti aşağı yönde olan şekil seçilmektedir. Kişide belirli bir beğeni yaratmamışsa ortadaki ifade işaretlenmektedir.

Bölümün geri kalan kısmında tez çalışması kapsamında özellik çıkarım için kullanılan dalgacık dönüşümünden, bilgi ölçüm yöntemlerinden ve istatistiksel metotlardan bahsedilmiştir. Ayrıca özellik vektörünün elde edilmesiyle başvuru sınıfı sınıflandırıcılar incelenmiştir.

3.2. Özellik Çıkarım Süresince Kullanılan Yöntemler

Tez çalışması sürecinde, EEG verilerinden özelliklerin elde edilmesi için dalgacık dönüşümüne, bilgi ölçüm yöntemlerine ve istatistiksel metotlara başvurulmuştur. Ham EEG verileri özellik vektörü elde edilmeden önce normalize işleminden geçirilmiş ve bu sayede tüm veriler [0-1] aralığında ölçeklenmiştir. Ardından normalizasyon işleminden geçirilmiş olan verilere, [45, 53, 54] referanslarında belirtilen EEG işaretinin duyguyla ilgili beta ve gama alt işaret bileşenlerinin elde edilebilmesi için 4. seviye dalgacık dönüşümü uygulanmış ve alt işaret bileşenleri elde edilmiştir. Özellik çıkarım işleminin son aşamasında ise tüm alt dalgacıklara bilgi ölçüm ve istatistiksel yöntemler uygulanarak özellik vektörü oluşturulmuştur. Çalışmada kullanılan yöntemler sırasıyla, EADA (Eğimden Arındırılmış Dalgalanma Analizi), Hjorth tanımlayıcılar, katsayıların ortalama enerjisi, logaritmik enerji entropi, çok-ölçekli entropi, örnek entropi, Shannon entropi, standart sapma, varyans, sıfır geçişleridir. Oluşturulan özellik vektörü, DVM, KNN ve YSA sınıflandırıcılarıyla sınıflandırılmak üzere kullanılmıştır. Şekil 3.4'te özellik çıkarım aşamasının adımları gösterilmiştir.



Şekil 3.4. Önerilen yöntemin akış şeması

3.2.1. Dalgacık Dönüşümü

Biyomedikal işaretlere dayalı gerçekleştirilen çalışmalarda, frekans bölgesinin zaman bölgesine oranla daha çok bilgi içerdiği gözlemlenmiştir [59]. Beyin işaretleri, kalp işaretleri ve kas hareketlerine dayalı işaretler elde edilirken zaman bölgesine ait verilerin toplanması, bilgilerin eksik işlenmesine neden olmakta ve sınıflandırma başarısını olumsuz yönde etkilemektedir. Frekans bölgesi verilerinin elde edilmesinde kullanılan yöntemlerden birisi olan Fourier dönüşümü, daha çok durağan işaretler üzerinde başarı sağlamaktadır [85]. Ancak durağan olmayan işaretler üzerinde yeterli başarı sağlayamaması, dalgacık dönüşümünün kullanılmasına yol açmıştır.


Dalgacık dönüşümü, çok-aşamalı ayrıştırma kullanarak, herhangi bir işareti alt işaretlerine dönüştürmektedir. Dönüştürülmesindeki asıl amaç, işaretin dalgacık katsayılarına ayrıştırılması ve bu katsayıların bir araya gelerek işaretin doğrusal kombinasyonunu vermesidir [86].

Dalgacık dönüşümünün, frekans-zaman bölgesi hakkında detaylı bilgi vermesi, çok-oranlı filtrelemeye sahip olması, ölçek-uzayını iyi analiz etmesi, EEG, EMG, EKG gibi durağan olmayan işaretler üzerinde başarılı olmasını sağlamaktadır. Dalgacık dönüşümü işareti, yaklaşık ve detaylı olmak üzere iki farklı katsayıya dönüştürerek, işareti farklı frekans ve çözünürlükte analiz etmektedir [87]. Biyomedikal işaretlerin çoğunda önemli bilgiler düşük frekanstan elde edilmektedir [88]. Sinyalin düşük frekansı yaklaşık katsayısını, yüksek frekans ise detaylı katsayısını vermektedir. Katsayılar, yüksek geçiren filtre ve düşük geçiren filtre aracılığıyla Denklem 3.1 ve Denklem 3.2’de gösterilen denklemlere göre elde edilmektedir.

$$YGF(S) = D_{1j} = \sum_t S(t)k(2j - t) \quad (3.1)$$

$$DGF(S) = A_{1j} = \sum_t S(t)h(2j - t) \quad (3.2)$$

İlk filtre olan YGF (Yüksek Geçiren Filtre) işaretin detaylı katsayısını (D_1) verirken, DGF (Düşük Geçiren Filtre) ise işaretin yaklaşık (A_1) katsayısını oluşturmaktadır. Katsayıların oluşmasından sonra yaklaşık katsayısı tekrar filtreleme işlemine maruz kalarak seviye seviye hedeflenen işarete ulaşana kadar ayrıştırılmaktadır. İşaretin 4 seviye ayrıştırılmasını gösteren işlemin adımları Şekil 3.5’te verildiği gibidir.



Şekil 3.5. 4 seviyeli dalgacık dönüşümü

Detaylı ve yaklaşık dalgacıkların enerjileri Denklem 3.3 ve Denklem 3.4’de verilen formül yardımıyla hesaplanmaktadır [86].

$$ED_i = \sum_{j=1}^N |D_{ij}|^2 \quad i = 1, 2, \dots, l \quad (3.3)$$

$$EA_i = \sum_{j=1}^N |A_{ij}|^2 \quad i = 1, 2, \dots, l \quad (3.4)$$

Formüle göre, N değeri her bir seviyedeki toplam detay veya yaklaşık katsayıları vermektedir. l değeri ise ayrıştırma seviyesini ifade etmektedir. Denklemden de anlaşılacağı üzere ED_i i. seviyedeki detay katsayıların enerjilerini hesaplarken, EA_i i. seviyedeki yaklaşık katsayıların enerjilerini ölçmektedir.

Tez çalışmasında, denemeler sonucunda en iyi sonucu veren 2. dereceden Daubechies filtresi (‘db2’) kullanılmış ve 4. seviyeye kadar ana işaret alt bileşenlerine ayrıştırılmıştır. Seviye 4 kullanılmasının nedeni literatürdeki çalışmalarla karşılaştırmak [59,89] ve duygu tahmininde en iyi sonuç veren frekanslar beta, gama ve yüksek gama olduğu için o frekans aralığında çalışmaktır [45, 53, 54]. Tablo 3.2’de ayrıştırılan işaretin katsayıları ve onlara karşılık gelen frekans değerleri verilmiştir. Karşılık gelen değerler literatürdeki frekans değerleri ile örtüşmektedir [90].

Tablo 3.2. Dalgacık katsayılarına karşılık gelen frekans değerleri

Dalgacık Katsayısı	Frekans Aralığı	Frekans İsmi
D1	64 Hz – 128 Hz	Yüksek Gama
D2	32 Hz – 64 Hz	Gama
D3	16 Hz – 32 Hz	Beta
D4	8 Hz – 16 Hz	Alfa
A4	4 Hz – 8 Hz	Teta

Katsayıların elde edilmesinden sonra her bir değerden bilgi ölçüm ve istatistiksel yöntemler kullanılarak özellikler elde edilmiştir.

3.2.2. Eğimden Arındırılmış Dalgalanma Analizi

EADA, karmaşık sistemlerdeki ölçeğe bağlı özellikleri ölçmek ve bulmak için kullanılan bir çeşit veri analizi yöntemidir ve durağan olmayan sinyaller üzerinde uygulanmaktadır [91]. İlk olarak sağlık alanında DNA nükleotidlerinin birbirleriyle olan ilişkilerini tanımlamak için kullanılmıştır. Ardından kalp sinyalleri gibi durağan olmayan sinyaller üzerinde de tercih edilmeye başlanmıştır [92, 93]. Biyomedikal alanında başarılı sonuçlar üretmesi bu tez çalışmasında kullanılmasına neden olmuştur [94].

Eğimden arındırılmış dalgalanma analizinin hesaplanma adımları aşağıda verilmiştir [95];

1. Bu adımda zaman serisindeki her bir değerden, o zaman serisinin ortalama değeri çıkartılarak, değerler yeni bir zaman serisine aktarılmaktadır. Denklem 3.5'te gösterilen denklem ile hesaplama işlemi yapılmaktadır.

$$yk = \sum_{i=1}^k (xi - x_{ort}) \quad (3.5)$$

{ $x_1, x_2, x_3, \dots, x_n$ } şeklinde verilen zaman serisinden, ortalaması çıkartılarak y zaman serisi oluşturulmaktadır.

2. Birleştirilmiş zaman serisi, uzunluğu n olan eşit kutulara bölünür ve her kutudaki veriye en küçük kareler kullanılarak bir doğru uydurulur ($y_n(k)$). Doğrunun uydurulmasıyla seri eğimden arındırılır ve zaman serisinin karekök ortalama dalgalanması Denklem 3.6'da verildiği gibi hesaplanır.

$$F(n) = \sqrt{\left(\frac{1}{N}\right) \sum_{k=1}^N [y(k) - y_n(k)]} \quad (3.6)$$

$y(k) - y_n(k)$, serinin eğimden arındırılmış değerini vermektedir.

3. Bu adımda $\log F(n)$, $\log(n)$ eğimi ile α değeri bulunmaktadır. Denklem 3.7'de verilen formülde, eğimden arındırılmış seri ile aralık uzunluğu arasındaki ilişki gösterilmiştir.

$$F(n) = \alpha n^\alpha \quad (3.7)$$

α değeri (ölçekleme üsteli, otokorelasyon üsteli) serinin otokorelasyon özelliğini vermektedir. Eğer ölçekleme üsteli (α) değeri 0.5 değerinden küçükse anti-korelasyonlu, büyük ise pozitif otokorelasyonludur. Değerin 0.5 olması beyaz gürültüyü ifade eder [96].

3.2.3. Hjorth Tanımlayıcılar

Hjorth tanımlayıcılar, B. Hjorth tarafından 1970 yılında tanıtılan ve sinyal işleme alanında sinyalin zaman-bölgesine ait istatistiksel sonuçların bulunmasına dayanan bir yöntemdir [97]. Etkinlik, hareketlilik ve karmaşıklık olmak üzere üç farklı parametresi bulunmaktadır. Etkinlik (Activity – A) parametresi, zaman bölgesinin varyans değerini bularak, frekans bölgesine ait güç spektrumunun yüzeyini belirtir. Eğer sinyalin yüksek frekans bileşenleri çok sayıda ise etkinlik değeri büyük olarak, az sayıda ise bu değer küçük olarak elde edilmektedir [98]. Hareketlilik (Mobility – M), sinyalin birinci derecen türevinin varyans değerinin, sinyalin varyans değerine oranının kareköküdür. Güç spektrumun standart sapmasını vererek, sinyalin enerjisini temsil eder. Karmaşıklık (Complexity – C) parametresi ise, sinyalin saf sinüs dalgası ile benzerliğini hesaplamak için kullanılmaktadır. Karmaşıklık değeri 1 değerine yaklaştıkça, sinyal o kadar saf sinüs dalgasına benzemektedir ve sinyallerin hareketlilik değerlerinin oranı ile hesaplanmaktadır. Etkinlik, hareketlilik ve karmaşıklık parametrelerinin hesaplanma adımları aşağıda verilmiştir.

$$A = \text{var}(x(t)) \quad (3.8)$$

$x(t)$ sinyali temsil etmekte ve var ise sinyalin varyans değerini bulmaktadır.

$$M = \sqrt{\frac{A\left(\frac{dx(t)}{dt}\right)}{A(x(t))}} \quad (3.9)$$

$dx(t)/dt$ sinyalinin birinci dereceden türevini ifade etmektedir.

$$C = \frac{M\left(\frac{dx(t)}{dt}\right)}{M(x(t))} \quad (3.10)$$

3.2.4. Dalgacık Katsayı İşaretlerinin Ortalama Enerjisi

Dalgacık dönüşümüyle elde edilen her bir seviyedeki detay ve yaklaşık katsayı işaretlerinin ortalama enerjileridir. Denklem 3.11 ve Denklem 3.12'deki gibi hesaplanmaktadır.

$$OrtD_i = (ED_1 + ED_2 + ED_3 + \dots + ED_i)/i \quad (3.11)$$

$$OrtA_i = (EA_1 + EA_2 + EA_3 + \dots + EA_i)/i \quad (3.12)$$

$OrtD_i$ değeri tüm seviyelerdeki detay katsayı işaretlerinin, $OrtA_i$ ise tüm seviyelerdeki yaklaşık katsayı işaretlerinin ortalamasını bulmaktadır. E enerjileri temsil ederken, i ise seviyeyi belirtmektedir. Detay ve yaklaşık katsayı işaretlerinin enerjilerinin hesaplanması 3.3 ve 3.4 numaralı denklemlerde verilmiştir.

3.2.5. Entropi

Her ne kadar dalgacık dönüşümü EEG, EKG gibi durağan olmayan sinyaller hakkında yeterli bilgi verse de katsayıların çok olması sınıflandırma aşaması için bilgilerin özellik olarak kullanılamamasına neden olmaktadır [99]. Bundan dolayı yüksek-seviyeli özelliklerin elde edilebilmesi için entropilerden yardım alınmaktadır. Sinyal işleme, örüntü tanıma, bilgi teorisi, tahmin ve sınıflandırma vb. birçok alanda kullanılan entropi, bilgideki belirsizliği ölçmek için kullanılmaktadır. Sinyal işleme alanında ise entropiye, durağan ya da durağan olmayan işaretin bünyesinde ne kadar bilgi taşıdığını hesaplamak için başvurulmaktadır [100]. Entropi bileşenli dalgacık dönüşümü yöntemi ilk olarak 1992 yılında Coifman ve Wickerhauser tarafından ortaya atılmış ve logaritmik enerji ile Shannon Entropi hesaplanmıştır [101]. Entropi, Denklem 3.13'deki gibi hesaplanmaktadır.

$$H(x) = -\sum_{i=0}^{N-1} p_i(x) \log_2(p_i(x)) \quad (3.13)$$

X sonlu bir sayı dizisini ifade etmekte ve p_i ise olasılık değerini vermektedir.

Bu tez çalışmasında bilgi ölçüm yöntemlerinden, shannon entropi, logaritmik enerji entropi, örnek entropi ve çok-ölçekli entropi kullanılmıştır. Her biri ile ilgili bilgi aşağıda verilmiştir.

3.2.6. Shannon Entropi

Shannon entropi, shannon tarafından bulunmuştur [102]. Verilerin rastgele dağılmış olduğu sistemdeki ya da dizideki, belirsizliği ölçmek için kullanılmaktadır. Shannon Entropi, Denklem 3.14’de verilen formül ile hesaplanmaktadır [100];

$$H_{ShanEn}(x) = - \sum_{i=0}^{N-1} (p_i(x))^2 (\log_2(p_i(x)))^2 \quad (3.14)$$

3.2.7. Logaritmik Enerji Entropi

Logaritmik enerji entropi, Shannon Entropi’nin bir parçası olup, Denklem 3.15’teki gibi hesaplanmaktadır [100].

$$H_{LogEn}(x) = - \sum_{i=0}^{N-1} (\log_2(p_i(x)))^2 \quad (3.15)$$

3.2.8. Örnek Entropi

Örnek entropi, bir zaman serisindeki karmaşıklığı ölçmek için kullanılmaktadır [103]. Entropi, aşağıda verilen beş adımdaki işlemlerden geçerek hesaplanmaktadır.

Adım 1: Boyutu m , tolerans değeri r olan $t(i) = \{1,2,3,\dots,N\}$ zaman serisi, ilk olarak Denklem 3.16’da verilen formüle göre yeniden düzenlenir.

$$t_m(i) = \{t_{i+1}, t_{i+2}, t_{i+3}, \dots, t_{i+m-1}\}, 1 \leq i \leq N-m+1 \quad (3.16)$$

Adım 2: Bu adımda ise, iki farklı vektör arasındaki maksimum değer bulunarak, aralarındaki mesafe, $m-1$ ’e kadar hesaplanır. Denklem 3.17’de bu işlemin nasıl yapıldığı gösterilmiştir.

$$D[t_m(i), t_m(k)] = \max(|t_m(i+w) - t_m(k+w)|), \quad (3.17)$$

Adım 3: $t_m(k)$ serisindeki toplam vektör ile $t_m(i)$ zaman serisinin toleransı sayılarak, aşağıda verilen eşitliklerle B_i serisi elde edilir.

$$B_i^m(r) = \frac{1}{N-m-1} B_i \quad (3.18)$$

$$B^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} B_i^m(r) \quad (3.19)$$

Adım 4: m vektörü $m = m + 1$ olacak şekilde düzenlenir ve 3.16, 3.17, 3.18 ve 3.19 numaralı Denklemlerdeki işlemler tekrar yeni bir seri için hesaplanır.

$$Z^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} Z_i^m(r) \quad (3.20)$$

Adım 5: Örnek entropi hesaplanır.

$$SampEn(m, r, N) = -\ln \frac{Z^m(r)}{B^m(r)} \quad (3.21)$$

3.2.9. Çok Ölçekli Entropi

Çok-ölçekli entropi, aynı örnek entropisinde olduğu gibi zaman serisindeki karmaşıklığı ölçmek için kullanılmaktadır. Ancak örnek entropi zaman ölçeklerine bağlı yapı bilgisini hesaba katmadığından dolayı, çok-ölçekli entropi ortaya atılmıştır [104]. Zaman serisi $x(i)$, ölçek katsayısı (r) kullanılarak geniş-çaplı zaman serisine (y^r) dönüştürülür. Dönüştürülme aşamasında ilk olarak orijinal seri r ölçekleme katsayısına bölünerek farklı pencerelere ayrılır ve ardından, her penceredeki ortalama veri değerleri hesaplanır. Bu işlemler için kullanılan hesaplama adımı Denklem 3.22’de belirtilmiştir [105].

$$y_j^{(r)} = \frac{1}{r} \sum_{i=(j-1)r+1}^{jr} x_i, \quad 1 \leq j \leq N/r \quad (3.22)$$

Her geniş-çaplı zaman serisinin uzunluğu, orijinal serinin ölçek katsayısına bölünmesiyle elde edilen uzunluğa eşit olmaktadır. Son olarak ise elde edilen her bir geniş-çaplı serilerinin entropileri hesaplanır ve çok-ölçekli entropi elde edilir.

