

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**İMLEÇ HAREKETİNİN HAYALİ SIRASINDA KAYDEDİLMİŞ EEG
SİNYALLERİNİN SINIFLANDIRILMASINI KOLAYLAŞTIRMAK AMACIYLA
YENİ BİR DÖNÜŞÜM YÖNTEMİ**

YÜKSEK LİSANS TEZİ

Bilgisayar Müh. Bahar HATİPOĞLU

**OCAK 2017
TRABZON**

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**İMLEÇ HAREKETİNİN HAYALİ SIRASINDA KAYDEDİLMİŞ EEG
SİNYALLERİNİN SINIFLANDIRILMASINI KOLAYLAŞTIRMAK AMACIYLA
YENİ BİR DÖNÜŞÜM YÖNTEMİ**

Bilgisayar Müh. Bahar HATİPOĞLU

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"BİLGİSAYAR YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih :20.12.2016
Tezin Savunma Tarihi :05.01.2017**

Tez Danışmanı: Prof. Dr. Cemal KÖSE

Trabzon 2017

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Bahar HATİPOĞLU Tarafından Hazırlanan

İMLEÇ HAREKETİNİN HAYALİ SIRASINDA KAYDEDİLMİŞ EEG
SİNYALLERİNİN SINIFLANDIRILMASINI KOLAYLAŞTIRMAK AMACIYLA
YENİ BİR DÖNÜŞÜM YÖNTEMİ

başlıklı bu çalışma, Enstitü Yönetim Kurulunun ??/??/2017 gün ve ???? sayılı kararıyla oluşturulan jüri tarafından yapılan sınavda
YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan :Prof. Dr. Cemal KÖSE

Üye :Prof. Dr. Rifat YAZICI

Üye :Yrd. Doç. Dr. Güzin ULUTAŞ

Prof. Dr. Sadettin KORKMAZ
Enstitü Müdürü

ÖNSÖZ

Elektroensefalogram, insan duygu ve hareketlerinin anlamlandırılması, kaydedilmesi ve insan beyninin geniş ölçekli sinirsel aktivitelerinin anlaşılabilmesi için kullanılan etkili bir araçtır. Birbirleriyle etkileşim halinde milyarlarca hücreden oluşan beyin ve beyin elektriksel aktiviteleri sonucunda elde edilen EEG sinyallerinin analizi, çeşitli beyinsel hastalıklarının teşhisinde ve Beyin Bilgisayar Arayüzü çalışma alanlarında sıkça kullanılmaktadır.

Tez çalışmasında, EEG sinyallerinin sınıflandırılması için yeni bir dönüşüm yöntemi önerilerek literatürde sinyallere uygulanan önışlem aşaması ortadan kaldırılmaya çalışılmıştır. Bu amaçla veri setindeki tüm sinyaller, önerilen yöntem doğrultusunda 2-boyutlu (2-B) görüntülere dönüştürülmüştür. Elde edilen görüntüler üzerine birçok etkin özellik çıkarma ve sınıflandırma yöntemi uygulanarak elde edilen sonuçlar doğrultusunda en ideal yöntem belirlenmiştir. En etkin sonuçları gözlemeyi sağlayanlar da teze eklenmişlerdir.

Çalışmalarım boyunca bilgi, görüş ve önerileriyle bana yardımcı olan çok değerli danışman hocam Sayın Prof. Dr. Cemal KÖSE' ye teşekkürlerimi bir borç bilirim.

Yüksek lisans eğitimim süresince sabır, destek ve sevgileriyle hep yanımda olan aileme ve katkılarından dolayı çok değerli arkadaşlarım Arş. Gör. Elif BAYKAL'a ve Arş. Gör. Çağatay Murat YILMAZ'a teşekkür eder saygılarımı sunarım.

Bahar HATİPOĞLU

Trabzon 2017

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “İmleç Hareketinin Hayali Sırasında Kaydedilmiş EEG Sinyallerinin Sınıflandırılmasını Kolaylaştırmak Amacıyla Yeni Bir Dönüşüm Yöntemi” başlıklı çalışmayı baştan sona kadar danışmanım Prof. Dr. Cemal KÖSE'nin sorumluluğunda tamamladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 05/01/2017

Bahar HATİPOĞLU

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	I V
İÇİNDEKİLER.....	V
ÖZET.....	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ.....	XII
TABLolar DİZİNİ.....	XIIV
SEMBOLLER DİZİNİ.....	XIV
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Literatür Taraması.....	5
1.3. İnsan Beyninin Anatomik Yapısı.....	5
1.4. İnsan Beyninin Fonksiyonları.....	6
1.5. İnsan Beyninde Var Olan Dalga Şekilleri.....	7
1.5.1. Alfa Dalgaları.....	7
1.5.2. Beta Dalgaları.....	8
1.5.3. Teta Dalgaları.....	8
1.5.4. Delta Dalgaları.....	8
1.5.5. Gamma Dalgaları.....	8
1.6. Beyin Loplarının Görevleri.....	8
1.7. EEG Sinyalleri Hakkında Genel Bilgiler.....	9
1.7.1. EEG Sinyallerinin Genel Özellikleri.....	9
1.7.2. EEG Sinyallerinin Tarihçesi.....	9
1.7.3. EEG Sinyallerinin Üretimi.....	10
1.7.4. EEG Sinyallerinin Kullanıldığı Alanlar.....	10
1.7.5. EEG Sinyallerinin Kaydı ve Donanımsal Detaylar.....	11
1.7.5. Normal Olmayan EEG Paternleri.....	12
1.8. Elektrot Yerleştirme Standardı.....	13
1.8.1. Elektrot Yerleştirme Prosedürü.....	14

1.9.	Beyin Bilgisayar Arayüzü.....	16
1.9.1.	Beyin Bilgisayar Arayüzüne Ait Problemler.....	17
1.10.	Öznitelik Çıkarım Yöntemi.....	18
1.10.1.	Temel Bileşen Analizi.....	18
1.10.1.1.	Standart Sapma ve Varyans.....	18
1.10.1.2.	Kovaryans Matris.....	20
1.10.1.3.	Özdeğerler ve Özvektörler.....	21
1.10.1.4.	Temel Bileşenler Analizi Örnek Çözüm.....	22
1.11.	Sınıflandırma Yöntemleri.....	23
1.11.1.	K En Yakın Komşuluk Algoritması.....	23
1.11.2.	Destek Vektör Makineleri.....	26
1.11.2.1.	Doğrusal Destek Vektör Makineleri.....	27
1.11.2.1.1.	Doğrusal Ayrılabilen Veriler İçin İkili Sınıflandırma Teorisi.....	27
1.11.2.1.2.	Doğrusal Ayrılamayan Veriler İçin İkili Sınıflandırma.....	31
1.11.2.2.	Doğrusal Olmayan Destek Vektör Makineleri.....	33
1.11.3.	Yapay Sinir Ağları.....	35
1.11.3.1.	Yapay Sinir Ağlarının Tarihçesi.....	35
1.11.3.2.	Biyolojik Nöronlar ve Yapay Nöron Modelleri.....	36
1.11.3.2.1.	Biyolojik Nöron Yapısı.....	37
1.11.3.2.2.	McCulloch-Pitts Nöron Modeli.....	38
1.11.3.2.3.	Yapay Sinir Sistemleri İçin Nöron Modeli.....	38
1.11.3.3.	Yapay Sinir Ağları Modeli.....	40
1.11.3.3.1.	İleri Beslemeli Ağlar.....	40
1.11.3.3.2.	Geri Beslemeli Ağlar.....	42
1.11.3.4.	Öğrenme ve Adaptasyon Yöntemleri.....	43
1.11.3.4.1.	Danışmanlı ve Danışmansız Öğrenme.....	44
1.11.3.5.	Yapay Sinir Ağlarında Öğrenme Kuralları.....	44
1.11.3.5.1.	Hebbian Öğrenme Kuralı.....	44
1.11.3.5.2.	Perseptron Öğrenme Kuralı.....	45
1.11.3.5.3.	Delta Öğrenme Kuralı.....	47
1.11.3.5.4.	Widrow-Hoff Öğrenme Kuralı.....	48
1.11.3.5.5.	Correlation Öğrenme Kuralı.....	49

1.11.3.5.6. Winner-Take-All Öğrenme Kuralı.....	49
1.11.3.5.7. Outstar Öğrenme Kuralı.....	50
2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME.....	52
2.1. Giriş.....	52
2.2. Çalışmada Kullanılan Veri Setinin Tanımı.....	52
2.2.1. Eğitim Verileri.....	53
2.2.2. Test Verileri.....	53
2.3. Önerilen Yöntem.....	55
2.3.1. Açık-Genlik Grafiğinin Elde Edilmesi.....	55
2.3.2. Dönüşüm Tekniğinin Adımları.....	55
2.3.3. Dönüşüm Tekniğinin Akışı.....	60
2.4. TBA ile Özellik Çıkarımı ve Boyut İndirgeme.....	61
2.5. Açık-Genlik Grafiği Görüntülerinin Sınıflandırılması.....	61
2.5.1. k-EYK ile Sınıflandırma Sonuçları.....	61
2.5.2. YSA ile Sınıflandırma Sonuçları.....	63
2.5.3. DVM ile Sınıflandırma Sonuçları.....	65
2.6. Deneysel Sonuçlar ve Karşılaştırmalar.....	67
3. SONUÇLAR VE TARTIŞMA.....	70
4. ÖNERİLER.....	72
5. KAYNAKLAR.....	73
ÖZGEÇMİŞ	

Yüksek Lisans Tezi

ÖZET

İMLEÇ HAREKETİNİN HAYALİ SIRASINDA KAYDEDİLMİŞ EEG
SİNYALLERİNİN SINIFLANDIRILMASINI KOLAYLAŞTIRMAK AMACIYLA YENİ
BİR DÖNÜŞÜM YÖNTEMİ

Bahar HATİPOĞLU

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Cemal KÖSE
2017, 78 Sayfa

Elektroensefalogram ölçümleri günümüzde anestezi seviyesinin belirlenmesinde, epilepsi tedavisinde ve apne hastalığı ile ilgili hastalıkların tedavisi gibi medikal araştırma alanlarının birçoğunda ve insan bilgisayar etkileşimi ile ilgili konularda sıkça kullanılmaktadır.

Bu çalışmada yeni, basit bir dönüşüm yöntemi olan Açık-Genlik dönüşüm yöntemi EEG sinyallerinin sınıflandırılması için önerilmiştir. Açık-Genlik dönüşümü, sinyaldeki değişim noktalarına (pozitiften negatife ve tam tersi yönde) bağlı olan sonlu genlik frekans dönüşümüdür. Yöntemde herhangi bir zaman domeinindeki EEG sinyali, 2-B görüntüye dönüştürülmektedir. Oluşan görüntüden çıkarılan özellikler de EEG sinyallerinin sınıflandırılmasında kullanılmaktadır.

Çalışmada Temel Bileşenler Analizi (TBA) yöntemi özellik çıkarıcı olarak; k En Yakın Komşuluk Algoritması (k -EYK), Yapay Sinir Ağı (YSA) ve Destek Vektör Makineleri (DVM) yöntemleri de sınıflandırıcı olarak kullanılmıştır. Çalışma sonunda EEG sinyallerinin dönüşüm sayesinde başarılı bir şekilde sınıflandırıldığı gözlenmiştir.

Anahtar Kelimeler: Elektroensefalogram, İnsan Bilgisayar Etkileşimi, Temel Bileşen Analizi, Destek Vektör Makineleri, k En Yakın Komşuluk, Özellik Çıkarma, Transformasyon, Dönüşüm Noktaları

Master Thesis

SUMMARY

A TRANSFORMATION METHOD FOR FEATURE EXTRACTION AND
CLASSIFICATION OF THE EEG SIGNAL RECORDED DURING CURSOR
MOVEMENT IMAGERY

Bahar HATIPOGLU

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Prof. Dr. Cemal KOSE
2017, 78 Pages

Electroencephalogram (EEG) measurements are used in the field of medical research such as determination of the level of anesthesia, treatment of epilepsy, and treatment of diseases associated with apnea and human computer interaction systems.

In this study, a simple Angle-Amplitude transformation method is proposed for classification of EEG signals. Angle-Amplitude transformation is a kind of finite amplitude frequency transformation based on the changing point of a signal (from negative to positive and vice versa). By employing the transformation, arbitrary time domain EEG signals are converted to two dimensional finite images. The attributes of resulting images are exploited in the classification of the EEG signals. Principal Component Analysis (PCA) approach is employed for feature extraction on the image; k -Nearest Neighbor (k -NN), Support Vector Machine (SVM), and Artificial Neural Network (ANN) methods are applied for the classification.

The obtained results also show that the EEG signals are quite successfully classified by employing the proposed method with the transformation.