Çok ölçekli entropi ile serinin karmaşıklığı hakkında karar verilirken iki durum söz konusudur. Bunlar [105];

- Ölçeklerin çoğunda bulunan entropi değerleri, başka zaman serisindeki değerlerden yüksek ise, eski zaman serisi, yeni zaman serisine göre daha karmaşıktır.
- Entropi değerlerinde monoton bir şekilde azalma görülürse, bilgi sadece orijinal sinyalde bulunan en küçük ölçekten elde edilmektedir.

3.2.10. Standart Sapma

Verilerin ortalamaya olan uzaklıklarını hesaplamak için kullanılan istatistiksel bir yöntemdir. Verilerin ortalamaya yakın olması standart sapma değerinin azalmasına neden olmaktadır. Verinin ortalamaya olan uzaklığı arttıkça bu değer o kadar büyümektedir. Standart sapmanın 0 olması değerlerin aynı uzaklıkta olduğunu göstermektedir. Sinyal işleme alanında ise standart sapma, sinyaldeki değişimleri gözlemlemek için kullanılır [106]. Standart sapma, Denklem 3.23'teki formülle elde edilir.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (3.23)$$

3.2.11. Varyans

Bir dizideki veya zaman serisindeki verilerin aritmetik ortalaması bulunarak, her bir verinin ortalama değer ile arasındaki fark hesaplanır. Ardından farklar toplanarak varyans değeri elde edilir. Standart sapma değerinin karesi varyansı vermektedir. Denklem 3.24'te varyans işleminin formülü verilmiştir.

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (3.24)$$

3.2.12. Sıfır Geçişleri

Sıfır geçişleri, bir periyot boyunca hareket eden sinyalin frekansını elde edebilmek için başvurulan yöntemdir. İşaretin eksen üzerinde 0 değerini kaç kere geçtiğini hesaplamak için kullanılır ve geçişin değeri işaretin belirli bir zaman aralığında değiştirmiş olduğu işaret sayısını (pozitif-negatif) vermektedir. Denklem 3.25'te sıfır geçişlerinin hesaplaması verilmiştir [107].

$$zgd = \sum_{n=1}^{N-1} \text{sgn}(x_n * x_{n+1}) \cap |x_n - x_{n+1}| \geq 0 \quad (3.25)$$

3.3. Sınıflandırma İşlemi için Başvurulan Sınıflandırıcılar

Bu tez çalışmasında özellik vektörünün elde edilmesinden ardından anahtar özelliklerin sınıflandırılarak duygu analizinin yapılması için, üç farklı sınıflandırıcı kullanılmıştır. Kullanılan sınıflandırıcılar KNN, DVM ve YSA olup, her biri ile ilgili detaylı bilgi aşağıda verilmiştir.

3.3.1. K En Yakın Komşu Sınıflandırıcısı

KNN algoritması öğrenme tabanlı bir algoritma olmakla beraber, birbirine yakın olan verilerin aynı sınıf ya da kümeye aktarılmasına dayanan bir yöntemdir. Öğrenmeye dayalı algoritmalarda öğrenme işlemi, eğitim setinde bulunan verilere bağlı olarak gerçekleştirilmektedir. Veri uzayına gelen her yeni örnek, eğitim setindeki verilerle karşılaştırılır ve benzerliğe göre ait olduğu sınıf ya da kümeye yerleştirilir [108]. KNN algoritması kolay, anlaşılabilir bir algoritma olduğu için çalışmalarda kullanılan algoritmaların başında gelmektedir. Veri madenciliği, örüntü tanıma, güvenlik olmak üzere çeşitli alanlarda başvurulan bir yöntemdir. Ancak algoritmaların çoğunda da olduğu gibi avantajları ve dezavantajları mevcuttur.


EEG, EKG, EMG gibi veriler elde edilirken gürültülü işaretlerde bu verilerle beraber cihazlardan toplanmaktadır. Çalışmaların çoğunda veriler önışlemden geçirilerek gürültülerden temizlenir [109-112].

KNN algoritmasının en büyük avantajlarından birisi gürültü içeren veriler üzerinde başarılı sonuçlar vermesidir. Ayrıca veri sayısı arttıkça algoritmanın başarılı sonuçlar verdiği belirlenmiştir. Dezavantajları arasında ise, sınıflandırma başarısının seçilen uzaklık hesaplama yöntemi ve k değerine bağlı olarak değişmesi gösterilebilir. Veriler arasındaki uzaklık tek tek hesaplandığı için, sınıflandırmanın performansında azalmalar olabilmektedir. KNN algoritması, birbirine yakın olan verilerin aynı kümede bulunması üzerine tasarlanmış olduğu için, sınıflandırma işlemi verilerin arasındaki uzaklığa bağlı olarak gerçekleştirilmektedir. Test setinde olan herhangi bir verinin, eğitim setinde yer alan verilerle arasındaki uzaklık hesaplanır ve en yakında bulunan k adet veri en çok hangi sınıfta ise veri o sınıfa ait olmaktadır.

KNN algoritmasının adımları şu şekilde gerçekleştirilmektedir;

- **Adım 1:** Sınıflandırma işlemine başlamadan önce k değeri belirlenir.
- **Adım 2:** Eğitim kümesinde bulunan veriler ile test setinde olan veri arasındaki uzaklık (d) hesaplanır. Uzaklıkların hesaplanması için çeşitli ölçütler bulunmakta ve en çok kullanılanlar ise Minkowski, Öklid, Manhattan, Chebyshev ve Dilca uzaklığıdır [113].
- **Adım 3:** Uzaklıklar hesaplandıktan sonra mesafesi en az olan k adet komşu veri belirlenir.
- **Adım 4:** En yakın verilerin belirlenmesiyle, verilerin ait olduğu kümeler sıralanır.
- **Adım 5:** Eğitim kümesindeki komşu veriler en çok hangi kümeye aitse, test setinde bulunan veri de o kümeye yerleştirilir ve sınıflandırma işlemi gerçekleştirilmiş olur.
- **Adım 6:** Sınıflandırmanın başarısının ölçülmesi için çapraz doğrulama işlemi gerçekleştirilir. Çapraz doğrulama işleminde, k değeri sürekli değiştirilir ve sonuç irdelenir. k değeri değiştirildikten sonra Adım 2’den Adım 5’e kadar olan kısımlar tekrar yapılır ve çapraz doğrulama işlemi tamamlanmış olur. Sonucun aynı olması durumunda en uygun sonuç elde edilmiş olur.

Şekil 3.6’da açıklanan algoritmanın bir örneği gösterilmiştir.



Şekil 3.6. KNN algoritma örneği

Yukarıda verilen şekilde $k = 3$ olmak üzere test verisetine ait siyah karenin yerleştirilmesini gerçekleştirilen işlem gösterilmiştir. Şekil 3.6 a’da siyah kare ile eğitim verisetine ait olan tüm veriler arasındaki mesafe ölçülmektedir. Ölçüm işlemi gerçekleştirildikten sonra Şekil 3.6 b’de en yakın 3 veri daire içerisine alınmış ve komşu veriler belirlenmiştir. Bu işlemin ardından çember içerisindeki mavi karenin, kırmızı kareden daha fazla olduğu görülmüş ve siyah kare artık mavi kare olarak sınıflandırılmıştır.

3.3.1.1. Mahalanobis Uzaklığı

Bu tez çalışmasında, uzaklık ölçütü olarak Mahalanobis uzaklık metrisi kullanıldığından bu uzaklık üzerinde durulmuştur. Mahalanobis uzaklığı, hesaplaması istatistik yöntemlere dayanan uzaklık fonksiyonudur. İki ya da daha fazla ilişkili değişken ile tanımlanan uzaydaki iki nokta arasındaki mesafeyi ölçmek için başvurulanan yöntemdir. Uzaklığın hesaplanma işlemleri şu şekilde gösterilebilir;

A matrisi n adet değişkenden oluşan vektör olmak üzere, bu vektörün öncelikle ortalaması alınarak yeni bir B matrisi oluşturulur. Denklem 3.26 ve Denklem 3.27’de matrisler gösterilmiştir.

$$A = \begin{bmatrix} a_1 \\ a_2 \\ a_3 \\ \vdots \\ a_n \end{bmatrix} \quad (3.26)$$

$$B = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \\ \vdots \\ b_n \end{bmatrix} \quad (3.27)$$

Matrisler oluşturulduktan sonra Mahalanobis uzaklığı aşağıda verilen Denklem 3.28 ile hesaplanmaktadır.


$$D = \sqrt{\left(\begin{bmatrix} a_1 \\ a_2 \\ a_3 \\ \vdots \\ a_n \end{bmatrix} - \begin{bmatrix} b_1 \\ b_2 \\ b_3 \\ \vdots \\ b_n \end{bmatrix} \right)^T S^{-1} \left(\begin{bmatrix} a_1 & a_2 & a_3 & \dots & a_n \end{bmatrix} - \begin{bmatrix} b_1 & b_2 & b_3 & \dots & b_n \end{bmatrix} \right)} \quad (3.28)$$

S^{-1} değeri kovaryans matrisinin tersini ifade etmektedir.


3.3.2. Destek Vektör Makineleri Sınıflandırıcısı

DVM, istatistiksel öğrenme teorisine dayanan ve danışmanlı öğrenme tekniği ile geliştirilen bir makine öğrenme algoritmasıdır. 1995 yılında ilk kez Vapnik tarafından ortaya atılmış ve örüntü tanıma ile sınıflandırma problemlerinin çözümü amaçlanmıştır [114]. İlk zamanlar sadece iki sınıflı doğrusal verilerin ayrımında kullanılmış, ancak günümüzde hem doğrusal olmayan hem de çok sınıflı verilerin ayrımında da kullanılabilir. DVM ile sınıflandırma işleminin temelinde, birbirinden farklı iki sınıfa ait verilerin belirlenen bir sınır ile yani hiper-düzlem ile ayrılması yatmaktadır.

Eğitim verisetinde bulunan verilerin eğitilmesi sonucu ortaya çıkan karar fonksiyonu ile test verisetindeki veriler test edilir ve en iyi ayrımın yapıldığı düzlem elde edilir. Şekil 3.7’de verilen iki ayrı sınıfa ait verileri birbirinden ayırmak için çok sayıda hiper-düzlem çizilmiştir. Ancak bu hiper-düzlemler en uygun değeri vermeyecektir. Eğitim setinde olan verisetlerinden birbirine en yakın olan verilerin uzaklığı en uygun değeri verir ve DVM sayesinde Şekil 3.8’de de görüldüğü üzere, en yüksek kenar boşluğu değeri bulunarak bu işlem gerçekleştirilir.



Şekil 3.7. İki farklı sınıf için çizilebilecek farklı hiper-düzlemler



Şekil 3.8. Hiper-düzlem ve en iyi hiper-düzlem

DVM ile eğitim verisetinde bulunan en uç noktadaki veriler seçilerek en uygun düzlem belirlenir. Seçilen bu verilere destek vektörü denmektedir. En uygun hiper-düzlemin seçilmesi, sınıflandırma ve ayırım başarımını olumlu yönde desteklemekte ve daha etkili sonuçlar ortaya çıkmaktadır. Kısacası DVM, destek vektörleri arasındaki maksimum uzaklığı hesaplayarak sınıflandırma işlemi gerçekleştirir [115]. DVM doğrusal ve doğrusal olmayan şeklinde 2'ye ayrılmaktadır.

3.3.2.1. Doğrusal Destek Vektör Makineleri

Anlaşılması ve uygulanması en kolay modeldir. Doğrusal bir şekilde ayrılabilen sınıflar ve özellikler için geçerli olmasından dolayı gerçek dünya problemlerinde başarı sağlamaları çok zordur. Doğrusal destek vektör makinelerinde sınıflandırma işlemi için ayırıcı özelliklerin belirlenmesi yeterlidir. A verisetinin $(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_i, y_i)$ şeklinde tanımlandığını düşünelim. x eğitim setindeki verileri y ise bu örneklerin ait olduğu sınıf etiketlerini göstermek üzere A veriseti Denklem 3.29'daki gibi tanımlanır.

$$\{x_i, y_i\}, i = 1, 2, 3, \dots, N, y_i \in \{-1, 1\} \quad (3.29)$$

Sınıfları birbirinden ayıracak hiper-düzlemin formülü ise Denklem 3.30'da verilmiştir.

$$w \cdot x + c \quad (3.30)$$

w değeri denklemde hiper-düzlemin normalini temsil etmekte ve c değeri ise sabit bir değer olarak ifade edilmektedir. Bu aşamadan sonra DVM sınıflandırıcısının hesaplama adımları verilerin doğrusal bir şekilde veya hatalı bir şekilde ayrılıp ayrılmamasına bağlı olarak değişiklik gösterir. Eğer eğitim verisindeki verilerin doğrusal bir şekilde ayrılması söz konusuysa, DVM en uygun hiper-düzlemi aşağıda verilen Denklem 3.31 ve Denklem 3.32 aracılığıyla bulmaya çalışır [116].

$$f(x_i) = \langle w, x_i \rangle + c \geq +1, y_i = 1 \quad (3.31)$$

$$f(x_i) = \langle w, x_i \rangle + c \leq -1, y_i = -1 \quad (3.32)$$

Eşitliklerden yola çıkarak hem birbirlerine paralel olan hem de hiper-düzleme eşit uzaklıkta bulunan iki düzlem $\{H_1 \text{ ve } H_2\}$, Denklem 3.33 ve Denklem 3.34'e göre hesaplanır.

$$H_1 = \langle w, x_i \rangle + c = +1 \quad (3.33)$$

$$H_2 = \langle w, x_i \rangle + c = -1 \quad (3.34)$$

H_1 ve H_2 düzlemlerinin üzerinde eğitim setinde yer alan destek vektörleri bulunmaktadır. Bu vektörler hiper-düzleme en yakın vektörler olup, aşağıda verilen Denklem 3.35 ve Denklem 3.36 ile hiper-düzleme olan uzaklıkları (D) ve sınır değeri (p) bulunmaktadır.

$$D(w, c; x) = \frac{|\langle w, x_i \rangle + c|}{\|w\|} \quad (3.35)$$

$$p(w, c) = \frac{2}{\|w\|} \quad (3.36)$$

En iyi çözümü sağladığı için, optimal hiper-düzlemin bulunması işlemi için Lagrange çarpanlarına başvurulmaktadır [117,118]. Lagrange çarpanlarıyla yapılan işlem Denklem 3.37'de verilmiştir.

$$L_p = (w, c, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i [y_i(\langle w, x_i \rangle + c)] + \sum_{i=1}^n \alpha_i \quad (3.37)$$

Eşitliğin küçük değer alması, α_i Lagrange çarpanının en büyük değeri almasına bağlı olarak gerçekleşmektedir [119]. w ve c değerlerinin hesaplama adımları Denklem 3.38 ve Denklem 3.39'daki formüller aracılığıyla gerçekleşmektedir.

$$w = \sum_{i=1}^n y_i \alpha_i x_i \quad (3.38)$$

$$c = \sum_{i=1}^n -\frac{1}{2} [x_r, x_s] \quad (3.39)$$

x_r ve x_s değerleri H_1 ve H_2 düzlemleri üzerinde bulunan destek vektörlerini ifade etmektedir. Sonuç olarak aşağıda verilen Denklem 3.40 ile DVM sınıflandırma işlemi tamamlanmış olmaktadır.

$$f(x) = \text{sign}(\langle w, x_i \rangle + c) = \text{sign}(\sum_{i=1}^n y_i \alpha_i \langle x_i, x \rangle + c) \quad (3.40)$$

Verilerin gürültü içermesi, boyutlarının fazla ve karmaşık olması, verilerin belirli bir hata ile sınıflandırılmasına neden olmaktadır [120]. Bu tarz verilerin ayırım işlemi için gevşek kenar boşluğu (soft margin) kullanılmaktadır. Bu durumda, eğitim setindeki bazı veriler, en uygun hiper-düzlemin diğer tarafında kalmaktadır. Problemin çözümü için ise gevşek değişken (soft variable) Denklem 3.41 ve Denklem 3.42’de verildiği gibi kullanılmaktadır.

$$f(x_i) = \langle w, x_i \rangle + c \geq +1 - \xi_i \quad (3.41)$$

$$f(x_i) = \langle w, x_i \rangle + c \geq +1 + \xi_i \quad (3.42)$$

Sınıflandırmadan kaynaklanacak hatanın en aza indirgenmesi ve hesaplanan sınırın maksimum değere sahip olabilmesi için ise, Denklem 3.43 verildiği gibi bir düzenleme parametresi (C) kullanılmaktadır [121].

$$\min \frac{1}{2} ||w||^2 + C \sum_{i=1}^n \xi_i \quad (3.43)$$

Denklemdaki C parametresi ceza değerini ifade etmektedir. Ceza parametresinin Lagrange çarpanına eşit olması halinde destek vektörleri, hiper-düzlem üzerinde olacak şekilde değer alırlar [122]. C değerinin çok yüksek ya da çok az olması en uygun hiper-düzleminin belirlenememesine neden olmakta ve C değerinin sonsuza eşit olması, sadece doğrusal verilerin ayırımının yapılacağı anlamına gelmektedir. Denklem 3.44’te en uygun hiper-düzlemin elde edilmesi gösterilmiştir.


$$L_p = (w, c, \alpha, r, \xi) = \frac{1}{2} ||w||^2 + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \alpha_i [y_i (\langle w, x_i \rangle + c) - 1 + \xi_i] - \sum_{i=1}^n r_i \xi_i \quad (3.44)$$

Denklem 3.45 ile sınıflandırma işlemi gerçekleştirilmektedir.

$$f(x) = \text{sign}(w^*, x_i + c^*) = \text{sign}(\sum_{i=1}^n y_i \alpha_i \langle x_i, x_j \rangle) \quad (3.45)$$

3.3.2.2. Doğrusal Olmayan Destek Vektör Makineleri

Verilerin doğrusal olarak ya da belirli bir hata ile ayrılmadığı durumda başvurulacak vektör makineleridir. Gerçek dünya problemlerin çoğu doğrusal bir fonksiyonla sınıflandırılmadığı için bu yöntem kullanılmaktadır. Doğrusal olarak ayrılan destek vektör makinelerine kıyasla uygulaması daha zor bir yöntemdir. Bunun en büyük nedeni ise, sınıflandırma işleminin tahmine dayalı bir şekilde gerçekleştirilmesidir [117]. Şekil 3.9’da doğrusal bir şekilde ayrılamayan verilere ait dağılım görüntüsü verilmiştir.