Key Words: Elektroansefalogram, Human Computer Interaction, Principal Component Analysis, Support Vector Machines, K Nearest Neighbour, Transformation, Changing Points, Feature Extraction, Classification

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1. İnsan beyninin anatomik yapısı.....	5
Şekil 1.2. Beynin sağ ve sol yarımküreleri	7
Şekil 1.3. Uluslararası 10-20 standardına göre yerleştirilmiş elektrotlar	13
Şekil 1.4. Kafatası üzerinde nasion-inion gösterimi.....	14
Şekil 1.5. Elektrot yerleştirme standardının ilk altı adımı.....	15
Şekil 1.6. Beyin Bilgisayar Arayüzü sistemlerinin çalışma prensibi	17
Şekil 1.7. 2-boyutlu 2 sınıflı k -EYK sınıflandırıcı örneği.....	24
Şekil 1.8. Doğrusal ayrılabilen iki sınıfı ayıran hiper düzlem.....	28
Şekil 1.9. Doğrusal olarak ayrılmayan veriler için ayırıcı hiper düzlem örneği	32
Şekil 1.10. Doğrusal ayrılamayan verilere ait örnek gösterim	34
Şekil 1.11. Bir üst boyuta taşınarak doğrusal ayrışması sağlanmış örnek veri dağılımı	34
Şekil 1.12. Sinir sisteminde bilgi akışı	37
Şekil 1.13. Basit bir nörona yapısı.....	37
Şekil 1.14. McCulloch ve Pitt Modeli.....	38
Şekil 1.15. Bipolar sürekli ikili aktivasyon fonksiyonu	39
Şekil 1.16. İleri beslemeli ağ modeli (a) Bağlantı şeması, (b) Blok diyagram.....	40
Şekil 1.17. İki katmanlı ileri beslemeli ağ modeli.....	42
Şekil 1.18. Geri beslemeli ağ modeli (a) Bağlantı şeması, (b) Blok diyagram	43
Şekil 1.19. (a) Danışmanlı, (b) Danışmansız öğrenme blok gösterimi.....	44
Şekil 1.20. Hebbian öğrenme kuralı şematik gösterim.....	45
Şekil 1.21. Perceptron öğrenme kuralının şematik gösterimi.....	46
Şekil 1.22. Delta öğrenme kuralına ait şema	47
Şekil 1.23. Winner-Take-All öğrenme kuralı.....	49
Şekil 1.24. Outstar öğrenme kuralının şekilsel gösterimi.....	50
Şekil 2.1. Veri setinin kafaya yerleştirilme durumu.....	53
Şekil 2.2. (a) Sınıf 1'e ait sinyal örnekleri, (b) Sınıf 0' a ait sinyal örnekleri	54
Şekil 2.3. (a) Sınıf 1, (b) Sınıf 0'a ait örnek EEG sinyali ve sinyale ait tepe-çukur noktaları	56
Şekil 2.4. Örnek sinyal üzerindeki açı ve uzaklıkların gösterimi.....	57
Şekil 2.5. Açı – Genlik grafiği temsili gösterimi (Img (i, j)).....	58

Şekil 2.6. (a) Sınıf 0'a ait örnek sinyal dönüşümü, (b) Sınıf 1'e ait örnek sinyal dönüşümü	59
Şekil 2.7. (a) Metodun blok diyagramı, (b) Önerilen dönüşüm metodunun blok diyagram	60



TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1.1. Elektrotlar ve yerleştirildikleri beyin lobları.....	13
Tablo 1.2. [0 8 12 20] Dizisine ait standart sapma değerinin hesaplanması	20
Tablo 1.3. Örnek olarak verilen x ve y dizilerinin ortalama vektörleri.....	22
Tablo 1.4. x_1 ve x_2 dizileri ve bu dizilerin ait olduğu sınıflar	25
Tablo 1.5. Öğrenme kuralları ve bu kurallara ait özet tablosu.....	51
Tablo 2.1. Değişen bileşen sayısına göre Kanal 1’den elde edilen k -EYK sınıflandırma doğrulukları.....	62
Tablo 2.2. Değişen bileşen sayısına göre Kanal 2’den elde edilen k -EYK sınıflandırma doğrulukları.....	62
Tablo 2.3. Değişen bileşen sayısına göre Kanal 3’ten elde edilen k -EYK sınıflandırma doğrulukları.....	62
Tablo 2.4. Değişen bileşen sayısına göre Kanal 4’ten elde edilen k -EYK sınıflandırma doğrulukları.....	62
Tablo 2.5. Değişen bileşen sayısına göre Kanal 5’ten elde edilen k -EYK sınıflandırma doğrulukları.....	62
Tablo 2.6. Değişen bileşen sayısına göre Kanal 6’dan elde edilen k -EYK sınıflandırma doğrulukları.....	63
Tablo 2.7. Farklı temel bileşen sayısına göre Kanal 1’den elde edilen YSA sınıflandırma doğrulukları.....	64
Tablo 2.8. Farklı temel bileşen sayısına göre Kanal 2’den elde edilen YSA sınıflandırma doğrulukları.....	64
Tablo 2.9. Farklı temel bileşen sayısına göre Kanal 3’ten elde edilen YSA sınıflandırma doğrulukları.....	64
Tablo 2.10. Farklı temel bileşen sayısına göre Kanal 4’ten elde edilen YSA sınıflandırma doğrulukları.....	65
Tablo 2.11. Farklı temel bileşen sayısına göre Kanal 5’ten elde edilen YSA sınıflandırma doğrulukları.....	65
Tablo 2.12. Farklı temel bileşen sayısına göre Kanal 6’dan elde edilen YSA sınıflandırma doğrulukları.....	65
Tablo 2.13. Farklı C parametre değerlerine göre Kanal 1’den elde edilen DVM sınıflandırma doğrulukları	66
Tablo 2.14. Farklı C parametre değerlerine göre Kanal 2’den elde edilen DVM sınıflandırma doğrulukları	66
Tablo 2.15. Farklı C parametre değerlerine göre Kanal 3’ten elde edilen DVM sınıflandırma doğrulukları	66

Tablo 2.16. Farklı C parametre değerlerine göre Kanal 4'ten elde edilen DVM sınıflandırma doğrulukları	66
Tablo 2.17. Farklı C parametre değerlerine göre Kanal 5'ten elde edilen DVM sınıflandırma doğrulukları	67
Tablo 2.18. Farklı C parametre değerlerine göre Kanal 6'dan elde edilen DVM sınıflandırma doğrulukları	67
Tablo 2.19. Önerilen yöntemin Dataset I(a)'yı kullanan diğer çalışmalarla karşılaştırılması.....	68
Tablo 2.20. Çalışmada kullanılan tüm sınıflandırma ve öznelik çıkarma yöntemlerinin sınıflandırma doğrulukları	71



SEMBOLLER DİZİNİ

EEG	Elektroensefalogram (Elektroansefalogram)
İBE	İnsan Bilgisayar Etkileşimi (Human-Computer Interaction)
TBA	Temel Bileşenler Analizi (Principal Component Analysis)
YSA	Yapay Sinir Ağları (Artificial Neural Network)
DVM	Destek Vektör Makineleri (Support Vector Machines)
ADD	Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)
SDD	Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform)
<i>k</i> -EYK	K En Yakın Komşuluk (K-Nearest Neighbor Algorithm)
ÇKP	Çok Katmanlı Perseptron (Multi Layer Perceptron)
YKP	Yavaş Kortikal Potansiyel
SCP	Slow Cortical Potentials

1. GENEL BİLGİLER

1.1. Giriş

Elektroensefalografi (EEG) en genel olarak beyinsel aktivitelerin incelenmesi amacıyla kullanılan bir ölçüm aracıdır. İnsanların beyne olan merakı EEG üzerine birçok deneysel ve klinik çalışma yapılmasına olanak sağlamıştır. Beyinsel aktivitelerin bir nevi işaretçisi olan bu sinyaller önceki çalışmalarda, epilepsi hastalığının tedavisinde, uyku bozukluklarının düzeltilmesinde, zihinsel-psikolojik rahatsızlıkların tespitinde, kafa zedelenmelerinde meydana gelen hasarların tespit edilmesinde, anestezi derinliğinin tespit edilmesinde, beynin gelişiminin izlenmesinde, psikolojik rahatsızlıkların tedavisinde ilaç etkisinin gözlemlenmesinde gibi klinik teşhis ve tanı sistemlerinde sıklıkla kullanılmıştır. Kullanıldığı uygulama tabanlı diğer en önemli alan beyin bilgisayar ara yüzleridir. Bu alanda EEG fiziksel engeli olan kişilerin yaşam kalitesini ve dış dünya ile olan iletişimini sağlamaya yönelik olarak kullanılmaktadır. Ayrıca EEG yönteminin ağrısız, yan etkisi olmayan ve MR gibi radyasyon yaymayan bir yöntem olması da bu yöntemi daha da popüler hale getirmiştir.

Bu tez çalışmasında, öncelikle EEG sinyal verileri üzerindeki yerel tepe ve çukur noktalarında faydalanarak grafiksel Açı-Genlik görüntüleri oluşturulmuş, sonrasında elde edilen bu görüntüler üzerinde özellik çıkarma ve çeşitli sınıflandırma yöntemleri kullanılarak önerilen yöntemin başarısı ölçülmüştür.

Çalışmada ilk olarak ham EEG sinyal verileri üzerindeki tüm tepe ve çukur noktaları bulunmuştur. Bulunan tüm tepe noktalarının sağ ve sol tarafındaki çukur noktaları ile aralarındaki öklid uzaklıkları ve bu noktaların birleşimiyle oluşan doğrular arasındaki açılar hesaplanmıştır. Benzer şekilde, tüm çukur noktalarının sağ ve sol tarafındaki tepe noktaları ile aralarındaki öklid uzaklıkları ve oluşan doğrular arasındaki açılar hesaplanmıştır. Tepe noktalarının sağ ve sol tarafındaki çukur noktaları arasındaki açı değerleri pozitif olarak, diğer açı değerleri ise negatif olarak değerlendirilmiştir. Her tepe ve çukur noktasının sağ ve sol yanındaki tepe veya çukur noktaları arasındaki mesafelerden faydalanarak grafik görüntüsünün oluşturulmasında kullanılacak olan büyük öklid uzaklık bilgisi elde edilmiştir. Benzer şekilde her tepe ve çukur noktası için elde edilen küçük uzaklık değerleri büyük uzaklık değerlerine bölünerek $[-1, +1]$ aralığında genlik

değerleri hesaplanmış ve açı-genlik bilgilerinden oluşan 2-Boyutlu (2-B) sonlu grafik görüntüleri elde edilmiştir. Çalışmada ön işlem aşamasına gerek duymayan hesaplama karmaşıklığı az ancak güçlü bir dönüşüm yöntemi önerilmiştir. Önerilen yöntemin ayrıca EEG verilerinin sınıflandırma başarısını da önemli derecede arttırdığı elde edilen sonuçlarda gözlemlenmiştir.

Çalışmada özellik çıkarma aşamasında literatürde sıkça kullanılan ve başarısı bilinen TBA yöntemi kullanılmıştır. Sınıflandırma aşamasında ise k -EYK, YSA ve DVM yöntemleri kullanılmıştır. Ayrıca, kullanılan özellik çıkarma ve sınıflandırma yöntemlerinin başarısını doğrudan etkileyen en iyi parametre değerlerinin seçimi bruteforce arama yoluyla gerçekleştirilmiştir.

Çalışmada temel olarak iki soruna çözüm bulunması amaçlanmıştır. (1) Sınıflandırma doğruluğu sinyali görüntüye dönüştürülerek artırılabilir mi? (2) EEG-tabanlı çalışmalarda herhangi bir ön işlem kullanmamak mümkün müdür? Elde edilen sonuçlar incelendiğinde önerilen dönüşüm yönteminin bu iki soruna çözüm getirebileceği açıkça görülmüştür.

Tez çalışmasında birinci bölümde ilk olarak EEG sinyalleri hakkında detaylı bilgi verilmiş; sonrasında sırayla kullanılan özellik çıkarma ve sınıflandırma yöntemleri detaylı olarak açıklanmıştır. İkinci bölümde ise önerilen dönüşüm yöntemi detaylı bir şekilde anlatılmış ve sınıflandırma yöntemlerinden elde edilen sonuçlar da ayrıntılı bir şekilde irdelenmiştir.

1.2. Literatür Taraması

Literatürde EEG işaretleri kullanılarak yapılmış birçok çalışma mevcuttur. Mevcut çalışmalar incelendiğinde çoğunlukla öznitelik çıkarma, sınıflandırma ve gürültüden arındırma aşamalarında yoğunlaştığı görülmektedir. EEG tabanlı beyin bilgisayar etkileşimi çalışmaları genel olarak 3 aşamadan oluşmaktadır. İlk aşamada sinyal, insan kafatasına yerleştirilen elektrotlar yardımıyla kaydedilmekte ve gerekirse ön işlem yapılmaktadır. İkinci aşamada EEG sinyalinden özellik çıkarma işlemi, üçüncü aşamada ise çıkarılan özelliklerden faydalanılarak sınıflandırma işlemi gerçekleştirilmektedir.