Şekil 3.9. Verilerin doğrusal ayrılamama durumu

Şekil 3.9’den de anlaşılacağı üzere verilerin ayrımı doğrusal bir şekilde yapılamamaktadır. Bundan dolayı verilerin özellik uzayı adı verilen yüksek dereceden başka bir uzaya taşınması gerekmektedir. Özellik uzayındaki amaç, verilerin doğrusal hale getirildiği ve en uygun hiper düzlem oluşturularak sınıflandırılmasını sağlamaktır. Çekirdek fonksiyonlarının kullanılmasıyla veriler doğrusal verilere dönüştürülmekte ve özellik uzayına taşınarak doğrusal bir fonksiyon ile sınıflandırılmaya hazır hale getirilmektedir. Matematiksel ifade Denklem 3.46’da gösterilmiştir.

$$f(x) = \text{sign} \left(\sum_i \alpha_i y_i \phi(x) \cdot \phi(x_i) + b \right) \quad (3.46)$$

Denklemdaki φ simgesi çekirdek fonksiyonunu belirtmektedir. Formüldende de anlaşılaçağı üzere sınıflandırmanın başarısı seçilen çekirdek fonksiyonuna göre değışiklik göstermektedir. Yapılan çalışmalar incelendiğinde çekirdek fonksiyonu olarak en çok kullanılanlar arasında, radyal tabanlı, polinomiyal, sigmoid ve doğrusal fonksiyonlar bulunmaktadır [117, 123, 124]. Tablo 3.3’de kullanılan çekirdek fonksiyonlarına ait formüller verilmiştir.

Tablo 3.3. Kullanılan çekirdek fonksiyonları ve formülleri


Çekirdek Fonksiyonu	Formülü
Radyal Tabanlı Fonksiyon	$K(x, y) = e^{-\gamma \ x - x_l\ ^2}$
Polinomiyal Fonksiyon	$K(x, y) = (x \cdot y + 1)^d$
Sigmoid Fonksiyonu	$K(x, y) = \tanh(\gamma x \cdot y + r)$
Linear (Doğrusal) Fonksiyon	$K(x, y) = x \cdot y$

3.4. Yapay Sinir Ağları Sınıflandırıcısı

Öğrenme, keşfetme ve yeni bilgiler üretebilme gibi insanlara özgü davranışları yardım almayarak gerçekleştiren, öğrenme tabanlı bilgisayar sistemlerine YSA denmektedir. Günümüzde sınıflandırma, optimizasyon, genelleme, ilişkilendirme tahmin işlemleri, veri doğrulama vb olmak üzere birbirinden farklı bir çok alanda kullanılmakta ve gün geçtikçe kullanım alanlarında artış gözlemlenmektedir [125-129].

3.4.1. Yapay Sinir Hücresinin Yapısı ve Elemanları

Yapay sinir hücresinin başlıca elemanı insan beyninden esinlenmiş olduğu için nöronlardır. İnsanlardaki sinir hücreleriyle benzerlik göstermekte ve belirli bir giriş değerleri, çıkış değerleri ve verilerin ya da bilgilerin işlendiğı bir alan bulunmaktadır. Şekil 3.10’da bir yapay sinir hücresine ait görüntü verilmiştir.



Şekil 3.10. Yapay sinir hücresi yapısı

Şekil 3.10'dan anlaşılabacağı üzere, bir yapay sinir hücresinde girdi, ağırlık, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere beş eleman bulunmaktadır.

Girdi değeri: Girdi değeri sinir hücresine gelen bilgileri ifade etmektedir. Bu bilgiler başka bir sinir hücresinden, dış ortamdan veya kendisinden gelmektedir. Gelen bilgiler daha sonra ağırlıklar aracılığıyla hesaplanmak üzere toplama fonksiyonuna iletilirler.

Ağırlık değeri: Yapay sinir ağlarında hafıza görevi görmektedirler. Hücreye gelen girdi bilgileri ağırlık değerleriyle çarpılır ve işlenmek üzere toplama fonksiyonuna iletilirler. Bu sayede girdilerin sistemin çıktısı üzerindeki etkisi hesaplanmakta ve hücreye yansıyan etkisi belirlenmektedir. Ağırlık değerleri sıfır, sıfırdan büyük ve sıfırdan küçük olabilmektedir. Sistemin çalışma hızına (öğrenme iterasyon sayısına) belirlenen ağırlıkların doğrudan etkileri bulunmaktadır [130].

Toplama Fonksiyonu: Hücreye gelen bilgileri işleyerek net girdiyi hesaplamakla görevli olan kısımdır. Birleştirme fonksiyonu da denmektedir. Tablo 3.4'de toplama fonksiyonu için en çok kullanılan formüller verilmiştir.

Tablo 3.4. Toplama fonksiyonu için yaygın olarak kullanılan formüller

Toplama Fonksiyonu	Açıklama
$\prod X_i W_i$	Girdi ve karşılık gelen ağırlık değerleri birbirleriyle çarpılmaktadır. Daha sonra elde edilen değerler tekrar birbirleriyle çarpılarak net girdi hesaplanır.
$\text{Max}(X_i W_i)$	Giriş ve ağırlıkların çarpılmasıyla elde edilen değerler içerisindeki en büyük değer bu formül ile net girdi olarak elde edilmektedir.
$\text{Min}(X_i W_i)$	Giriş ve ağırlıkların çarpılmasıyla elde edilen değerler içerisindeki en küçük değer bu formül ile net girdi olarak elde edilmektedir.
$\sum \text{sgn}(X_i W_i)$	Girdiler ile ağırlıklar çarpıldıktan sonra pozitif ve negatif değerler belirlenir. Hangi değer çok ise o ağırlık net girdisi olarak hesaplanmaktadır.
$\text{Net (eski)} + \sum(X_i W_i)$	Formül ile önceden elde edilen net girdi, güncel net girdinin üzerine eklenir.

Etkinleştirme Fonksiyonu: Toplama fonksiyonundan gelen net girdiyi işlemekle ve hücrenin çıktısını üretmekle sorumlu olan kısımdır. Genel olarak doğrusal olmayan fonksiyonlar seçilmektedir. Bundan dolayı doğrusal olmayan problemlerin çözümünde başarı sağlamaktadır. Transfer fonksiyonu olarak da bilinir. Doğrusal, adım, sigmoid, tanjant hiperbolik ve eşik fonksiyonları en çok tercih edilen ve kullanılan fonksiyonların başında gelmektedir. Aşağıda belirtilen fonksiyonlara ait formüller verilmiştir.

Doğrusal fonksiyon ile hesaplanan net çıktı direk hücrenin çıktısı olarak belirlenmektedir. c katsayısı sabit bir değeri ifade etmektedir. Denklem 3.47’de doğrusal fonksiyon gösterilmiştir.

$$F(\text{net}) = c * \text{net} \quad (3.47)$$

Denklem 3.48’de adım (step) fonksiyonun hesaplanması verilmiştir. Formüle göre, gelen net girdi hesaplandıktan sonra net girdinin belirlenen eşik değerinden büyük ya da küçük olmasına göre, yapar sinir ağının çıktısı belirlenmektedir. Eğer net girdi eşik değerden büyük ise 1 çıktısını, eşik değerden küçük ve eşik değere eşit ise 0 çıktısını vermektedir.

$$F(\text{net}) = \begin{cases} \text{eğer } \text{net} > \text{eşik değeri ise } 1 \\ \text{eğer } \text{net} \leq \text{eşik değeri ise } 0 \end{cases} \quad (3.48)$$

Denklem 3.49’da sigmoid fonksiyonuna ait hesaplama işlemi verilmiştir.

$$F(net) = \frac{1}{1+e^{-net}} \quad (3.49)$$

Doğrusal olmamasından ve çıkış değerlerinin $[0,1]$ aralığında olacak şekilde değer üretmesinden dolayı yapay sinir ağlarında en çok kullanılan aktivasyon fonksiyonlarının başında gelmektedir.

Tanjant hiperbolik fonksiyonuna ait hesaplama Denklem 3.50’de ifade edildiği gibidir. Daha çok çıktı olarak $[-1,1]$ arasında sonuç üreten yapay sinir ağlarında kullanılmaktadır.

$$F(net) = \frac{e^{net} + e^{-net}}{e^{net} - e^{-net}} \quad (3.50)$$

Eşik fonksiyonu Denklem 3.51’de gösterildiği şekilde kullanılmaktadır.

$$F(net) = \begin{cases} \text{eğer } net \geq 1 \text{ ise } 1 \\ \text{eğer } net \leq 0 \text{ ise } 0 \\ \text{eğer } 0 < net < 1 \text{ ise } net \end{cases} \quad (3.51)$$


Formüle göre yapay sinir ağının net girdisinin 1 ve 1’den büyük değer alması ağın çıktısının 1 olmasına neden olmaktadır. Eğer çıktı 0 olarak elde edilmişse ağın net girdisi 0 ve 0 değerinin altındadır. Ağın net girdisi $(0,1)$ aralığında elde edilirse, ağın çıktısı net girdi olarak hesaplanmaktadır.

Çıktı değeri: Aktivasyon fonksiyonu aracılığıyla hesaplanan değer hücrenin çıktı değerini vermektedir. Ortaya çıkan bu çıktı, hücrenin yapısına göre ya diğer hücreye ya da dış dünyaya iletilmektedir. Sinir hücresinde birden çok giriş varken bir sinir hücresi sadece tek çıktı üretmektedir.

Şekil 3.10’da görüldüğü üzere x değerleri girişi ve w değerleri ise ağırlığı ifade etmektedir. Her giriş değeri karşılık gelen ağırlık ile çarpılır ve hücrenin çekirdeğine (toplama fonksiyonu) iletilmektedir. Toplama fonksiyonunda ($\sum$) net girdi hesaplanır ve aktivasyon fonksiyonuna (ϕ) iletilerek hücrenin çıktısına denk gelen değer bulunur ve hücrenin çıktısı üretilir.

3.4.2. Yapay Sinir Ağının Yapısı ve Elemanları

Yapay sinir hücreleri bir araya gelerek yapay sinir ağını meydana getirmektedir. Bir yapay sinir ağı giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç farklı katmandan meydana gelmektedir. Şekil 3.11’de yapay sinir ağı gösterilmiştir.



Şekil 3.11. Yapay sinir ağı modeli

Giriş katmanı: YSA’ya gelen giriş değerlerinin tutulduğu katmandır. Bu katmanda genelde bilgiler işlenmez ve direk ara katmana iletilir.

Gizli (Ara) katman: Giriş katmanından gelen bilgilerin işlendiği katmandır. Ara katmanda bulunan nöronlar elde edilen özellik vektöründeki özellikleri temsil etmektedir. Bundan dolayı ara katman için oluşturulan modelin (katman sayısı, nöron sayısı) başarıma etkisi büyüktür.

Çıkış katmanı: Ara katmandan gelen bilgilerin işlenip dış dünyaya aktarıldığı kısımdır.

3.4.3. Yapay Sinir Ağının Özellikleri

Yapay sinir ağlarının özellikleri oluşturulan modele göre değişiklik göstermekte ve modele göre başarımlar sağlanmaktadır. Ancak çoğu yapay sinir ağlarında görülen özellikler şu şekilde sıralanabilir;

Öğrenme: Yapay sinir ağlarının en önemli özelliklerinden birisi kendi kendine öğrenme gerçekleştirmeleridir. Yapay sinir ağları girdi olarak verilen verileri inceler ve o verilere dayanarak çıkarımda bulunur. Bu süreç için giriş değerleri ile çıkış değerleri arasındaki bağıntıyı inceleyerek ağırlıkları hesap eder ve doğru sonucu üretmeye çalışır. Eğer YSA, daha önceden verilmeyen bir bilgiyi kullanarak hesaplamış olduğu ağırlık ile doğru çıktı üretirse ağın öğrenmesi gerçekleşmiştir [131].

Doğrusal Olmama: YSA doğrusal olmadığı için karmaşık problemlerin çözümünde tercih edilmekte ve başarılı sonuçlar üretmektedir. Yapısında bulundurmuş olduğu aktivasyon fonksiyonu nedeniyle doğrusal değildir [125].

Genelleme: Yapay sinir ağları, ağ öğrenmesini gerçekleştirdikten sonra daha önce hiç karşılaşmadığı verileri kullanarak doğru çıkışlar üretebilmektedir. Önceden belirlenmiş olan özellikleri kullanarak yeni verilerle karşılaştırarak onları ait olduğu kümeye yerleştirmektedir [131].

Hata Toleransı: Eğer bir yapay sinir ağı, başarılı bir şekilde modellenmiş ve eğitilmiş ise eksik bilgi olsa dahi sonuç üretmektedir. Yapay sinir ağları yapı gereği paralel bir şekilde tasarlanmış ve bu sayede bilgi tüm ağı hücreler aracılığıyla yayılmış durumdadır. Verilerde azalmanın olması ve hücreler arasındaki iletişim kopması durumu söz konusu olduğunda bile doğru sonuç vermeye devam etmektedir. Ancak ağın topolojisinin bozulması performansı etkilemekte ve ağın hızında azalma görülebilmektedir [131,132].

Taşınabilirlik: YSA sonuçları ağırlık değerlerini güncelleyerek elde etmektedir. Özellik vektöründeki değerlerin değişmesi veya çözüme kavuşturulması gereken problemde değişiklik olması durumunda yapay sinir ağları tekrar eğitilebilir. Eğitim sonucunda YSA güncel ağırlıkları hesaplayarak doğru sonuçları üretmeye başlamaktadır [125].

Hız: Yapay sinir ağlarının topolojik yapısından dolayı verilerin yorumlanması hızlı bir şekilde gerçekleşmektedir. Katmanlı bir mimariye sahip olması işlemlerin paralel bir şekilde yürütmesine sebebiyet vermekte ve ağın hızında önemli derece artış görülmektedir. Bundan dolayı gerçek zamanlı uygulamalarda tercih edilmektedir [131,132].


3.4.4. Yapay Sinir Ağları Sınıflandırıcı Modelleri

Yapay sinir ağları eğitici öğrenme ve eğitici öğrenme olmak üzere ikiye ayrılmaktadır. Eğitici öğrenme yapay sinir ağlarının başında 1987 yılında Carpenter ve Grossberg'in tanımlamış olduğu ART (Adaptif Rezonans Teorisi) gelmektedir [133]. Ardından 1989 yılında Kohonen tarafından Kohonen Haritaları geliştirilmiştir [134]. Eğitici öğrenme ise kendi içerisinde dinamik ve statik olmak üzere ikiye ayrılmaktadır. Statik ağların başında ÖVK (Öğrenmeli Vektör Kuantumlama), RTBA (Radyal Tabanlı Fonksiyon Ağları), OA (Olasılıksal Ağlar) ve ÇKA (Çok Katmanlı Algılayıcı) gelmektedir [135-138]. Dinamik ağlarda kendi içlerinde ikiye ayrılmakta ve ileri-beslemeli ve geri-beslemeli olacak şekilde ifade edilmektedir.

Bu tez çalışmasında çok katmanlı yapay sinir ağı kullanılmış ve gerekli açıklamalar sonraki kısımda verilmiştir.

3.4.5. Çok Katmanlı Yapay Sinir Ağları

ÇKYSA (Çok Katmanlı Yapay Sinir Ağı) en az bir gizli katman olmak koşuluyla çok sayıda katmandan meydana gelmektedir. Şekil 3.12'de ÇKYSA örneği verilmiştir.




Şekil 3.12. ÇKYSA modeli

Şekil 3.12’de de görüldüğü üzere girdi katmanında giriş değerleri bulunmaktadır. Giriş değerleri daha sonra ara katmanda bulunan nöronlara iletilir ve işlenmeye başlar. Ardından çıkış katmanında bulunan çıktıları gönderilerek ağın çıktısı belirlenir. ÇKYSA’da öğrenme ileri beslemeli ve geri beslemeli olmak üzere iki şekilde hesaplanmaktadır.

3.4.5.1. İleri Beslemeli Hesaplama

Bu şekilde modellenen bir yapay sinir ağında, giriş değerleri ağın çıktı katmanına iletilmektedir. Bu iletim şekli giriş katmanından çıkış katmanına tek yön olacak şekilde gerçekleşmektedir. Giriş katmanında bulunan her bir işlem elemanı (nöron) ara katmandaki tüm işlem elemanları ile bağlantılıdır.

Aynı katmanda bulunan işlem elemanları birbirleriyle iletişim kurmazlar. İleri besleme ile gerçekleştirilen ağ yapısında ağın çıktısı hesaplanmaktadır. Şekil 3.13’de ÇKİBYSA (Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı) örneği gösterilmiştir.



Şekil 3.13. ÇKİBYSA öğrenme süreci

Aşağıda ileri besleme öğrenmesinin hesaplama adımları verilmiştir. İlk olarak girdi katmanına ulaşan giriş değerleri hiçbir işlem görmeden direk ara (gizli) katmanda bulunan nöronlara iletilirler. Ardından ara katmanda bulunan işlem elemanlarına gelen bilgilerin net giriş değeri Denklem 3.52’deki gibi hesaplanmaktadır [139].

$$NET_j^a = \sum_{k=1}^n A_{kj} C_k^i \quad (3.52)$$

A_{kj} değeri, girdi katmanında bulunan k. girdi elemanını, j. ara katmanda bulunan elemana iletilen bağlantının ağırlığını ifade etmektedir. Ara katmandaki hesaplamalar aktivasyon fonksiyonu aracılığıyla gerçekleşir ve ara katmandaki çıkış değeri elde edilir. Çıkış değeri elde edildikten sonra başka bir ara katman var ise giriş olarak kullanılmakta yok ise ağın çıktı katmanına iletilmektedir. İleri beslemeli çok katmanlı yapay sinir ağlarında genelde sigmoid fonksiyonu tercih edildiğinden çıkış değeri aşağıda verilen Denklem 3.53'teki gibi hesaplanmaktadır [139].

$$\zeta_j^a = \frac{1}{1 + e^{-(NET_j^a + \beta_j^a)}} \quad (3.53)$$

Ara katman sayısı ve ara katmandaki işlem elemanlarının sayısının belirlenmesi için herhangi bir formül ya da belirli bir dayanak yoktur. Verilerin şekline, miktarına, özellik vektörüne bağlı olarak değişiklik göstermektedir. Bundan dolayı yapay sinir ağlarının çalışma prensibi henüz bilinmemekte ve deneme yanılma ile en iyi sonuçlar elde edilmektedir [140].

3.4.5.2. Geri Beslemeli Hesaplama

Geriye doğru beslemede, ağı ağırlık hesaplamaları hedeflenen çıktıya ulaşıncaya kadar değiştirilip güncellenmektedir. Güncellenecek ağırlıklar, girdi katman- ara katman ve ara katman- çıktı katman olacak şekilde belirlenmektedir. Ağın hatası kabul edilebilir düzeye ulaştığında ağ eğitilmiş olmakta ve sınıflandırma başarılı bir şekilde gerçekleştirilmektedir.

ÇKGBYSA (Çok Katmanlı Geri Beslemeli Yapay Sinir Ağı) çalışma adımları aşağıda ifade edilmiştir. İlk aşamada ağı ürettiği çıktılar ile hedeflenen çıktılar kıyaslanarak aralarındaki fark belirlenir. Bu fark ile ağın hatası elde edilir. Ağın hatası geriye doğru iletilmekte ve ağı ağırlıkları bu hata ile güncellenmektedir. Denklem 3.54'te ağın hatasının bulunmasını gösteren formül verilmiştir.

$$E_j = B_j - \zeta_j \quad (3.54)$$

E_j çıkış katmanında bulunan j. elemandaki hatayı ifade etmektedir. B_j ise çıktı katmanındaki j. elemanın beklenen çıktısını göstermekte ve ζ_j ise j. elemanın gerçekleşen çıktısını vermektedir.

Elde edilen hata değeri sadece j. elemanın hata değeridir. Tüm elemanların hata değeri toplanarak (TE) ağırlık değeri elde edilmektedir. Toplam hatanın hesaplama işlemi Denklem 3.55'te verilmiştir.

$$TE = \frac{1}{2} \sum_j E_j^2 \quad (3.55)$$

Hata değerleri negatif olabilmektedir. Negatif değerlerden kurtulmak için hataların karesi alınarak toplama işlemi gerçekleştirilir. Gizli katmanındaki i. eleman ile çıkış katmanındaki j. eleman arasındaki ağırlık değişim miktarı Denklem 3.56'daki gibi hesaplanmaktadır.

$$\Delta W_{ij}^\alpha(k) = \lambda \delta_j \zeta_i^\alpha + \alpha \Delta W_{ij}^\alpha(k-1) \quad (3.56)$$


Denklemde ΔW_{ij} i.eleman ile j. eleman arasındaki ağırlık değişimini göstermektedir. Momentum katsayısı ağırlık maksimum ya da minimum noktaya takılmasını engellemekte ve α simgesi ile ifade edilmektedir. Öğrenme katsayısı λ ağırlıktaki değişim miktarını belirtmektedir. İterasyon sayısı ise k ile gösterilmektedir. Ağırlıkların k. adımdaki değerlerinin hesaplanması Denklem 3.57'de verilmiştir.

$$W_{ij}^\alpha(k) = W_{ij}^\alpha(k-1) + \Delta W_{ij}^\alpha(k) \quad (3.57)$$

YSA paralel bir yapıya sahip olduğu için ağırlıklar sadece çıkış katmanı ve gizli katman arasında değil aynı zamanda giriş katmanı ve gizli katman arasında da bulunmaktadır. Bundan dolayı tüm katmanlardaki ağırlıkların güncellenmesi gerekmektedir. Girdi katmanı ile ara katman arasında bulunan k. adımdaki ağırlıkların hesaplanması Denklem 3.58'de verilmiştir.

$$W_{jt}^\alpha(k) = W_{jt}^\alpha(k-1) + \Delta W_{jt}^\alpha(k) \quad (3.58)$$

Tüm bu adımlar ağ istenilen çıkışı üretene kadar tekrarlanmaktadır. Şekil 3.14'te ÇKGBYSA örneği verilmiştir.



Şekil 3.14. ÇKGBYSA öğrenme süreci

3.4.6. Yapay Sinir Ağlarının Eğitilmesi

YSA'da giriş katmanına gelen giriş verileri aktivasyon fonksiyonu ile işlenir ve çıkış katmanına iletilir. Çıkış katmanında ağın çıkışı belirlenir. Bu çıkış ile beklenen çıkış karşılaştırılır ve aralarındaki fark bulunup ağın hatası elde edilir. Ağırlıklar bulunan hatalar aracılığıyla güncellenir ve hedeflenen çıktı elde edilinceye kadar bu işlem devam eder. Arzulanan çıktı elde edilince işlemler sonlandırılır. Ağın öğrenmesinin test edilebilmesi için başka verilerin kullanılması gerekmektedir. Ağa daha önce verilmeyen veriler gösterilir ve ürettiği çıkışlar incelenir. Üretilen çıkışlar istenilen çıktılara yakın değerler üretiyorsa bu ağ öğrenme işlemini başarılı bir şekilde gerçekleştirmiş demektir. Eğer sonuçlar birbirine yakın değilse öğrenme işlemi gerçekleşmemiş olur ve ağ tekrar eğitime başlanır. Bir yapay sinir ağının eğitilmesi için çok sayıda süreç mevcuttur. Bu süreçler aşağıda belirtilmiş olup açıklamaları verilmiştir.

1. Verilerin elde edilmesi: Bu süreçte yapay sinir ağını hem eğitmek hem de test etmek için örnekler elde edilmektedir. Eğitim seti için toplanan örneklerle ağ eğitilir ve daha sonra test aşamasında kullanılması planlanan örnekler ağa gösterilerek ağın performansı değerlendirilmektedir. Test setindeki veriler ağın daha önce bilmediği veriler olduğu için değerlerin yorumlanması ve sonuç başarısı, ağın öğrenme gerçekleştirip gerçekleştirmediği hakkında bilgi vermektedir.

2. YSA modelinin belirlenmesi: Bu adımda YSA sınıflandırıcısı belirlenmektedir. Ağın giriş katmanında kaç adet giriş ünitesi olacağı, gizli katman sayısı ve her katmanda kaç adet işlem elemanı olacağı ve ağın çıktı katmanında kaç adet çıktı olacağı tasarlanmaktadır. Aynı zamanda ağın ileri beslemeli veya geri beslemeli olup olmayacağı da kararlaştırılmaktadır.

3. Gerekli parametrelerin belirlenmesi: Bu adımda ağda kullanılacak olan toplama fonksiyonu, aktivasyon fonksiyonu, momentum katsayısı ve öğrenme katsayısı gibi parametreler hesaplanmaktadır.

4. Ağırlıkların ilk değerlerinin belirlenmesi: Bu adımda giriş katmanı ve ara katman arasındaki nöronların ağırlıkları belirlenmektedir. Genelde ağırlıklar rastgele olacak şekilde tasarlanır ve ağın eğitilme aşamasında ağ kendi kendine ağırlıkları günceller. Ağırlıkların başlangıç değerlerinin ağ performansına etkisi çoktur.

Ağırlıkların küçük aralıkta seçilmesi, güncel ağırlıkların beklenen düzeye gelmesinde gecikmeye neden olmaktadır. Bazı çalışmalarda ağırlıklar belirli bir iterasyon sonucunda hemen güncellenirken, bazılarında ise uzun süren iterasyon sonucunda ağırlıklar güncellenmektedir [141,142].

5. Eğitim setindeki örneklerin kullanılması: Bu aşamada eğitim setinde bulunan örnekler belirli bir düzen içerisinde ağa gösterilmekte ve ağın öğrenmeye başlaması sağlanmaktadır. Ağ öğrenme işlemini ağırlıkları güncelleyerek gerçekleştirmektedir.

6. Ağın hesaplanması: Bu adımda ağ, giriş değerlerini kullanarak daha önceden belirlenmiş olan parametreler aracılığıyla ağın çıktısını üretmektedir.

7. Hata payının bulunması: Bu adımda gerçekleşen çıktı ile beklenen çıktı karşılaştırılır ve aralarındaki fark bulunarak ağın hatası belirlenmektedir.

8. Ağırlıkların güncellenmesi: Bu adımda bulunan hatalar aracılığıyla ağın güncel ağırlıkları değiştirilmektedir.

9. Ağın test edilmesi: Gerçekleşen çıktı ile beklenen çıktı arasındaki fark azaldıkça ağın öğrenme işlemi o kadar erken olmaktadır. Hata payı kabul edilebilir bir değere geldiği zaman test setindeki veriler kullanılır ve test setindeki örnekler ağa gösterilerek ağın öğrenip öğrenmediği kontrol edilir.

4. BULGULAR ve TARTIŞMA

Bu kısımda, tez çalışması kapsamında literatürde kullanılan DEAP verisetinden ve Fırat Üniversitesi Bilimsel Araştırma Projesi aracılığıyla temin edilen taşınabilir EEG cihazıyla toplanan belirli EEG kanallarına ait çıkarılan anahtar özelliklerin sınıflandırma başarımları değerlendirilmiştir.

4.1. DEAP Verisetinden Elde Edilen Bulgular

Çalışmada DEAP verisetine ait ve önışlemden geçirilmiş altı farklı (C3, C4, F3, F4, Fp1 ve Fp2) EEG kanalı üzerinde durulmuştur. Kanallar öncelikle ikinci Seviye Daubechies (db2) kullanılarak dört seviye ayrıştırılmış ve her bir kanaldan cd1, cd2, cd3, cd4, ca4 olmak üzere beş ayrı dalgacık katsayısı işaretleri elde edilmiştir. Dalgacık katsayısı işaretlerin elde edilmesiyle her bir alt işaretten bilgi ölçüm yöntemlerine, istatistiksel metotlara ve zaman-frekans alanına dayalı özellikler toplanmış ve özellik vektörü elde edilmiştir. Anahtar özellikler sırasıyla; eğimden arındırılmış dalgalanma analizi, Hjorth parametreleri, dalgaların ortalama enerjisi, logaritmik enerji entropi, çok-ölçekli entropi, örnek entropi, Shannon entropi, standart sapma, varyans ve sıfır geçişleridir. Her bir dalgacıktan 10 özellik elde edilmiş ve her kanal için özellik vektörü 50x2 ve 50x4 olacak şekilde tasarlanmıştır. Duyguların sınıflandırılması için uyarılma-valans düzlemi kullanılmış ve sistemin çıkış değerleri iki farklı şekilde irdelenmiştir. Dört çıkış olacak şekilde tasarlanan özellik vektöründe (50x4), 50 adet giriş değeri ve 4 adet (YUPV, DUPV, YUNV, DUNV) çıkış değeri bulunmaktadır. 50x2 şekilde tasarlanan özellik vektöründe ise 50 adet giriş ve 2 adet (Pozitif-Negatif) çıkış bulunmaktadır. Sınıflandırma için 3 (DVM, KNN, YSA) farklı sınıflandırıcı kullanılmış ve her kanal için elde edilen başarımlar kıyaslanmıştır. Ardından 2 farklı EEG kanalları belirlenmiş ve EEG kanal çiftleri sınıflandırılmıştır. Sınıflandırmanın başarımları değerlendirilirken tüm sınıflandırıcılar için 4-parçalı çapraz-doğrulama kullanılmış ve sınıflandırıcıların performansları doğruluk yüzdeleri ile ölçülmüştür.

4.1.1. KNN Sınıflandırıcısı ile Sınıflandırma

KNN sınıflandırıcısı için Mahalanobis Uzaklığı kullanılmış ve k değeri 6 olacak şekilde seçilmiştir. Parametreler belirlenirken deneme yanılma yöntemine başvurulmuş ve en iyi sonuçlar bu parametreler ile elde edilmiştir. Tablo 4.1’de dört çıkış ve Tablo 4.2’de ise iki çıkış ile yapılan sınıflandırmanın doğruluk sonuçları verilmiştir.

Tablo 4.1. 4 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	YUPV Doğruluk (%)	YUNV Doğruluk (%)	DUPV Doğruluk (%)	DUNV Doğruluk (%)	Ortalama Doğruluk (%)
C3	%42,0	%50,0	%41,0	%58,0	%47,8
C4	%40,0	%42,0	%37,0	%35,0	%38,5
F3	%50,0	%38,0	%57,0	%40,0	%46,3
F4	%46,0	%40,0	%50,0	%48,0	%46,0
Fp1	%91,0	%69,0	%64,0	%66,0	%72,5
Fp2	%47,0	%55,0	%46,0	%39,0	%46,8
Ortalama	%52,7	%49,0	%49,2	%47,7	%49,6

Tablo 4.1’den de anlaşılacağı üzere en iyi sınıflandırma başarımı uyarılma-valans düzleminde Fp1 kanalı için elde edilmiş ve ortalama değer %72,5 olarak bulunmuştur. En başarılı performans ise %91,0 ile YUPV koordinatında gerçekleşmiştir.

Tablo 4.2. 2 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	Pozitif Doğruluk (%)	Negatif Doğruluk (%)	Ortalama Doğruluk (%)
C3	%68,0	%64,0	%66,0
C4	%59,0	%59,0	%59,0
F3	%61,0	%59,0	%60,0
F4	%62,0	%64,0	%63,0
Fp1	%77,0	%79,0	%78,0
Fp2	%60,0	%60,0	%60,0
Ortalama	%64,5	%64,2	%64,3

İki sınıflı yapılan sınıflandırmada pozitif-negatif duyguların ayırımını en iyi gerçekleştiren kanal Fp1 (%78) olarak elde edilmiştir. Fp1 kanalı pozitif duyguları %77 oranında sınıflandırırken, bu oran negatif duygular için artmış ve %79 olmuştur.

EEG kanal çiftleri belirlenirken birbirine en yakın ve en iyi ayrımı yapan kanal çiftleri üzerinde durulmuş ve kanallar Fp1/F4, C3/C4 ve Fp2/F3 olacak şekilde oluşturulmuştur. Tablo 4.3 ve Tablo 4.4’de EEG kanal çiftlerinin sınıflandırma performansları verilmiştir.

Tablo 4.3. 4 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	YUPV Doğruluk (%)	YUNV Doğruluk (%)	DUPV Doğruluk (%)	DUNV Doğruluk (%)	Ortalama Doğruluk (%)
Fp1/F4	%73,0	%62,0	%57,0	%56,0	%62,0
Fp2/F3	%56,0	%49,0	%58,0	%45,0	%52,0
C3/C4	%32,0	%57,0	%40,0	%39,0	%42,0
Ortalama	%53,7	%56,0	%51,7	%46,7	%52,0

Uyarılma-valans düzlemi için en iyi başarımlı sonucunu Fp1/F4 kanal çifti vermiş ve sonuç ortalama %62 olacak şekilde elde edilmiştir. Tabloya bakıldığında Fp1/F4 kanal çiftinin YUPV koordinatı için en yüksek değeri ürettiği (%73) gözlemlenmiştir.

Tablo 4.4. 2 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	Pozitif Doğruluk (%)	Negatif Doğruluk (%)	Ortalama Doğruluk (%)
Fp1/F4	%73,0	%73,0	%73,0
Fp2/F3	%67,0	%65,0	%66,0
C3/C4	%65,0	%62,0	%63,5
Ortalama	%68,3	%66,7	%67,5

Fp1/F4 kanalı aynı 4 sınıflı sistemde olduğu gibi en iyi başarımlı performansını (%73) sergilemiştir. Kanal çifti pozitif ve negatif duyguları aynı oranda (%73) sınıflandırmıştır.

Sonuç olarak KNN sınıflandırıcısının kullanılmasıyla en başarılı sonuç Fp1 kanalından elde edilmiş ve duygu ayrımında belirlenen özellikler ile bu kanalın diğer kanallara oranla daha etkili olduğu belirlenmiştir.

4.1.2. DVM Sınıflandırıcısı ile Sınıflandırma

DVM sınıflandırıcısı ile yapılan sınıflandırmanın başarımları Tablo 4.5 ve Tablo 4.6’da verilmiştir. Çalışma kapsamında KDVM (Karesel Destek Vektör Makineleri) kullanılmıştır.