Sabeti ve arkadaşları, 2009' da EEG işaretlerini kullanarak şizofren hastaları ve normal kişileri entropi ve karmaşıklık ölçütü yardımıyla sınıflandırmışlardır [1]. Çalışmalarını 20 şizofreni hastası ve benzer yaşlarda 20 sağlıklı kişi üzerinde

gerçekleştirmişlerdir. Her durum için EEG sinyallerini 20 kanal bilgisinden oluşacak şekilde kaydetmişler ve sinyallerden aşağıda listelenen yöntemler yardımıyla özellik çıkarma işlemini gerçekleştirmişlerdir.

- Shannon Entropi
- Spektral Entropi
- Yaklaşık Entropi
- Lempel-Ziv Karmaşıklık
- Higuchi Fraktal Boyut

Birini Dışarıda Bırak (Leave-one-out) çapraz doğrulama metodunu iki grubun ayrımında daha güvenilir tahmin yapabilmek, LDA ve Adaboost yöntemlerini de sınıflandırma amacıyla kullanmışlardır. Sınıflandırma sonrasında yaklaşık olarak sırasıyla %86 ve %90 oranında başarı elde etmişler ve şizofreni hastalığının tespitinde dolayısıyla psikoloji alanında EEG sinyalinin kullanılabilceğini göstermişlerdir.

Fraïwan ve arkadaşları otomatik uyku durumu belirleme sistemini zaman-frekans analizine dayalı olarak EEG sinyalleri yardımıyla oluşturmuşlardır [2]. Çalışmalarında aşağıda listelenmiş olan 3 ayrı zaman-frekans dönüşüm tekniğini kullanmışlardır.

- Choi-Williams Dağılımı (CWD)
- Sürekli Dalgacık Dönüşümü (SDD)
- Hilbert-Huang Dönüşümü (HHD)

Çalışmada 16 denek kullanılmıştır. Önerilen yaklaşım, doğruluk ve kappa katsayısı değerlendirilerek test edilmiştir. Çalışmada, SDD dönüşümü kullanıldığında %83 ve kappa katsayısı kullanıldığında %76 doğruluk elde edilmiştir.

Übeyli, 2006 yılında yaptığı çalışmada EEG sinyallerini özvektör metoduyla çok sınıflı destek vektör makinesini birleştirerek analiz etmiştir [3]. Übeyli bu çalışmasında özvektörler yardımıyla özellik çıkarmış ve çıkarılan özellikleri sınıflandırmanın yerine kendi yöntemini önererek uygun bir sınıflandırma şeması elde etmeye çalışmıştır.

Parvinnia ve arkadaşları, uzaklık ağırlıklı k -EYK algoritmasını kullanarak EEG sinyallerini sınıflandırmışlardır [4]. Bu metodu kullanmalarındaki amaç, kayıt esnasında sinyalin bozulmasına sebep olan etkenler nedeniyle sınıflandırma yönteminin güvenilirliğinin ortadan kalkmasını önlemektir. Çalışmalarını 13 şizofreni hastası ve 18 sağlıklı insan üzerinde gerçekleştirmişlerdir. Sınıflandırma sonuçları Birini Dışarıda Bırak çapraz doğrulama metoduyla değerlendirilmiştir.

Bogacz ve arkadaşları, göz kırpması sonucu EEG sinyallerinde oluşan bozukluğunun algılanması üzerine çalışmışlardır [5]. Çalışmalarında bu bozuklukları tespit etmek

amacıyla YSA tabanlı bir yaklaşım önermişlerdir. Göz kırpma sonucunda sinyale eklenen gürültü literatürde üzerinde en çok durulan konular arasında yerini almaktadır [6]. Bireylerin fiziksel hareketlerine bağlı olarak sinyallere eklenen bu gürültü çeşidi, göze yakın kısımlara yerleştirilmiş elektrotlardan alınan sinyalleri daha çok etkilemektedir.

Aydemir ve Kayıkçıoğlu yaptıkları çalışmada 2-B imleç hareketinin hayali sırasında oluşan EEG verilerini sınıflandırmaya çalışmışlardır [7]. Çalışmada karar ağacı tabanlı bir yöntem önerilmiş ve deneyler yaşları 24 ve 29 arasında değişen 3 sağlıklı bireyden alınan veriler üzerinde gerçekleştirilmiştir. Kayıtlar bir hafta ara ile farklı seanslarda bireylerin bilgisayar imlecini (sağ, sol, yukarı ve aşağı) hareket ettirdiklerini hayal ettikleri durumda kaydedilmiştir [6].

Pfurtscheller ve arkadaşları sağ ve sol el hareketlerinin hayali sırasında oluşan EEG verilerinin ayrıştırılmasına yönelik bir çalışma yapmışlardır [8]. Çalışmada 3 denekten sağ ve sol ellerini hareket ettirdiklerini hayal etmeleri istenmiştir. Her denek 3-4 oturumda toplam 160 el hareketi hayal etmiştir. Çalışma sonucunda yaklaşık olarak %80 oranında başarı elde edilmiştir.

Aydemir ve Kayıkçıoğlu BBA uygulamalarında uygun sınıflandırıcıyı tespit etmek için yaptıkları çalışmalarında k -EYK, destek vektör makinesi, doğrusal ayırtaç analizi, naïve bayes ve karar ağacı olmak üzere 5 farklı sınıflandırıcı kullanmışlardır [9]. Çalışmada öğrenme ve test işlemleri BCI Competition 2003 Dataset III ve Dataset I(a) veri setleri üzerinde gerçekleştirilmiştir. Sınıflandırıcıların performans metrikleri ise doğruluk, duyarlılık, özgüllük, kappa katsayısı ve hesaplama zamanı olarak belirlenmiştir.

Ting ve arkadaşları Beyin Bilgisayar Arayüzü (BBA) için EEG sinyallerinden dalgacık paket ayrıştırma (WPD) yöntemine dayanan yeni bir özellik çıkarma metodu önermişlerdir [10]. Özel alt bantların enerjisini ve buna bağlı olarak dalgacık paket ayrışımı metodununun katsayılarını özellik olarak kullanmışlardır. Önerilen yöntem BCI Competition 2003'deki yarışmada yayınlanan Dataset I(a) ve I(b) veri setleri üzerinde sınanmıştır.

Sun ve Zhang yaptıkları çalışmada BCI Competition 2003'deki yarışmada yayınlanan Dataset I(a)'yı kullanarak EEG sinyal kategorizasyonu için özellik belirleme üzerine çalışmışlardır [11].