Tablo 4.5. 4 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	YUPV Doğruluk (%)	YUNV Doğruluk (%)	DUPV Doğruluk (%)	DUNV Doğruluk (%)	Ortalama Doğruluk (%)
C3	%44,0	%54,0	%51,0	%56,0	%51,3
C4	%34,0	%49,0	%37,0	%40,0	%40,0
F3	%43,0	%36,0	%58,0	%44,0	%45,3
F4	%47,0	%42,0	%61,0	%50,0	%50,0
Fp1	%79,0	%70,0	%56,0	%59,0	%66,0
Fp2	%51,0	%46,0	%55,0	%50,0	%50,5
Ortalama	%50,0	%49,5	%53,0	%49,8	%51,0

DVM sınıflandırıcısıyla, uyarılma-valans düzleminde en iyi ayrım tıpkı KNN sınıflandırıcısının da olduğu gibi Fp1 kanalından elde edilmiş ve ortalama başarımlar %66 olarak bulunmuştur. Bu kanal Tablo 4.5’den anlaşılacağı üzere en iyi ayrımı YUPV düzleminde yapmış ve sonucu ortalama %79 olacak şekilde gözlemlenmiştir.

Tablo 4.6. 2 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	Pozitif Doğruluk (%)	Negatif Doğruluk (%)	Ortalama Doğruluk (%)
C3	%69,0	%70,0	%69,5
C4	%61,0	%60,0	%60,5
F3	%69,0	%67,0	%68,0
F4	%66,0	%68,0	%67,0
Fp1	%84,0	%76,0	%80,0
Fp2	%67,0	%66,0	%66,5
Ortalama	%69,3	%67,8	%68,6

İki sınıflı yapılan sınıflandırmada pozitif-negatif duyguların ayrımını en iyi gerçekleştiren kanal Fp1 (%80) olarak elde edilmiş ve tıpkı KNN sınıflandırmasında olduğu gibi en başarılı sonuç Fp1 EEG kanalından elde edilmiştir.

Fp1 kanalı pozitif duyguların ayırımını %84 olacak şekilde gerçekleştirmiştir. Bu oran negatif duygular için azalmış ve %76 olmuştur. Tıpkı KNN sınıflandırıcısında olduğu gibi DVM sınıflandırıcısında da EEG kanal çiftleri kullanılmış ve doğruluk başarımları Tablo 4.7’de dört sınıflı, Tablo 4.8’de iki sınıflı olacak şekilde verilmiştir.

Tablo 4.7. 4 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	YUPV Doğruluk (%)	YUNV Doğruluk (%)	DUPV Doğruluk (%)	DUNV Doğruluk (%)	Ortalama Doğruluk (%)
Fp1/F4	%80,0	%56,0	%58,0	%57,0	%62,8
Fp2/F3	%45,0	%46,0	%61,0	%50,0	%50,5
C3/C4	%44,0	%46,0	%44,0	%45,0	%44,8
Ortalama	%56,3	%49,3	%54,3	%50,7	%52,7

Uyarılma-valans düzlemi için en iyi başarımlar sonucunu Fp1/F4 kanal çifti vermiş ve sonuç ortalama %62,8 olacak şekilde elde edilmiştir. Tablo 4.7’den de anlaşılacağı üzere Fp1/F4 kanal çiftinin YUPV koordinatı için en yüksek değeri ürettiği (%80) gözlemlenmiştir.

Tablo 4.8. 2 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	Pozitif Doğruluk (%)	Negatif Doğruluk (%)	Ortalama Doğruluk (%)
Fp1/F4	%74,0	%71,0	%72,5
Fp2/F3	%67,0	%66,0	%66,5
C3/C4	%65,0	%63,0	%64,0
Ortalama	%68,7	%66,7	%67,7

Fp1/F4 kanalı aynı 4 sınıflı sistemde olduğu gibi en iyi performansı (%72,5) sergilemiştir. Pozitif duygular %74 oranında ayrıştırılırken, negatif duygular %71 oranında sınıflandırılmıştır.

DVM ile yapılan sınıflandırma ile elde edilen başarımlara bakıldığında tıpkı KNN ile yapılan sınıflandırma da olduğu gibi en iyi sonuçlar Fp1 kanalından elde edilmiştir. Uyarılma-valans düzleminde en yüksek performans her iki sınıflandırma için YUPV düzleminde görülmüştür. Son olarak EEG kanal çiftlerindeki başarımlar incelendiğinde Fp1/F4 kanal çiftinin iki sınıflandırma içinde en başarılı çift olduğu gözlemlenmiştir.

4.1.3. YSA Sınıflandırıcısı ile Sınıflandırma

Duygu ayırımı gerçekleştirilmek için modellenen ÇKİBYSA parametreleri giriş katmanında 50 nöron, ara katmanda 10 nöron ve çıkış katmanında 4 nöron olacak şekilde tasarlanmıştır. Aynı diğer sınıflandırıcılarda olduğu gibi 4-parçalı çapraz doğrulama kullanılmış ve başarımları 2 sınıflı ve 4 sınıflı olmak üzere Tablo 4.9 ve Tablo 4.10'da verilmiştir.

Tablo 4.9. 4 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	YUPV Doğruluk (%)	YUNV Doğruluk (%)	DUPV Doğruluk (%)	DUNV Doğruluk (%)	Ortalama Doğruluk (%)
C3	%75,0	%61,3	%55,0	%60,6	%63,0
C4	%66,9	%70,0	%71,9	%69,4	%69,6
F3	%66,9	%74,4	%73,1	%75,0	%72,4
F4	%80,6	%85,6	%86,9	%87,5	%85,2
Fp1	%68,1	%70,0	%73,8	%72,5	%71,1
Fp2	%58,1	%75,0	%68,8	%66,3	%67,1
Ortalama	%69,3	%72,7	%71,6	%71,9	%71,4

YSA ile yapılan sınıflandırma işleminin sonucunda en iyi başarımlar F4 (%85,2) kanalından elde edilmiştir. Bu sınıflandırma sonucunda en etkili kanalın diğer sınıflandırmalardaki gibi Fp1 olmadığı gözlemlenmiştir. F4 kanalı en iyi duygu ayırımı uyarılma-valans düzlemi için DUNV koordinatında (%87,5) gerçekleştirmiştir.

Tablo 4.10. 2 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	Pozitif Doğruluk (%)	Negatif Doğruluk (%)	Ortalama Doğruluk (%)
C3	%72,5	%71,3	%71,9
C4	%62,9	%68,1	%65,5
F3	%73,5	%74,4	%73,9
F4	%91,0	%91,3	%91,1
Fp1	%77,6	%78,2	%77,9
Fp2	%67,5	%69,7	%68,6
Ortalama	%74,1	%75,5	%74,8

YSA tıpkı 4 sınıflı ayırım işleminde olduğu gibi, iki sınıflıda da en iyi performansı F4 (%91,1) kanalında gerçekleştirmiştir.

Bu kanalda hem pozitif duyguların hem de negatif duyguların başarımları %90'ın üzerinde olacak şekilde bulunmuştur. Tek çıkış ile gerçekleştirilen bu sınıflandırmada, YSA modeli 50x10x1 olacak şekilde tasarlanmıştır.

Tablo 4.11 ve Tablo 4.12'de EEG kanal çiftlerine ait sınıflandırma başarımları verilmiştir. EEG kanal çiftleri için kullanılan YSA sisteminin topolojisi giriş katmanında 100 nöron, ara katmanda 10 nöron ve çıkış katmanında 4 nöron olacak şekilde belirlenmiştir.

Tablo 4.11. 4 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	YUPV Doğruluk (%)	YUNV Doğruluk (%)	DUPV Doğruluk (%)	DUNV Doğruluk (%)	Ortalama Doğruluk (%)
Fp1/F4	%75,6	%78,8	%75,0	%75,0	%76,1
Fp2/F3	%74,4	%74,4	%68,8	%73,1	%72,7
C3/C4	%74,4	%61,3	%74,4	%73,8	%71,0
Ortalama	%74,8	%71,5	%72,7	%74,0	%73,5

YSA ile yapılan sınıflandırmanın sonucunda Fp1/F4 kanalının tıpkı diğer sınıflandırma yöntemlerinde olduğu gibi en etkili kanal çifti olduğu gözlemlenmiştir. Fp1/F4 kanal çiftinin en iyi ayrımı YUNV koordinatında ortalama %78,8 oranında gerçekleştirdiği belirlenmiştir.

Tablo 4.12. 2 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	Pozitif Doğruluk (%)	Negatif Doğruluk (%)	Ortalama Doğruluk (%)
Fp1/F4	%78,2	%78,2	%78,2
Fp2/F3	%65,3	%66,9	%66,1
C3/C4	%63,2	%62,5	%62,9
Ortalama	%68,9	%69,2	%69,0

Fp1/F4 kanal çiftinin 2 sınıflı duygunun ayrımında en etkili kanal olduğu gözlemlenmiştir. Tüm sınıflandırmalara ait başarımları her bir EEG kanalı ve kanal çiftleri için 2 sınıflı ve 4 sınıflı olacak şekilde aşağıda Tablo 4.13 ve Tablo 4.14'te gösterilmiştir.

Tablo 4.13. EEG kanalları ile gerçekleştirilen tüm sınıflandırıcıların başarımlarının kıyaslanması

Sınıf Sayısı	KNN Doğruluk (%)	DVM Doğruluk (%)	YSA Doğruluk (%)
4	%49,6	%51,3	%71,4
2	%64,3	%68,6	%74,8

Tablo 4.13’de görüldüğü üzere her iki çıkış değeri için en iyi ortalama başarımların performansı YSA ile elde edilmiştir.

Tablo 4.14. EEG kanal çiftleri ile gerçekleştirilen tüm sınıflandırıcıların başarımlarının kıyaslanması

Sınıf Sayısı	KNN Doğruluk (%)	DVM Doğruluk (%)	YSA Doğruluk (%)
4	%52,0	%52,7	%73,5
2	%67,5	%67,7	%69,0

Aynı, farklı EEG kanallarında olduğu gibi EEG kanal çiftlerinde de YSA sınıflandırıcısının diğer sınıflandırıcılara göre daha iyi sonuç ürettiği gözlemlenmiştir. YSA sınıflandırıcısının diğer sınıflandırıcılardan daha iyi sonuç vermesinden dolayı, YSA topolojisi üzerinde bir takım iyileştirici denemeler yapılmıştır. Böylece, önceki YSA’da kullanılan parametreler değiştirilmiş ve yeni parametreler ile YSA sınıflandırıcısının başarımları değerlendirilmiştir. Modellenmiş olan yeni ÇKİBYSA parametreleri giriş katmanında 50 nöron, ara katmanda 10 nöron ve çıkış katmanında 2 nöron olacak şekilde değiştirilmiş ve sınıflandırmanın doğruluk değeri Tablo 4.15’de verilmiştir.

Tablo 4.15. 50x10x2 YSA modeli ile gerçekleştirilen sınıflandırmanın başarımlar değeri

EEG Kanalları	Pozitif Doğruluk (%)	Negatif Doğruluk (%)	Ortalama Doğruluk (%)
C3	%76,0	%92,2	%84,1
C4	%78,5	%89,7	%84,1
F3	%87,5	%91,9	%89,7
F4	%93,5	%95,2	%94,3
Fp1	%82,9	%82,5	%82,7
Fp2	%82,2	%79,7	%81,0
Fp1/F4	%86,6	%99,1	%92,8
Fp2/F3	%86,0	%86,0	%86,0
C3/C4	%91,3	%96,0	%93,6
Ortalama	%84,9	%90,3	%87,6

Tablo 4.15’den anlaşılacağı üzere modellenen 50x10x2 YSA ile yapılan sınıflandırma öncekine göre daha başarılı sonuçlar üretmiştir.

4.2. Taşınabilir EEG Cihazı ile Elde Edilen Bulgular

Bu kısımda taşınabilir EEG cihazı (EK-1) ile edilmiş olan verilerin başarımları değerlendirilmiştir. Bunun için temin edilen 14 kanallı EEG cihazı ile 25 farklı kişiden veriler elde edilmiştir. Verilerin elde edilmesi için görsel-işitsel uyaranlar kullanılmış ve deneklerden duygular bilgisayar oyunları aracılığıyla elde edilmiştir. Fırat Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulunun 26.10.2017 tarihinde verilen 14/26 Nolu kararıyla gönüllü deneklerden EEG işaretleri alınmıştır. Veriler toplanırken pozitif-negatif duygular üzerinde durulmuş ve bunun için 1 korku, 1 komedi, 1 sıkıcı ve 1 heyecanlı olmak üzere 4 farklı bilgisayar oyunu oynatılmıştır. Veriler toplam 25 denekten elde edilmiş ve herbir uyarının ardından deneklere öz değerlendirme formu doldurtulmuştur. Denekler bilgisayarın karşısına geçmiş ve kulaklık takmışlardır. Bu sayede hem görsel ve işitsel olarak oyuna odaklanmaları sağlanmış hem de dışarıdan gelebilecek, deneklerin konsantrasyonunu bozabilecek gürültülerin önüne geçilmiştir. Her denek her bir oyunu 5 dakika boyunca oynamış ve toplam 500 dakika olacak şekilde EEG sinyalleri elde edilmiştir.

Veriler elde edildikten sonra, Denklem 4.1’de gösterildiği üzere SDY (Sonsuz Dürtü Yanıtı) filtresi ile işaretler gürültülerden arındırılmış ve 3. Bölümde özellik çıkarım için veilen hesaplamaların tümü bu veriler içinde yapılmıştır.

$$s(n) = -\sum_{k=1}^N a(k)s(n-k) + \sum_{k=0}^M b(k)x(n-k) \quad (4.1)$$

Ön işlem için SDY filtresinden geçirilen veriler 3 farklı sınıflandırıcıyla sınıflandırılmış ve başarımları değerlendirilmiştir.

4.2.1. KNN Sınıflandırıcısı ile Sınıflandırma

Aynı DEAP veri setinde olduğu gibi taşınabilir cihaz ile elde edilen EEG sinyalleri KNN sınıflandırma algoritmaları kullanılarak sınıflandırılmış ve her bir EEG kanalının başarımları değerlendirilerek sonuçları kıyaslanmıştır. KNN sınıflandırıcısı için Mahalanobis Uzaklık ölçütü kullanılmış ve k en yakın komşu değeri 6 olacak şekilde sınıflandırıcı tasarlanmıştır. Tablo 4.16’da başvuru sınıflandırma işlemi için elde edilen başarımlar gösterilmiştir. 4 farklı çıktıya sahip olan değerler kıyaslanmış ve tablo üzerinde başarımları irdelenmiştir.

Tablo 4.16. 4 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	YUPV Doğruluk (%)	YUNV Doğruluk (%)	DUPV Doğruluk (%)	DUNV Doğruluk (%)	Ortalama Doğruluk (%)
AF3	%45,0	%37,0	%44,0	%42,0	%42,0
AF4	%52,0	%55,0	%53,0	%61,2	%55,3
F3	%34,0	%43,2	%36,0	%30,0	%35,8
F4	%42,0	%43,0	%41,0	%46,0	%43,0
F7	%42,0	%41,0	%49,0	%40,0	%43,0
F8	%53,0	%62,0	%53,0	%48,0	%54,0
FC5	%54,0	%44,0	%45,0	%45,0	%47,0
FC6	%34,0	%33,0	%34,0	%42,2	%35,8
O1	%51,0	%39,0	%42,0	%40,0	%43,0
O2	%43,0	%38,0	%35,0	%36,0	%38,0
P7	%46,0	%40,0	%38,0	%41,0	%41,3
P8	%39,0	%41,0	%40,0	%40,0	%40,0
T7	%38,0	%37,0	%38,0	%39,0	%38,0
T8	%50,0	%44,0	%42,0	%44,0	%45,0
Ortalama	%44,5	%42,4	%42,1	%42,2	%42,8

KNN ile yapılan sınıflandırma işleminin sonucunda en iyi başarımlar AF4 (%55,3) kanalından elde edilmiştir. Bu sınıflandırma sonucu ile elde edilen verilerin kafanın ön bölgesinde etkili olduğu gözlemlenmiştir. AF4 kanalı en iyi duygu ayrımını uyarılma-valans düzlemi için DUNV koordinatında (%61,2) gerçekleştirmiştir. Tablo 4.17’de pozitif-negatif duyguların ayrımına yönelik yapılan sınıflandırmanın başarımları verilmiştir. Bu sonuçlar ile hangi EEG kanalının pozitif duygu ya da negatif duygu üzerinde etkili olduğu bulunmaya çalışılmış ve tablo aracılığıyla performansları gözlemlenmiştir.

Tablo 4.17. 2 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	Pozitif Doğruluk (%)	Negatif Doğruluk (%)	Ortalama Doğruluk (%)
AF3	%59,0	%63,0	%61,0
AF4	%84,0	%66,0	%75,0
F3	%55,0	%63,0	%59,0
F4	%61,0	%71,0	%66,0
F7	%55,0	%79,0	%67,0
F8	%71,0	%79,0	%75,0
FC5	%80,0	%47,0	%63,5
FC6	%55,0	%80,0	%67,5
O1	%62,0	%67,0	%64,5
O2	%68,0	%61,0	%64,5
P7	%60,0	%61,0	%60,5
P8	%65,0	%81,0	%73,0
T7	%61,0	%61,0	%61,0
T8	%55,0	%73,0	%64,0
Ortalama	%63,6	%68,0	%65,8

Pozitif ve negatif duyguların ayrımında ise en iyi sonuç, KNN sınıflandırıcısı ile F8 ve AF4 kanallarından toplanmış ve başarımlar oranları %75 olacak şekilde değerlendirilmiştir. En iyi performans AF4 kanalı için pozitif duygudan elde edilmiştir (%84). Bu başarımlar F8 kanalında ise değişmiş ve en yüksek başarımlar oranı negatif duygudan %79 olacak şekilde görülmüştür.

4.2.2. DVM Sınıflandırıcısı ile Sınıflandırma

Aynı DEAP veri setinde olduğu gibi taşınabilir cihaz ile elde edilen EEG sinyalleri KDVM sınıflandırma algoritmaları kullanılarak sınıflandırılmış ve her bir EEG kanalının başarımları değerlendirilerek sonuçları kıyaslanmıştır.

Tablo 4.18’de uyarılma-valans düzlemi esas alınarak gerçekleştirilen sınıflandırma işleminin sonuçları verilmiştir. Bu sonuçlar doğrultusunda hangi EEG kanallarının duygu düzlemi üzerinde etkili olduğunun bulunması amaçlanmıştır.

Tablo 4.18. 4 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	YUPV Doğruluk (%)	YUNV Doğruluk (%)	DUPV Doğruluk (%)	DUNV Doğruluk (%)	Ortalama Doğruluk (%)
AF3	%52,0	%51,0	%56,0	%56,2	%53,8
AF4	%53,0	%58,0	%34,0	%55,0	%50,0
F3	%45,0	%44,0	%38,0	%33,0	%40,0
F4	%50,0	%48,0	%67,0	%49,0	%53,5
F7	%85,0	%67,0	%65,0	%61,0	%69,5
F8	%64,0	%65,0	%58,0	%63,0	%62,5
FC5	%28,0	%35,0	%43,2	%31,0	%34,3
FC6	%33,0	%35,2	%35,0	%32,0	%33,8
O1	%53,0	%48,0	%72,0	%48,0	%55,3
O2	%60,0	%54,0	%48,0	%52,0	%53,5
P7	%64,0	%75,0	%63,0	%62,0	%66,0
P8	%69,0	%69,0	%68,0	%73,2	%69,8
T7	%46,0	%41,0	%46,0	%53,0	%46,5
T8	%75,0	%96,0	%71,0	%72,0	%78,5
Ortalama	%55,5	%56,2	%54,6	%52,9	%54,8

DVM sınıflandırıcısı ile gerçekleştirilen sınıflandırma işleminde KNN sınıflandırmasından farklı olarak en yüksek performans T8 kanalından (%78,5) elde edilmiştir. Bu kanal en iyi duygu ayrımını YUNV düzleminde gerçekleştirmiş ve sınıflandırma başarımları bu düzlem için %96,0 olacak şekilde elde edilmiştir. Tablo 4.19’da pozitif ve negatif duyguların sınıflandırma performansı verilmiştir. Performans değerleri kıyaslanarak en etkili EEG kanalının bulunması amaçlanmıştır.

Tablo 4.19. 2 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	Pozitif Doğruluk (%)	Negatif Doğruluk (%)	Ortalama Doğruluk (%)
AF3	%77,0	%85,0	%81,0
AF4	%95,0	%80,0	%87,5
F3	%59,0	%66,0	%62,5
F4	%71,0	%72,0	%71,5
F7	%81,0	%86,0	%83,5
F8	%81,0	%79,0	%80,0
FC5	%65,0	%67,2	%66,1
FC6	%68,0	%67,0	%67,5
O1	%56,0	%58,0	%57,0
O2	%79,0	%60,0	%69,5
P7	%57,0	%61,0	%59,0
P8	%83,0	%78,0	%80,5
T7	%56,0	%73,0	%64,5
T8	%90,0	%71,0	%80,5
Ortalama	%72,7	%71,7	%72,2

İki çıkış ile gerçekleştirilen sınıflandırma işleminde en yüksek ayırım oranı %87,5 değeri ile AF4 kanalından elde edilmiştir. Bu kanalın başarımı aynı KNN sınıflandırıcısında olduğu gibi beynin ön tarafından elde edilen işaretlerin önemini göstermiştir. AF4 kanalı ile negatif duyguların ayırım işlemi %80 doğruluk oranında hesaplanmışken bu oran pozitif duygular için %95 olacak şekilde gözlemlenmiştir.

4.2.3. YSA Sınıflandırıcısı ile Sınıflandırma

YSA ile yapılan sınıflandırma işleminde ÇKİBYSA kullanılmış ve duyguların ayırımının yapılması amaçlanmıştır. Öncelikle kullanılacak YSA modeline karar verilmiş ve uyarılmalı valans düzleminde kullanılmak üzere YSA'nın parametreleri giriş katmanında 50 nöron, ara katmanda 10 nöron ve çıkış katmanında 4 nöron olacak şekilde belirlenmiştir. Bu parametreler pozitif-negatif duyguların ayrıştırılması işleminde ise 50x10x1 şeklinde güncellenmiştir. Bu çalışmada kullanılan tüm sınıflandırıcılarda olduğu gibi doğrulama için 4-parçalı çapraz doğrulama kullanılmıştır. Çıkış katmanında 4 nöron olacak şekilde gerçekleştirilen çalışmanın başarımları Tablo 4.20'de verilmişken, çıkış katmanında 1 nöron olacak şekilde gerçekleştirilen sınıflandırmanın performans değerleri Tablo 4.21'de belirtilmiştir.

Tablo 4.20. 4 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	YUPV Doğruluk (%)	YUNV Doğruluk (%)	DUPV Doğruluk (%)	DUNV Doğruluk (%)	Ortalama Doğruluk (%)
AF3	%77,0	%72,0	%78,0	%94,6	%80,4
AF4	%91,0	%73,0	%66,0	%70,0	%75,0
F3	%75,0	%77,0	%73,0	%75,0	%75,0
F4	%82,0	%80,0	%85,8	%81,0	%82,2
F7	%69,0	%66,0	%67,0	%83,6	%71,4
F8	%76,6	%70,0	%68,0	%71,0	%71,4
FC5	%72,0	%83,0	%74,0	%71,0	%75,0
FC6	%81,8	%73,0	%71,0	%69,0	%73,7
O1	%70,0	%80,8	%65,0	%69,0	%71,2
O2	%60,0	%64,0	%70,8	%64,0	%64,7
P7	%70,0	%66,0	%65,0	%79,0	%70,0
P8	%71,0	%69,0	%76,0	%72,0	%72,0
T7	%60,0	%61,0	%64,0	%75,0	%65,0
T8	%84,0	%78,0	%76,0	%78,0	%79,0
Ortalama	%74,2	%72,3	%71,4	%75,2	%73,3

Sınıflandırma işleminin sonucunda en yüksek başarımlar F4 kanalından elde edilmiş ve ortalama performans %82,2 olacak şekilde hesaplanmıştır. F4 kanalı için en yüksek değer %85,8 ile DUPV düzleminde gerçekleşmiştir. Tüm kanalların ortalama değerine bakıldığında ise en iyi sonucun DUNV düzleminde gerçekleştiği gözlemlenmiş ve ortalama başarımlar tüm kanallar için %75,2 şeklinde bulunmuştur. Tablo 4.21’de pozitif ve negatif duyguların ayırımına yönelik gerçekleştirilen sınıflandırmanın başarımları gösterilmiştir.

Tablo 4.21. 2 çıkış değeri ile elde edilen doğruluk sonuçları

EEG Kanalları	Pozitif Doğruluk (%)	Negatif Doğruluk (%)	Ortalama Doğruluk (%)
AF3	%80,0	%82,0	%81,0
AF4	%72,0	%78,0	%75,0
F3	%67,6	%61,0	%64,3
F4	%84,4	%82,0	%82,2
F7	%76,0	%81,2	%78,6
F8	%80,2	%77,0	%78,6
FC5	%77,0	%81,0	%79,0
FC6	%80,8	%72,0	%76,4
O1	%73,0	%74,0	%73,5
O2	%68,0	%72,2	%70,1
P7	%75,0	%67,0	%71,0
P8	%75,0	%71,0	%73,0
T7	%60,0	%62,0	%61,0
T8	%59,0	%69,0	%64,0
Ortalama	%73,4	%73,4	%73,4

Tıpkı 4 çıkışlı sınıflandırma sonucunda olduğu gibi en iyi performansı F4 (%82,2) EEG kanalı vermiştir. Tablo 4.21’de de görüldüğü üzere F4 kanalının pozitif duyguyu (%84,4) negatif duyguya (%82) göre daha iyi sınıflandırdığı gözlemlenmiştir. Sınıflandırmanın ortalama başarımı %73,4 olarak elde edilmiş ve bu başarım pozitif ve negatif duygular için eşit olacak şekilde hesaplanmıştır. Tablo 4.22’de kullanılan tüm sınıflandırma algoritmalarının başarımları kıyaslanmıştır. Anlaşıldığı üzere YSA sınıflandırıcısının diğer sınıflandırıcılardan üstün olduğu görülmektedir. Uyarılma-valans düzlemi için gerçekleştirilen sınıflandırma işleminde YSA diğer sınıflandırıcılara nazaran çok üstün bir başarım göstermiştir.

Bu üstünlük pozitif-negatif duyguların ayrımında azalmış ve tüm sınıflandırıcılar birbirine yakın performans sergilemiştir.

Tablo 4.22. EEG kanalları ile gerçekleştirilen tüm sınıflandırıcıların başarımlarının kıyaslanması

Sınıf Sayısı	KNN Doğruluk (%)	DVM Doğruluk (%)	YSA Doğruluk (%)
4	%42,8	%54,8	%73,3
2	%65,8	%72,2	%73,4

Tıpkı DEAP veri setinde olduğu gibi YSA sınıflandırıcısının üstün olması bu sınıflandırıcı üzerinde durulmasına neden olmuştur. YSA sınıflandırıcısının başarımının artırılması için YSA yeniden modellenmiş ve yeni modellenen sistemde tıpkı DEAP veri setinde olduğu gibi YSA’nın parametreleri 50x10x2 olacak şekilde değiştirilmiştir. Tablo 4.23’te tasarlanan yeni YSA’ya göre elde edilen başarımlar gösterilmiştir.

Tablo 4.23. 50x10x2 YSA modeli ile gerçekleştirilen sınıflandırmanın başarımlar değeri

EEG Kanalları	Pozitif Doğruluk (%)	Negatif Doğruluk (%)	Ortalama Doğruluk (%)
AF3	%81,0	%90,4	%85,7
AF4	%86,0	%87,4	%86,7
F3	%83,8	%74,0	%78,9
F4	%93,0	%92,4	%92,7
F7	%87,0	%80,0	%83,5
F8	%84,4	%84,0	%84,2
FC5	%81,8	%77,0	%79,4
FC6	%94,6	%75,0	%84,8
O1	%76,0	%82,0	%79,0
O2	%79,0	%87,4	%83,2
P7	%80,8	%77,0	%78,9
P8	%75,0	%79,0	%77,0
T7	%80,0	%70,0	%75,0
T8	%83,2	%75,0	%79,1
Ortalama	%83,2	%80,8	%82,0

Tablo 4.23'ten anlaşılacağı üzere en iyi başarımlar F4 kanalından elde edilmiş ve başarımlar oranı %92,7 olacak şekilde bulunmuştur. Bu kanalda pozitif duygunun ayırımı %93 oranında gerçekleşirken negatif duyguların ayırım oranı %92,4 olarak bulunmuştur. Tüm kanallar için ortalama sınıflandırma başarımlarını pozitif duygular için %83,2 ve negatif duygular için ise %80,8 olarak hesaplanmıştır.

Bu tez çalışmasında EEG sinyallerine dayalı duygu analizi gerçekleştirilmiştir. Tez kapsamında öncelikle duygu tahminine yönelik yapılan çalışmalar incelenmiş ve kullanılan yöntemler nedenleriyle beraber irdelenmiştir. Çalışmalarda kullanılan EEG veritabanına erişilmiş ve bu sayede önerilen metodun literatürdeki yerinin kıyaslanması amaçlanmıştır. Ayrıca, geliştirilen yöntem, bilgisayar oyunları ile uyarılan farklı deneklerden elde edilen EEG sinyaller üzerinde denenmiş ve yöntemin performansı değerlendirilmiştir. Özellik vektörünün elde edilme aşamasında bilgi ölçüm tekniklerine ve istatistiksel yöntemlere başvurulmuş ve sinyaller zaman-frekans alanında analiz edilmiştir. Sinyaller ilk olarak Daubechies dalgacık filtresi kullanılarak 4 seviye ayrıştırılmış ve 5 farklı alt sinyal elde edilmiştir. Ardından bahsi geçen yöntemler kullanılarak özellik uzayı oluşturulmuş ve 3 farklı sınıflandırıcı ile sınıflandırılarak duyguların ayırımı yapılmıştır.

Çalışmanın sonunda DEAP veriseti ile yapılan sınıflandırmada YSA sınıflandırıcısının başarılı olduğu gözlemlenmiş ve ortalama başarımlar pozitif – negatif duygular için %87,6 olarak bulunmuştur. Bilgisayar oyunları ile uyarılan deneklerden elde edilen sinyaller üzerinde yapılan sınıflandırma sonucunda ise en başarılı sınıflandırıcının YSA olduğu belirlenmiş ve sistemin doğruluk oranı %82 olarak bulunmuştur.

4.3. Öneriler

1. Çalışmada Daubechies dalgacık filtresi kullanılmış ve sonuçları irdelenmiştir. Bunun yerine başka bir dalgacık filtresi (Morlet, Symlet, vb.) kullanılabilir ve sonuçları gözlemlenebilir.
2. Sinyaller farklı bir seviyeye kadar ayrıştırılabilir veya farklı dereceden filtreler kullanılabilir. Bu tez çalışmasında sinyaller 4 seviye ayrılmış ve ayırım aşamasında 2.dereceden Daubechies kullanılmıştır.
3. Çalışmada ADD kullanılmış ve özellik vektörü dalgacık katsayılarından elde edilmiştir. Başka bir dalgacık dönüşüm yöntemi (HFD, AKA, vb.) kullanılabilir ve sistemin performansı değerlendirilebilir.
4. Özellik çıkarım aşamasında istatistiksel yöntemler içerisinde başka değerler kullanılabilir.
5. Farklı bilgi ölçüm yöntemlerine başvurulabilir.
6. Başka sınıflandırma metotları kullanılabilir ya da aynı sınıflandırıcıların farklı parametreleri kullanılarak yöntemin başarımlar oranı kıyaslanabilir.
7. Bilgisayar oyunları ile uyarılan deneklerden veri toplanması kısmında farklı bir uyaran kullanılabilir. Bu tez çalışmasında veriler elde edilirken işitsel – görsel uyaranlar kullanılmıştır. Bunun için bilgisayar oyunları oynatılmıştır. Farklı bir uyaran yöntemine (video klipleri, resimler, şarkılar vb.) başvurularak sinyallerin doğruluk oranı hesaplanabilir.
8. Denek sayısı artırılarak, denek sayısının sistemin performansı üzerinde etkisi araştırılabilir.
9. EEG kanal sayısı azaltılarak kanal sayısındaki değişimin sistemin başarımlarına etkisi gözlemlenebilir.
10. Farklı EEG kanal çiftleri seçilebilir. Bu tez çalışmasında kanallar, başarılı oldukları alana ve elektrotların yerleşim şekillerine göre seçilmiştir.

4.4. Yayınlar

Bu tez çalışması FÜBAP (Fırat Üniversitesi Bilimsel Araştırma Projesi) tarafından TEKF.17.21'nolu proje ile desteklenmiştir. Elde edilen sonuçlar, 1 adet makale [143] ve 2 adet bildiri [144,145] yayınına dönüştürülmüştür.



KAYNAKLAR

- [1]. **Pedraza-Hueso, M., Martin-Calzon, S., Diaz-Pernas, F. J. and Martinez-Zarzuela, M.**, 2015. Rehabilitation using kinect-based games and virtual reality, *Procedia Computer Science*, **75**, 161 – 168.
- [2]. **Jansdottir, J., Bertoni, R., Lawo, M., Montesano, A., Bowman, T. And Gabrielli, S.**, 2018. Serious Games for Arm Rehabilitation of Persons with Multiple Sclerosis. A randomized controlled pilot study, *Multiple Sclerosis and Related Disorders*, **19**, 25 – 29.
- [3]. **Cecilio, J., Andrade, J., Martins, P., Castelo-Branco, M. and Furtado, P.**, 2016. BCI framework based on games to teach people with cognitive and motor limitations, *Procedia Computer Science*, **83**, 47 – 81.
- [4]. **Wheatley, E., Termaat, J., Bloom, M.V., Freeman, J.W. and Huntington, M. K.**, 2011. Structured video gaming as affordable visual restoration therapy, *American Academy of Physical Medicine and Rehabilitation*, **3(9)**, 882 – 883.
- [5]. http://www.who.int/mental_health/prevention/suicide/suicideprevent/en/ Dünya Sağlık Örgütü, İntihar Verisi, 2017.
- [6]. <http://www.bbc.com/turkce/41281200> BBC News, İntihar oyunu Mavi Balina'dan kurtulanlar anlatıyor, (Erişim tarihi 2017).
- [7]. <http://www.hurriyet.com.tr/mavi-balina-oyunu-bursada-can-aldi-2-40749667> Hürriyet Gazetesi, Mavi Balina oyunu Bursa'da can aldı, (Erişim tarihi 2018).
- [8]. <http://www.hurriyet.com.tr/gundem/mavi-balina-oyunu-bu-kez-orduda-can-aldi-40640584> Hürriyet Gazetesi, Mavi Balina oyunu bu kez Ordu'da can aldı (Erişim tarihi 2017).
- [9]. **Khan, A., Moin, A., Fatima, H., Hussain, S.A. and Qadir, T.F.**, 2018. A whale of a challenge for pakistan and the world, *Asian Journal of Psychiatry*, **31**, 56 – 57.
- [10]. **Ferreira, A.M.S., Cavalcante, C.A.M.T., Fontes, C.H.O. and Marambio, J.E.S.**, 2018. Patterns recognition in energy management, *Comprehensive Energy Systems*, **5**, 537 – 580.
- [11]. **Junior, J.R.F., Koenigkam-Santos, M., Cipriano, F.E.G., Fabro, A.T. and Azevedo-Marques, P.M.**, 2018. Radiomics-based features for pattern recognition of lung cancer histopathology and metastases, *Computer Methods and Programs in Biomedicine*, **159**, 23 – 30.