Wang ve arkadaşları da aynı veri setini kullanarak dalgacık paket ayrışımı ve sinir ağları yöntemiyle EEG tanıma üzerine çalışmışlardır [12]. Bu yöntemleri kullanarak EEG


tabanlı BBA uygulamalarında ikili sınıflandırma yapmışlardır. Ağın yapısını değiştirerek performans üzerine etkilerini incelemişlerdir.

Aynı veri setini kullanarak çalışma yapan diğer bir grup da Mensh ve arkadaşlarıdır. Çalışmalarında EEG sınıflandırması için yüksek frekanslı gamma bandını kullanmışlardır [13]. Bunun yanında, çalışmada daha anlamlı tahminler yapmak amacıyla farklı bir yaklaşımda bulunarak yavaş kortikal potansiyel (Slow Cortical Potentials-SCPs) kullanarak başarı oranlarını artırmışlardır.

Kayıkçıoğlu ve Aydemir BBA sistemlerinde hız ve doğruluğun öneminden yola çıkarak aynı veri seti üzerinde yaptıkları çalışmada polinom uydurma yöntemi önermişlerdir [14]. Çalışmada EEG verilerinden çıkarılan özellikler k -EYK metodu ile sınıflandırılmıştır. k -EYK yönteminin sınıflandırma başarısı ayrıca çok katmanlı Perceptron ve DVM ile de karşılaştırılmış ancak k -EYK yöntemiyle sınıflandırma doğruluğu artarken eğitim ve test sürelerinin de azaldığı gözlemlenmiştir.

1.3. İnsan Beyninin Anatomik Yapısı

Beyin, tüm fiziksel işlevleri gerçekleştiren ve milyonlarca sinir hücresinden oluşan en karmaşık organ olmasının yanı sıra sinir sisteminin de merkezidir [15]. İnsanın yaşamsal olarak gerekli tüm aktivitelerinin yanında; hisler, açlık, susuzluk, vücut hareketleri ve uyku faaliyetleri de beyin tarafından yönetilmektedir [46].



Şekil 1.1. İnsan beyninin anatomik yapısı

1.4. İnsan Beyninin Fonksiyonları

Sinir sistemi, en temel anlamda omurilik ve beyinden oluşmaktadır. Sinirler; beynimizden yüzümüze, kulaklarımıza, gözlerimize kadar tüm organlarımıza uzanan, vücudumuzun karar ve iletişim merkezidir [15]. Bu sayede duyu sinirleri bilgileri çevreden almakta ve omuriliğe yönlendirmektedir. Omurilik ise aldığı mesajı karar merkezi olan beyne iletmekte beyin de en uygun mesajı cevap olarak geri döndürmektedir [46]. Bu geri döndürme işlemini yapan motor nöronlar vücudun geri kalanına mesajı dağıtmaktadırlar.


Beyin 3 kısımdan oluşmaktadır [82]:

- Ön beyin
- Ara beyin
- Arka beyin

Ön beyin talamus, hipotalamus ve beyinden; ara beyin tektum ve tegmentumdan; arka beyin ise beyincik, pons (beyincik ve soğan iliğini asıl beyne bağlayan sinir lifleri) ve medulladan oluşmaktadır [83, 84].

Çok kırışik bir yapıdan oluşan beyin zarı (Cerebral korteks) ise lop olarak adlandırılmakta ve Şekil 1.1'de gösterildiği gibi 4 bölüme ayrılmaktadır [47]. Kırışik olması beynin yüzeyinin artmasını dolayısıyla da etkili fonksiyonlara sahip olmasını sağlamaktadır.

Beyin derin bir yarıkla iki küreye ayrılmaktadır [15,16]. Bu küreler sağ ve sol yarımküre olarak adlandırılıp simetrik olmaktadır. Görünüş olarak aynı olmalarına rağmen içerik ve fonksiyon olarak tamamen farklı özellikler sergilemektedirler. Sağ lop yaratıcılıkla alakalı olmakta, sol lop ise mantıksal yeteneklerle ve matematiksel zekâ ile ilgilenmektedir [61]. Ayrıca sol beyin vücudun sağ tarafındaki tüm kasları kontrol ederken, sağ beyin ise sol taraftaki kasları kontrol etmektedir. Bu kürelerden bir tanesi insanlarda daha etkilidir (Sağ eli kullanmak veya sol eli kullanmak gibi).



Şekil 1.2. Beynin sağ ve sol yarımküreleri

1.5. İnsan Beyninde Var Olan Dalga Şekilleri

Sağlıklı yetişkinlerde sinyalin genlik ve frekans değerleri bir durumdan diğerine (uyku durumundan uyanma durumuna geçmek gibi) ya da yaşa bağlı olarak da değişmektedir [16]. Bu değişimin sinyal kaydını bozmasına engel olmak amacıyla deneklerin beyinlerinde oluşan elektriksel aktiviteler, gözleri kapalı ve stresten arındırılmış durumdayken kaydedilmektedirler. İşaretler genelde sinüzoidal yapıda olmakla birlikte genlik değerleri 0.5 ile 100 μ_v aralığında değişmektedirler. Birbirlerinden farklı frekans aralıklarında 5 büyük beyin dalgası mevcuttur; beta (β), alfa (α), teta (Θ), delta (δ) ve gamma (γ) [15,17].

1.5.1. Alfa Dalgaları

Alfa ve beta dalgaları 1929'da Berger tarafından keşfedilmiştir. Jasper ve Andrews 1938'de "gamma" kelimesini 30 H_z 'in üzerindeki dalgaları ilişkilendirmek için kullanmışlardır [15].

İnsan beyninin en iyi bilinen ve üzerinde en yaygın çalışılan ritmi (8-13 H_z aralığında) normal alfa ritmidir. Alfa ritmi 50 μ_v genlikle artkafa bölgesinde sinüzoidal ya da yuvarlak olarak gözlemlenmektedir [48]. Alfa ritminin aktivitesi gözler kapalı pozisyonda ve rahatlamayla başlatılmaktadır [17]. İşlem tamamlandığında da herhangi bir uyarılma (düşünme, hesaplama vb.) sonucunda gözler açılarak sonlandırılmaktadır. Bireylerin çoğu, gözlerini kapattıklarında dalga şekilleri betadan alfaya geçişecek kadar

göz kapatma olgusuna duyarlı olmaktadır. Alfa ritminin kökeni hala kesin olarak bilinmemekte buna bağlı olarak dentritlerin toplamı olarak ifade edilmektedirler.

1.5.2. Beta Dalgaları

Beta dalgaları (12-38 H_z aralığında) ise gözler açık durumda ve normal uyanıklık halinde gözlenmektedir [18]. Aktif düşünme, karmaşık problemlerin düşünülmesinde ve odaklanma durumunda ortaya çıkmaktadırlar [48]. Yüksek seviyede beta dalgaları panik halinde oluşmakta ve uyku sersemliği durumunda beta dalgalarının aktivitesi azalmaktadır.

1.5.3. Teta Dalgaları

Teta dalgaları (4-7 H_z aralığında) yetişkinlerde tembellik halinde ortaya çıkmakta ve bu dalgalar çocukluk döneminde çok önemli bir konuma sahip olmaktadır [17]. Bu dalgalara kafanın merkezinde, temporal ve yan loplarda rastlanılmaktadır [48].

1.5.4. Delta Dalgaları

Delta dalgaları ise (0.5-3.5 H_z aralığında) yetişkinlerde derin uyku ve uykudan uyanma modunda oluşmaktadır [15].

1.5.5. Gamma Dalgaları

Gamma dalgaları, frekans aralığı 30 H_z 'in üzerinde olan dalgalar olmaktadır. Bu ritimlerin genlikleri çok düşük olmasına ve nadiren gerçekleşmesine rağmen, dalgalar beyin hastalıklarının onayında kullanılmaktadır [15]. Gamma dalgaları yüksek frekans ve düşük genlikli olmalarının yanı sıra en hızlı beyin dalgaları özelliğine de sahip olmaktadır [26].

1.6. Beyin Loplmasının Görevleri

Ön lop; planlama, sonuçlandırma, konuşmanın bir kısmı, duygular, problem çözme, hareket ile ilişkili olmaktadır [36]. Yan lop; hareket, tanıma, alışma (uyum), uyarıcıları

algılama ile artkafa lobu ise görsel işleme ile ilgili olmaktadır. Tüm bunların yanında temporal lop ise hafıza, konuşma, algılama ve işitsel uyarıcıları tanıma ile ilişkili olmaktadır [19].

1.7. EEG Sinyalleri Hakkında Genel Bilgiler

1.7.1. EEG Sinyallerinin Genel Özellikleri

EEG insan vücuduna uygulanan çeşitli görüntüleme yöntemlerinden sıklıkla tercih edilen bir modern tıp yöntemidir. EEG sinyalleri ise kafa yüzeyinden elektrotlar yardımıyla alınan ve durağan bir yapıya sahip olmayan düşük genliğe sahip elektriksel işaretlerdir [44]. Bu işaretler, nöron zarlarındaki kanallar boyunca pompalanan Na^+ , K^+ , Ca^{++} , Cl^- iyonlarından oluşan elektrik akımı sonucunda meydana gelmektedir [16, 53]. İnsan beyninin elektriksel aktivitesi 17-23'üncü haftalar arasında doğum öncesi gelişim ile başlamaktadır.

1.7.2. EEG Sinyallerinin Tarihi

Tarihinin 100 yılı boyunca EEG alanında büyük ilerleme gösterilmiştir. Carlo Matteucci ve Emil Du Bois-Reymond galvanometre yardımıyla kas sinirlerinden elektriksel sinyali ilk kaydeden bilim insanlarıdır. Beyinde elektriğin varlığı 1875 yılında İngiliz fizikçi Richard Caton tarafından keşfedilmiştir [16]. Richard Caton, EEG işaretlerini tavşan ve maymun beyninden alınan sinyallerden gözlemlemiştir [25]. Vasili Yakovlevich Danilevsky, Caton'un çalışmalarını takip etmiş ve 1877 yılında Ph. D. tezini insan beyninin psikolojik araştırması üzerinde tamamlamıştır [15].

İlerleyen yıllarda epileptik atakların beyindeki anormal elektriksel aktiviteyle alakalı olduğu fikri Kaufman tarafından ortaya atılmıştır [15]. Alman nörolog Hans Berger ise 1924'de insan derisinden ölçülen elektriği yükseltebilmek için sıradan bir radyo takımı kullanmış ve yaptığı çalışmalar sonunda zayıf elektrik akımının kafatasını açmadan da kaydedilebileceğini duyurmuştur [24]. Bunun üzerine beyindeki elektriksel aktivitenin durumlara (uyku, sinirsel hastalık, epilepsi vb.) bağlı olarak değiştiğini kâğıt bir şerit üzerine çizdirerek göstermiştir. Berger, birçok EEG uygulamasının temelini atmasının yanı sıra "EEG" sözünü ilk kullanan bilim adamı olmaktadır.

1926 yılında, Berger Siemens çift bobinli galvanometreyi kullanarak mevcut EEG çalışmalarını ilerletmiştir [15]. Daha sonraki yıllarda yaptığı çalışmalarla, Berger beyin aktivitelerinin tutarlı ve tanınabilir bir yolla değiştiğini belirtmiştir. 1930 yılında uyku altında ilk EEG kaydı yine Berger tarafından yapılmıştır [54]. Berger bu çalışmasında kanda oksijen eksikliğinin insan beynine etkisini raporlamıştır.

1934 yılında ise Adrian ve Matthews 10-12 Hertz aralığında düzenli salınımlar kavramını doğrulayan “İnsan Beyni Dalgaları” isimli bildiriye yayınlamışlardır [15].

EEG gelişim tarihi günümüzde yapılan çalışmalar sayesinde hala gelişmeye devam etmektedir. Tarih boyunca da kliniksel, deneysel ve hesaplamsal ilerlemelere bağlı olarak EEG çalışmaları da gelişme göstermiştir.

1.7.3. EEG Sinyallerinin Üretimi

EEG sinyalleri, beyin kabuğundaki nöronların dentritleri boyunca akan akımlardır [20]. Beyin hücreleri aktif olduğunda, sinaptik akımlar dentrit içerisinden devam etmektedirler. İnsan kafası; kafatası, kafa derisi ve beyin içeren farklı katmanlardan oluşmakta ve kafatası EEG sinyallerini yaklaşık yüz kez küçülmesine sebep olmaktadır. Ek olarak kafa derisinde oluşan gürültüler de buna eklenmektedir. Bu nedenle sadece aktif nöronların geniş bir popülasyonu kafa derisinden kaydedilebilecek yeterlilikte akım üretmekte ve üretilen bu akımlar da yükseltilecek görüntülenebilmektedirler [16]. İnsanların merkezi sinir sistemlerinde yaklaşık 100 milyar kadar nöron bulunmakta ve nöronlar birbirlerine sinapsislerle bağlanmaktadır [27, 55]. Yetişkinlerde yaklaşık olarak 5×10^{14} sinapsis bulunmakta ve nöron başına düşen sinapsis miktarı da yaşla birlikte artmakta, buna karşılık nöron sayısı azalmaktadır.