- [12]. **Mortaz, E., Adcock, I.M., Abedini, A., Kiani, A., Kazempour-Dizaji, M., Movassaghi, M. and Garssen, J.,** 2017. The role of pattern recognition receptors in lung sarcoidosis, *European Journal of Pharmacology*, **808**, 44 – 48.
- [13]. **Zlokazov, E.Y., Starikov, R.S., Odinokov, S.B., Tsyganov, I.K., Talalaev, V.E. and Koluchkin, V.V.,** 2015. Specificity of correlation pattern recognition methods application in security holograms identity control apparatus, *Physics Procedia*, **73**, 308 – 312.
- [14]. **Çoşkun, M. ve İstanbullu, A.,** 2012. EEG işaretlerinin FFT ve dalgacık dönüşümü ile analizi, *XIV. Akademik Bilişim Konferansı Bildirileri*, 323 – 328.
- [15]. **Haşiloğlu, A.,** 2001. Dalgacık dönüşümü ve yapay sinir ağları ile döndürmeye duyarsız doku analizi ve sınıflandırma, *Turkish Journal of Engineering and Environmental Sciences*, **25**, 405 – 413.
- [16]. **Wessel, M.,** 2006. Pioneering research into brain computer interfaces, *Master of Science Thesis*, Delft University of Technology.
- [17]. <https://courses.lumenlearning.com/boundless-biology/chapter/neurons-and-glial-cells/> The Nervous System.
- [18]. **Dong, S., Chen, W., Wang, X., Zhang, S., Xu, K. and Zheng, X.,** 2016. Flexible ECoG electrode for implantation and neural signal recording applications, *Vacuum*, **140**, 96 – 100.
- [19]. **Koptelova, A., Bikhullina, R., Medvedovsky, M., Novikova, S., Golovtsev, A., Grinenko, O., Korsakova, M., Kozlova, A., Arkhipova, N., Vorobyev, A., Melikyan, A., Paetau, R., Stroganova, T. and Metsahonkala, L.,** 2017. Ictal and interictal MEG in pediatric patients with tuberous sclerosis and drug resistant epilepsy, *Epilepsy Research*, **140**, 162 – 165.
- [20]. **Hur, Y.J., Kim, A.J., Douglas, R. and Nordli, R.,** 2017. MRI supersedes ictal EEG when other presurgical data are concordant, *Seizure*, **53**, 18 – 22.
- [21]. **Mcdonald, C.R., Thesen, T., Carlson, C., Blumberg, M., Girard, H.M., Trongnetrpunya, A., Sherfey, J.S., Devinsky, O., Kuzniecky, R., Dolye, W.K., Cash, S.S., Leonard, M.K., Hagler, D.J., Dale, A.M. and Halgren, E.,** 2010. Multimodal imaging of repetition priming: Using fMRI, MEG and intracranial EEG to reveal spatiotemporal profiles of word processing, *NeuroImage*, **53**, 707 – 717.

- [22]. **Guerra, A.D., Ahmad, S., Avram, M., Belcari, N., Berneking, A., Biagi, L., Bisogni, M.G., Brandl, F., Cabello, J., Camarlinghi, N., Cerello, P., Choi, C.H., Coli, S., Colpo, S., Fleury, J., Gagliardi, V., Giraudo, G., Heereken, K., Kawohl, W., Kostou, T., Lefaucheur, J-L., Lerche, C., Loudos, G., Morrocchi, M., Muller, J., Mostafa, M., Neuner, I., Papadimitroulas, P., Pennazio, F., Rajkumar, R., Brambilla, C.R., Rivoire, J., Kops, E.R., Scheins, J., Schimpf, R., Shah, N.J., Sorg, C., Sportelli, G., Tosetti, M., Trincherio, R., Wyss, C. and Ziegler, S., 2018.** TRIMAGE: A dedicated trimodality (PET/MR/EEG) imaging tool for schizophrenia, *European Psychiatry*, **50**, 7 – 20.
- [23]. **Ruddy, K.L., Woolley, D.G., Mantini, D., Balsters, J.H., Enz, N. and Wenderoth, N., 2018.** Improving the quality of combined EEG – TMS neural recordings: introducing the coil spacer, *Journal of Neuroscience Methods*, **294**, 34 – 39.
- [24]. **Useche, J.N. and Bermudez, S., 2018.** Conventional computed tomography and magnetic resonance in brain concussion, *Neuroimaging Clinics*, **28(1)**, 15 – 29.
- [25]. **Arunkumar, N., Kumar, K.R. and Venkataraman, V., 2018.** Entropy features for focal EEG and non focal EEG, *Journal of Computational Science*.
- [26]. **Sood, M., Besson, P., Muthalib, M., Jindal, U., Perrey, S., Dutta, A. and Hayashibe, M., 2016.** NIRS-EEG joint imaging during transcranial direct current stimulation: Online parameter estimation with an autoregressive model, *Journal of Neuroscience Methods*, **274**, 71 – 80.
- [27]. **Buzsaki, G., Anastassiou, C.A. and Koch, C., 2012.** The origin of extracellular fields and currents – EEG, ECoG, LFP and spikes, *Nature Reviews*, **13**, 407 – 420.
- [28]. **Demitri, M., 2016.** Types of brain imaging techniques, PsychCentral, <https://psychcentral.com/lib/types-of-brain-imaging-techniques/> .
- [29]. **Caton, R., 2015.** The electric currents of the brain, *American Journal of EEG Technology*, **10(1)**, 12 – 14.
- [30]. **Ahmed, O.J. and Cash, S.S., 2013.** Finding synchrony in the desynchronized EEG: The history and interpretation of gamma rhythms, *Frontiers in Integrative Neuroscience*, **7(58)**, 1 – 7.
- [31]. **Alkaç, Ü.İ., (2009).** Beyin araştırmaları tarihinde bir gezinti: Elektronörofizyoloji, *Klinik Gelişim*, **22(3)**, 14 – 19.

- [32]. **Balasubramanian, G., Kanagasabai, A., Mohan, J. and Seshadri, N.P.G.,** 2018. Music induced emotion using wavelet packed decomposition: An EEG study, *Biomedical Signal Processing and Control*, **42**, 115 – 128.
- [33]. **Piryatinska, A., Woyczynski, W.A., Scher, M.S. and Loparo, K.A.,** 2012. Optimal channel selection for analysis of EEG-sleep patterns of neonates, *Computer Methods and Programs in Biomedicine*, **106**, 14 – 26.
- [34]. **Kocadagli ,O. and Langari, R.,** 2017. Classification of EEG signals for epileptic seizures using hybrid artificial neural networks based wavelet transforms and fuzzy relations, *Expert Systems With Applications*, **88**, 419 – 434.
- [35]. **Tandle, A., Jog, N., D’cunha, P. and Chheta, M.,** 2016. Classification of artefacts in EEG signal recordings and EOG artefact removal using EOG subtraction, *Communications on Applied Electronics (CAE)*, **4(1)**, 12 – 19.
- [36]. **Lahiri, R., Rakshit, P. and Konar, A.,** 2017. Evolutionary perspective for optimal selection of EEG electrodes and features, *Biomedical Signal Processing and Control*, **36**, 113 – 137.
- [37]. <https://www.emotiv.com/product-category/mobile-eeeg-headsets/#> Emotiv Products.
- [38]. <http://neurosky.com/biosensors/eeeg-sensor/biosensors/> NeuroSky Product.
- [39]. **Cooper, R., Osselton, J.W. and Shaw, J.C.,** 1970. EEG technology, *Journal of Psychosomatic Research*, **14(1)**, 112.
- [40]. **Jasper, H.H.,** 1958. The ten-twenty electrode system of the international federation, *Electroencephalography and Clinical Neurophysiology*, **10**, 371 – 375.
- [41]. **Petrushin, V.,** 1999. Emotion in speech: Recognition and application to call, *Proceedings of Artificial Neural Networks in Engineering Conference*, 7 – 10.
- [42]. **Black, M. and Yacoob, Y.,** 1997. Recognizing facial expressions in image sequences using local parameterized models of image motion, *International Journal of Computer Visions*, **25**, 23 – 48.
- [43]. **Pan, J., Li, Y. and Wang, J.,** 2016. An EEG-based brain-computer interface for emotion recognition, *International Joint Conference on Neural Networks (IJCNN)*, 2063 – 2067.
- [44]. **Koelstra, S., Mühl, C. and Soleymani, M.,** 2012. DEAP: A database for emotion analysis using physiological signals, *IEEE Transactions on Affective Computing*, **3(1)**, 18 – 31.

- [45]. **Wichakam, I. and Vateekul, P.**, 2014. An evaluation of feature extraction in EEG-based emotion prediction with support vector machines, *11 International Joint Conference on Computer Science and Software Engineering*, 106 – 110.
- [46]. **Ekman, P.**, 1992. An argument for basic emotions, *Cognition and Emotion*, **6(3/4)**, 169 – 200.
- [47]. **Shahnaz, C., Masud, S.B. and Hasan, S.M.S.**, 2016. Emotion recognition based on wavelet analysis of empirical mode decomposed EEG signals responsive to music videos, *IEEE Region 10 Conference (TENCON)*, 424 – 427.
- [48]. **Russell, J.A.**, 2003. Core affect and the psychological construction of emotion, *Psychological Review*, **110(1)**, 145 – 172.
- [49]. **Plutchik, R.**, 2001. The nature of emotions human emotions, *American Scientist*, **89(4)**, 344 – 350.
- [50]. **Russel, J.A.**, 1991. Culture and the categorization of emotions, *Psychological Bulletin*, **110**, 425 – 450.
- [51]. **Lang, P.J., Bradley, M.M. and Cuthbert, B.N.**, 1997. International affective picture system (IAPS): Technical manual and affective ratings, *NIMH Center for the Study of Emotion and Attention*.
- [52]. **Redondo, J., Fraga, I., Padron, I. and Pineiro, A.**, 2008. Affective ratings of sound stimuli, *Behaviour Research Methods*, **40(3)**, 784 – 790.
- [53]. **Sarıkaya, M.A. ve İnce, G.**, 2017. Tek elektrotlu cihaz ile EEG sinyallerinden duygu tanıma, *25th Signal Processing and Communications Applications Conference (SIU)*.
- [54]. **Liu, Y.H., Cheng, W.T., Hsiao, Y.T., Wu, C.T., and Jeng, M.D.**, 2014. EEG-based emotion recognition based on kernel fisher's discriminant analysis and spectral powers, *IEEE International Conference on Systems, Man, and Cybernetics*, 5 – 8.
- [55]. **Lahane, P., and Sangaiah, A. K.**, 2015. An approach to EEG based emotion recognition and classification using kernel density estimation, *Procedia Computer Science*, **48**, 574 – 581.
- [56]. **Paul, S., Mazumder, A., Ghosh, P., Tibarewala, D.N., and Vimalarani, G.**, 2015. EEG based emotion recognition system using MFDFA as feature extractor, *International Conference on Robotics, Automation, Control and Embedded Systems (RACE)*.

- [57]. **Tabanfar, Z., Yousefipoor, F., Firoozabadi, M., and Khodakarami, Z.,** 2016. Recognition of two emotional states of joy and sadness using phase lag index and SVM classifier, *23rd Iranian Conference on Biomedical Engineering and 1st International Iranian Conference on Biomedical Engineering (ICBME)*.
- [58]. **Javaid, M.M., Yousaf, M.A., Sheikh, Q.Z., Awais, M.M, Saleem, S., and Khalid, M.,** 2015. Real-time EEG-based human emotion recognition, *Neural Information Processing*, 182 – 190.
- [59]. **Krisnandhika, B., Faqih, A., Purnamasari, P.D., and Kusumoputro B.,** 2017. Emotion recognition system based on EEG signals using relative wavelet energy features and a modified radial basis function neural networks, *International Conference on Consumer Electronics and Devices*, 50 – 54.
- [60]. **Turnip, A., Simbolon, A.I., Amri, M.F., Sihombing, P., Setiadi, R. H., and Mulyana, E.,** 2017. Backpropagation neural networks training for EEG-SSVEP classification of emotion recognition, *Internetworking Indonesia Journal*, **9(1)**, 53 – 57.
- [61]. **Michalopoulos, K., and Bourbakis, N.,** 2017. Application of multiscale entropy on EEG signals for emotion detection, *IEEE EMBS International Conference on Biomedical & Health Informatics – BHI*, 341 – 344.
- [62]. **Patil, A., Deshmukh, C., and Panat, A.R.,** 2016. Feature extraction of EEG for emotion recognition using Hjorth features and higher order crossings, *Conference on Advances in Signal Processing – CASP*, 429 – 434.
- [63]. **Zhuang, N., Zeng, Y., Tong, L., Zhang, C., Zhang, H., and Yan, B.,** 2017. Emotion recognition from EEG signals using multidimensional information in EMD domain, *BioMed Research Article*.
- [64]. **Ghare, P.S., and Paithane, A.N.,** 2016. Human emotion recognition using non linear and non stationary EEG signal, *International Conference on Automatic Control and Dynamic Optimization Techniques – ICACDOT*, 1013 – 1016.
- [65]. **Mehmood, R.M., and Lee, H.J.,** 2016. Emotion recognition from EEG brain signals based on particle swarm optimization and genetic search, *IEEE International Conference on Multimedia & Expo Workshops – ICMEW*.

- [66]. **Gomez, A., Quintero, L., Lopez, N., Castro, J., Villa, L., and Mejia, G.,** 2016. An approach to emotion recognition in single-channel EEG signals using stationary wavelet transform, *VII Latin American Congress on Biomedical Engineering – CLAIB*, 654 – 657.
- [67]. **Wang, H., Zhang, Y., Waytowich, N.R., Krusienski, J., Zhou, G., Jin, J., Wang, X., and Cichocki, A.,** 2015. Discriminative feature extraction via multivariate linear regression for SSVEP-based BCI, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **24(5)**, 532 – 541.
- [68]. **Leeb, R., and Pfurtscheller, G.,** 2004. Walking through a virtual city by thought, *Proceedings of the 26th Annual International Conference of the IEEE EMBS*, 4503 – 4506.
- [69]. **Pfurtscheller, G., Leeb, R., Keinrath, C., Friedman, D., Neuper, C., Guger, C., and Slater, M.,** 2006. Walking from thought, *Brain Research* 1071, 145 – 152.
- [70]. **Pattnaik, P. K., and Sarraf, J.,** 2018. Brain computer interface issues on hand movement, *Journal of King Saud University – Computer and Information Sciences*, **30**, 18 – 24.
- [71]. **Bousetta, R., Ouakouak, I.E., Gharbi, M., and Regragui, F.,** 2018. EEG based brain computer interface for controlling a robot arm movement through thought, *Innovation and Research in Biomedical Engineering – IRBM*, **39(2)**, 129 – 135.
- [72]. **Farwell, L.A., and Donchin, E.,** 1988. Talking off the top of your head: Toward a mental prosthesis utilizing event-related brain potentials, *Electroencephalography and Clinical Neurophysiology*, **70**, 510 – 523.
- [73]. **Wolpaw, J.R., McFarland, D.J., Neat, G.W., and Forneris, C. A.,** 1991. An EEG-based brain-computer interface for cursor control, *Electroencephalography and Clinical Neurophysiology*, **78**, 252 – 259.
- [74]. **Pfurtscheller, G., and McFarland, D.,** 2012. BCIs that use sensorimotor rhythms, *Brain Computer Interfaces: Principles and Practice*, 227 – 240.
- [75]. **Iacoviello, D., Petracca, A., Spezialetti, M., and Placidi, G.,** 2015. A real-time classification algorithm for EEG-based BCI driven by self-induced emotions, *Computer Methods and Programs in Biomedicine*, **122(3)**, 293 – 303.
- [76]. **Atkinson, J., and Campos, D.,** 2016. Improving BCI-based emotion recognition by combining EEG feature selection and kernel classifiers, *Expert Systems with Applications*, **47**, 35 – 41.

- [77]. **Rached, T. S., and Perkusich, A.,** 2013. Emotion recognition based on brain-computer interface systems, *Brain-Computer Interface Systems*, 253 – 270.
- [78]. **Ripley, B.D.,** 1996. Pattern recognition via neural networks, United Kingdom, *Cambridge University Press*.
- [79]. **Sajedi, H.,** 2016. Handwriting recognition of digits, signs, and numerical strings in Persian, *Computer and Electrical Engineering*, **49**, 52 – 65.
- [80]. **Naseem, I., Aleem, A., Togneri, R., and Bennamoun, M.,** 2016. Iris recognition using class-specific dictionaries, *Computer & Electrical Engineering*, **62**, 178 – 193.
- [81]. **Panwar, R., Goyal, K., Pandey, N., and Khanna, N.,** 2014. Imaging system for classification of local flora of Uttarakhand Region, *International Conference on Power, Control and Embedded Systems – ICPCES*.
- [82]. **Rizvi, S.T.H., Patti, D., Björklund, T., Cabodi, G., and Francini, G.,** 2017. Deep classifiers- based license plate detection, localization and recognition on GPU-powered mobile platform, *Future Internet*, **9(4)**, 66 – 77.
- [83]. **Karlık, B., ve Hayta, Ş.B.,** 2014. Comparison machine learning algorithms for recognition of epileptic seizures in EEG, *IWBBIO*, 1 – 12.
- [84]. **Türkoğlu, İ.,** 1996. Yapay sinir ağları ile nesne tanıma, *Yüksek Lisans Tezi*, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.
- [85]. **Hamad, A., Hassanien, A.E., Houssein, E.H., and Fahmy, A.A.,** 2016. Feature extraction of epilepsy EEG using discrete wavelet transform, *12th International Computer Engineering Conference*, 190 – 195.
- [86]. **Salem, O., Naseem, A., and Mehaoua, A.,** 2014. Epileptic seizure detection from EEG signal using discrete wavelet transform and ant colony classifier, *IEEE International Conference on Communications*, 3529 – 3534.
- [87]. **Sartoretto, F., and Ermani, M.,** 1999. Automatic detection of epileptiform activity by single-level wavelet analysis, *Clinical Neurophysiology*, **110**, 239 – 249.
- [88]. **Misiti, M., Misiti, Y., Oppenheim, G., and Poggi, J.M.,** 2009. Wavelet toolbox 4 User's Guide, *The MathWorks*.
- [89]. **Guo, L., Seoane, J.A., Rivero, D., and Pazos, A.,** 2009. Classification of EEG signals using relative wavelet energy and artificial neural networks, *Proceedings of the first ACM/SIGEVO Summit on Genetic and Evolutionary Computation*, 177 – 184.

- [90]. **Zainuddin, Z., Huong, L.K., and Pauline, O.,** 2013. Reliable epileptic seizure detection using an improved wavelet neural network, *Australasian Medical Journal*, **6(5)**, 308 – 314.
- [91]. **Cheng, J., and Liu, Guangyuan,** 2014. Detrended fluctuation analysis based on the affective EEG, *Journal of Fiber Bioengineering and Informatics*, **7(1)**, 91 – 102.
- [92]. **Ning, X., Xu, Y., Wang, J, and Ma, X.,** 2005. Approximate entropy analysis of short-term HFECG based on wave mode, *Physica A*, **346**, 475 – 483.
- [93]. **Zhang, Q., Zhou, Y., Singh, V.P., and Chen, Y.D.,** 2011. Comparison of detrending methods for fluctuation analysis in hydrology, *Journal of Hydrology*, **400(1-2)**, 121 – 132.
- [94]. **Golinska, A.K.,** 2012. Detrended fluctuation analysis (DFA) in biomedical signal processing: Selected examples, *Studies in Logic, Grammar and Rhetoric*, **29(42)**, 107 – 115.
- [95]. **Sanyal, S., Banerjee, A., Pratihari, R., Maity, A.K., Dey, S., Agrawal, V., Sengupta, R., and Ghosh, D.,** 2015. Detrended fluctuation and power spectral analysis of alpha and delta EEG brain rhythms to study music elicited emotion, *International Conference on Signal Processing, Computing and Control – ISPCC*, 205 – 210.
- [96]. **Hardstone, R., Poil, S.S., Schiavone, G., Jansen, R., Nikulin, V.V., Mansvelder, H.D., and Hansen, K.L.,** 2012. Detrended fluctuation analysis: A scale-free view on neuronal oscillations, *Frontiers in Physiology*, **3**.
- [97]. **Hjorth, B.,** 1970. EEG analysis based on time domain properties, *Electroencephalography and Clinical Neurophysiology*, **29(3)**, 306 – 310.
- [98]. **Oh, S.H., Lee, Y.R., and Kim, H.N.,** 2014. A novel EEG feature extraction method using hjorth parameter, *International Journal of Electronics and Electrical Engineering*, **2(2)**, 106 – 110.
- [99]. **Li, T., and Zhou, M.,** 2016. ECG classification using wavelet packet entropy and random forests, *Entropy* 2016, **18(8)**, 1 – 16.
- [100]. **Aydin, S., Saraoğlu, H.M., and Kara, S.,** 2009. Log energy entropy-based EEG classification with multilayer neural networks in seizure, *Annals of Biomedical Engineering*, **37(12)**, 2626 – 2630.
- [101]. **Coifman, R.R., and Wickerhauser, M.V.,** 1992. Entropy-based algorithms for best basis selection, *IEEE Transactions on Information Theory*, **38(2)**, 713 – 718.

- [102]. **Shannon, C.E.**, 1948. A mathematical theory of communication, *The Bell System Technical Journal*, **27**, 379 – 423.
- [103]. **Richman, J.S., and Moorman, J.R.**, 2000. Physiological time-series analysis using approximate entropy and sample entropy, *American Journal of Physiology: Heart and Circulatory Physiology*, **278(6)**, 2039 – 2049.
- [104]. **Liu, Q., Chen, Y.F., Fan, S.Z., Abbod, M.F., and Shieh, J.S.**, 2015. EEG signals analysis using multiscale entropy for depth of anesthesia monitoring during surgery through artificial neural networks, *Computational and Mathematical Methods in Medicine*, **2015**.
- [105]. **Costa, M., Goldberger, A.L., and Peng, C.K.**, 2005. Multiscale entropy analysis of biological signals, *Physical Review E*, **71**, 021906-1 – 021906-18.
- [106]. **Walker, H.M.**, 1930. Studies in the history of statistical method, *Isis*, **13(2)**, 382 – 383.
- [107]. **Alakuş, T.B., ve Türkoğlu, İ.**, 2017. Yapay sinir ağları kullanılarak epilepsi nöbeti öncesinin tahmin edilmesi, *8th International Advanced Technologies Symposium – IATS*, 510 – 516.
- [108]. **Mitchell, T.M.**, 1997. Machine learning, *McGraw-Hill Series in Computer Science*.
- [109]. **Übeyli, E.D., ve Güler, İ.**, 2004. Dalgacık dönüşümü ile EEG işaretlerinden çıkarılan öznitelik vektörleri üzerinde istatistiksel işlemlerin gerçekleştirilmesi, *Elektrik, Elektronik ve Bilgisayar Sempozyumu*, 230 – 234.
- [110]. **Shen, C.P., Chan, C.M., Lin, F.S., Chiu, M.J., Lin, J.W., Kao, J.H., Chen, C.P., and Lai, F.**, 2011. Epileptic seizure detection for multichannel EEG signals with support vector machines, *11th IEEE International Conference on Bioinformatics and Bioengineering*, 39 – 43.
- [111]. **Hassan, A.R., and Bhuiyan, M.I.H.**, 2016. A decision support system for automatic sleep sataging from EEG signals using tunable Q-factor wavelet transform and spectral features, *Journal of Neuroscience Methods*, **271**, 107 – 118.
- [112]. **Ravindran, R.M.**, 2014. Classification of human emotions from EEG signals using filtering and ANFIS classifier, *2nd International Conference on Current Trends in Engineering and Technology – ICCTET*, 113 – 119.
- [113]. **Taşçı, E., ve Onan, A.**, 2016. K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi, *Akademik Bilişim Konferansı*.


- [114]. **Vapnik, V.N.**, 2000. The nature of statistical learning theory, *Information Science and Statistics*.
- [115]. **Shigeo, A.**, 2010. Support vector machines for pattern classification, *Advances in Computer Vision and Pattern Recognition 2nd Edition*.
- [116]. **Soman, K.P., Loganathan, R., and Ajay, V.**, 2009. Machine learning with SVM and other kernel methods, *PHI Learning Pvt. Ltd.*
- [117]. **Ayhan, S., ve Erdoğan, Ş.**, 2014. Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi, *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, **9(1)**, 175 – 198.
- [118]. **Gunn, S.R.**, 1998. Support vector machines for classification and regression, *University of Southampton, Faculty of Engineering, Science and Mathematics, School of Electronics and Computer Science*, 1 – 66.
- [119]. **Burges, C.J.C.**, 1998. A tutorial on support vector machines for pattern recognition, *Data Mining and Knowledge Discovery*, **2(2)**, 121 – 167.
- [120]. **Li, S., Li, H., Li, M., Shyr, Y., Xie, L., and Li, Y.**, 2009. Improved prediction of lysine acetylation by support vector machines, *Protein & Peptide Letters*, **16**, 977 – 983.
- [121]. **Cortes, C., and Vapnik, V.**, 1995. Support-vector networks, *Machine Learning*, **20**, 273 – 297.
- [122]. **Katagiri, S., and Abe, S.**, 2006. Incremental training of support vector machines using hyperspheres, *Pattern Recognition Letters*, **27**, 1495 – 1507.
- [123]. **Bulut, S., ve Günlü, A.**, 2016. Arazi kullanım sınıfları için farklı kontrollü sınıflandırma algoritmalarının karşılaştırılması, *Kastamonu Üniversitesi Orman Fakültesi Dergisi*, **16(2)**, 528 – 535.
- [124]. **Üstüner, M., Şanlı, F.B., Balçık, F.B., ve Esetlili, M.T.**, 2013. Destek vektör makineleri tekniği ile sınıflandırma: Rapideye örneği, *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VII. Teknik Sempozyumu – TUFUAB*.
- [125]. **Öztemel, E.**, 2012. Yapay sinir ağları, *Papatya Yayıncılık Eğitim Bilgisayar Sis. San. ve Tic. 3.Basım*.
- [126]. **Manngard, M., Kronqvist, J., and Böling, J.M.**, 2018. Structural learning in artificial neural networks using sparse optimization, *Neurocomputing*, **272**, 660 – 667.

- [127]. **Verpoort, P.C., MacDonald, P., and Conduit, G.J.**, 2018. Materials data validation and imputation with an artificial neural network, *Computational Materials Science*, **147**, 176 – 185.
- [128]. **Zhi, L.H., Hu, P., Chen, L.X., and Zhao, G.**, 2018. Viscosity prediction for six pure refrigerants using different artificial neural networks, *International Journal of Refrigeration*, **88**, 432 – 440.
- [129]. **Tavana, M., Abtahi, A.R., Caprio, D.D., and Poortarigh, M.**, 2018. An artificial neural network and bayesian network model for liquidity risk assessment in banking, *Neurocomputing*, **275**, 2525 – 2554.
- [130]. **Anderson, C.W., and Sijercic, Z.**, 1996. Classification of EEG signals from four subjects during five mental tasks, *Proceedings of the Conference on Engineering Applications in Neural Networks – EANN*, 407 – 414.
- [131]. **Türkoğlu, İ.**, 2002. Durağan olmayan işaretler için zaman-frekans entropilerine dayalı akıllı örüntü tanıma, *Doktora Tezi*, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.
- [132]. **Toraman, S.**, 2016. Kızılötesi spektroskopisi kullanılarak kan örneklerinden kolon kanserine yönelik özellik çıkarımı, *Doktora Tezi*, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.
- [133]. **Carpenter, G.A., and Grossberg, S.**, 1987. A massively parallel architecture for a self-organizing neural pattern recognition machine, *Computer Vision, Graphics, and Image Processing*, **37**, 54 – 115.
- [134]. **Kohonen, T.**, 1989. Self-organization and associative memory, Springer Series in Information Sciences.
- [135]. **Hush, D.R., and Horne, B.G.**, 1993. Progress in supervised neural networks: What's new since Lippmann, *IEEE Signal Processing Magazine*, 8 – 39.
- [136]. **Kohonen, T.**, 1988. An introduction to neural computing, *Neural Networks*, **1(1)**, 3 – 16.
- [137]. **Specht, D.F.**, 1990. Probabilistic neural networks, *Neural Networks*, **3(1)**, 109 – 118.
- [138]. **Moody, J., and Darken, C.J.**, 1989. Fast learning in networks of locally-tuned processing units, *Neural Computation*, **1(2)**, 281 – 294.
- [139]. **Kutlu, F.**, 2014. Melez sınıflandırma yaklaşımı ile EEG işaretlerinden epileptik dönemlerin algılanması, *Yüksek Lisans Tezi*, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon.

- [140]. **Duda, R.O., Hart, P.E., and Stork, D.G.,** 2000. *Pattern Classification 2nd Edition*.
- [141]. **Millan, J.R., and Mourino, J.,** 2003. Asynchronous BCI and local neural classifiers: An overview of the adaptive brain interface project, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **11(2)**, 159 – 161.
- [142]. **Culioli, J., and Protopopescu, V.,** 1990. Neural network models for linear programming, *International Joint Conference on Neural Networks*, **1**, 293 – 296.
- [143]. **Alakuş, T.B. ve Türkoğlu, İ.,** 2018. EEG tabanlı duygu analizi sistemleri, *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, **11(1)**, 26 – 39.
- [144]. **Alakuş, T.B. ve Türkoğlu, İ.,** 2018. Determination of effective EEG channels in recognition of positive-negative emotions by applying wavelet decomposition and supportt vector machines, *Abstract Proceedings of International Congress on Engineering and Life Science – ICELIS*, 215.
- [145]. **Alakuş, T.B. ve Türkoğlu, İ.,** 2018. Determination of accuracies from different wavelet methods in emotion estimation based on EEG signals by applying KNN classifier, *3rd International Conference on Engineering Technology and Applied Sciences*, **accepted**.

EKLER

Ek – 1: Taşınabilir EEG cihazı hakkında bilgiler ve kanallarının gösterilmesi.



Şekil Ek-1: Elektrotların yerleşim bölgesi

Tablo Ek-1: EEG cihazı hakkında teknik bilgiler

EEG Sensor Sayısı	16 (14 + 2 referans elektrot)
Bağlantı Şekli	USB
Örnekleme Metodu	Ardışık örnekleme
Pil Ömrü	12 saate kadar
İşletim Sistemi	Windows, MAC, IOS, Android
Bant Genişliği	0.16 – 43 Hz
Garanti	24 ay



Ek - 2: Etik kurulu onayı belgesi.

Evrak Tarih ve Sayısı: 31/10/2017-228250

T.C.



FIRAT ÜNİVERSİTESİ REKTÖRLÜĞÜ

Girişimsel Olmayan Araştırmalar Etik Kurulu

Sayı :97132852/050.01.04/

Konu :Prof. Dr. İbrahim TÜRKOĞLU(Yük. Lis. Öğr. Talha Burak ALAKUŞ)

YAZILIM MÜHENDİSLİĞİ BÖLÜMÜNE

İlgi :26/09/2017 tarihli, 221373 sayılı ve "Burak Talha ALAKUŞ" konulu yazı

Bölümünüz Öğretim Üyesi Prof. Dr. İbrahim TÜRKOĞLU yönetiminde, Yük. Lis. Öğr. Talha Burak ALAKUŞ'a ait "EEG Verilerinden İşaret İşleme ve Sınıflandırma Teknikleri Kullanılarak Duygu Tahmini" konulu çalışma ile ilgili Etik Kurul Kararı ekte sunulmuştur.

Bilgilerinizi ve gereğini rica ederim.

e-imzalıdır.
Prof. Dr. Mustafa KAPLAN
Kurul Başkanı

Not : Araştırmacıların TÜBİTAK'a yapılacak başvurular için, tüm üyelerin ıslak imzalarının bulunduğu etik kurul kararını talep etmeleri gerekmektedir.

EK :
Etik Kurul Kararı 1(bir) sayfa

Firat Üniversitesi Rektörlüğü 23119 ELAZIĞ/TÜRKİYE

Tel: 0 (424) 237 00 00

E-Posta: :

halklaileiskiler@firat.edu.tr

Faks: 0 424 2122717

Elektronik e-<http://www.firat.edu.tr>

Ayrıntılı bilgi için irtibat : Teslime ÖZKILIÇ

Bu belge 5070 sayılı Elektronik İmza Kanununun 5. Maddesi gereğince güvenli elektronik imza ile imzalanmıştır.

T.C.
FIRAT ÜNİVERSİTESİ
Girişimsel Olmayan Araştırmalar Etik Kurulu Başkanlığı

ETİK KURUL KARARI

TOPLANTI TARİHİ	TOPLANTI SAYISI	KARAR NO	ÇALIŞMACININ ADI SOYADI
26.10.2017	14	26	Prof. Dr. İbrahim TÜRKOĞLU

KARAR

“EEG Verilerinden İşaret İşleme ve Sınıflandırma Teknikleri Kullanılarak Duygu Tahmini” konulu çalışma etik kurulumuzda görüşülmüş olup; çalışmanın etik kurallara uygun olduğuna oybirliğiyle karar verilmiştir.

Prof. Dr. Mustafa KAPLAN (Başkan)			
Prof. Dr. Demet ÇİÇEK (Üye)	İmza	Prof. Dr. Figen DEVECİ (Üye)	İmza
Prof. Dr. Erdal TAŞKIN (Üye)	İmza	Prof. Dr. Nuri GÖMLEKSİZ (Üye)	Bulunmadı
Doç. Dr. Funda GÜLCÜ BULMUŞ (Üye)	İmza	Doç. Dr. Süleyman İLHAN (Üye)	İmza
Doç. Dr. İrfan EMRE (Üye)	Bulunmadı	Doç. Dr. Sebahattin DEVECİOĞLU (Üye)	Bulunmadı
Doç. Dr. Özge HANAY (Üye)	İmza	Doç. Dr. Taner YILDIRIM (Üye)	İmza
Yrd. Doç. Dr. Nurhan HALİSDEMİR (Üye)	İmza	Yrd. Doç. Dr. Mehmet TUZCU (Üye)	İmza

ÖZGEÇMİŞ

Talha Burak ALAKUŞ 1991 yılında Samsun’da doğdu. 1998-2009 yılları arasında eğitim ve öğretimini Samsun’da tamamlayarak 2009 yılında Samsun 19 Mayıs Lisesi’nden mezun oldu. 2010 yılında İzmir Ekonomi Üniversitesi Yazılım Mühendisliği’ni kazandı. 2015 yılında üniversiteden bölüm 5.si olarak mezun oldu ve 2016 yılında ÖYP ile Kırklareli Üniversitesi Mühendislik Fakültesi Yazılım Mühendisliği Bölümü’nde Araştırma Görevlisi olarak işe başladı. Ardından lisansüstü eğitimine başlamak ve devam etmek için Fırat Üniversitesi Yazılım Mühendisliği Anabilim Dalında yüksek lisans yapmaya hak kazandı.