1.7.4. EEG Sinyallerinin Kullanıldığı Alanlar

EEG işaretleri, beyin yüzeyinden elektrotlar yardımıyla kaydedilen düşük genlik değerine sahip biyolojik işaretler olmaktadır [85]. Henüz tam olarak açıklanamamakla birlikte insan beyninden kaydedilen bu işaretlerde çok miktarda bilgi bulunduğu tahmin edilmektedir [20]. Ayrıca beynin karmaşık bir yapıya sahip olması ve işaretlerinde düşük genlikli olması bu bilgilere ulaşılmasını zorlaştırmaktadır. Ancak ucuz ve acı vermeyen bir yöntem olması sebebiyle günümüzde birçok alanda kullanılmaktadır. İnsan kafasından

EEG sinyallerinin kaydedilmesine ihtiyaç duyulması aşağıda listelenen kliniksel problemlere çözüm bulabilmek amacıyla gerçekleştirilmektedir [51].

- Alerjileri, koma hali ve beyin ölümünün görüntülenmesi
- Kafa zedelenmelerinde meydana gelen hasarların tespit edilmesi
- Bilişsel ritimlerin gözlemlenmesi
- Anestezi derinliğinin tespit edilmesi
- Epilepsi hastalığının teşhis edilmesi
- Epilepsi hastalığını test edilmesi ve ilaç etkisinin gözlemlenmesi
- Beyin gelişiminin izlenmesi
- Uyku bozuklukları ve psikolojik rahatsızlıkların tespit edilmesi
- Zihinsel bozuklukların tespit edilmesi

Listelenen kliniksel problemlere EEG uygulanabiliyor olması bu kayıt yönteminin ne kadar zengin bir potansiyele sahip olduğunu göstermektedir.

1.7.5. EEG Sinyallerinin Kaydı ve Donanımsal Detaylar

Beyindeki nöral aktivitelerin kafa derisinden kaydı EEG kaydı olarak adlandırılmaktadır [52]. İnsan vücudundan görüntü veya sinyal almak çeşitli hastalıkların ön tespiti için hayati önem taşımaktadır. Elektrobiyolojik sinyaller sırasıyla; kalpten alınan ECG (Elektrokardiyogram), kaslardan alınan EMG (Elektromyogram), beyinden alınan MEG (Magnetoensefalografi), mideden alınan ECG (Elektrogastogram) ve gözlerden alınan EOG (Elektrookulogram) sinyalleridir [53]. Beyindeki fonksiyonel ve psikolojik değişimler EEG, MEG ya da fMRI ile kaydedilebilmektedir fakat fMRI uygulaması EEG ve MEG ile karşılaştırıldığında çok kısıtlı kalmaktadır [65]. İlk elektriksel sinir aktivitesi galvanometre kullanılarak kaydedilmiştir. Daha sonraki EEG sistemlerinde hassas elektrotlar keşfedilmiş ve çok kanallı EEG sinyalleri kâğıtlar üzerinde çizdirilmeye başlanmıştır. Yakın geçmişte ise araştırmacılar sinyali hesaplayan ve saklayan makine arayışına girmişlerdir. Bu düşünceden hareketle günümüzdeki modern EEG cihazları geliştirilmiştir.

EEG ölçüm sistemi elektrotlar, iletim ortamı (kablolar), yükseltici filtreler, analog/dijital dönüştürücüler ve kayıt cihazlarından oluşmaktadır [16]. Elektrotlar sinyali kafa yüzeyinden okumakta ve yükselteçler mikro volt düzeyindeki sinyalleri

sayısallaştırılabilecek aralığa taşımaktadırlar. Dönüştürücüler yardımıyla sinyaller dijital ortama çevrilmekte ve son olarak bilgisayarlar yardımıyla da kayıt sağlanmaktadır.

EEG'de elektrotlar kayıt işlemi ve veriyi yüksek kalitede yorumlamak için önemli araçlar olmaktadır. Farklı karakteristik özelliklere sahip çok sayıda elektrot türü mevcuttur fakat klinik araştırmalarda en çok tercih edilen elektrot metal diskli elektrotlardır [50]. Bu elektrot türleri aşağıdaki gibi listelenebilmektedir:

- Tek kullanımlık elektrot
- Yeniden kullanılabilir elektrot
- Başlıklı elektrot
- Tuzlu su tabanlı elektrot
- İğneli elektrot

Çok kanallı montajlar söz konusu olduğunda başlıklı elektrotlar tercih edilmektedir. İğneli elektrotlar uzun süreli kayıtlar için tercih edilmekte ve kafa derisinin altına yerleştirilmektedirler. Bu yöntemde çekimler esnasında cildin yağdan arındırılmış ve tamamen kuru olması oldukça önem taşımaktadır [20]. Tek kullanımlık elektrotlarda ise aşındırıcı macun kullanılarak etkin kayıt yapılması sağlanmaktadır. Şapka sistemlerinde enjeksiyon sonunda cilt kazınmaksızın iğneler kullanılmaktadır. Bir kişinin EEG ölçümünün tekrarlanma durumu söz konusu olduğunda şapka aynı elektrot noktasına yerleştirilmektedir. Bu kayıt esnasında ağrı ve kanama tehdidi söz konusu olduğundan, temizlik ve güvenlik önlemlerine dikkat edilmesi gerekmektedir.

1.7.6. Normal Olmayan EEG Paternleri

Örnek alınan deneğin EEG paternleri içerisindeki varyasyonlar anormallik olarak adlandırılmaktadırlar. Bu durum sinyal bozulması ve kaybolması sebebiyle de oluşabilmektedir. Sharbrough EEG sinyallerindeki özel olmayan bu anormallikleri aşağıda listelendiği gibi 3 ayrı kategoriye ayırmaktadır [15].


- (a) Genellikle delta dalgası aralığında ve beyin işlev bozukluğu ile ilgili yaygın yavaş dalga bozuklukları
- (b) Sürekli EEG olarak adlandırılan bozulmuş bilinçli beyin reaksiyonlarıyla ilişkili anormallikler
- (c) Odak (focal) beyinle ilgili kalıcı EEG bozuklukları

1.8. Elektrot Yerleştirme Standardı

1947 yılında Londra’da gerçekleştirilen birinci Uluslararası EEG Kongresinde Dr. Herbert H. Jasper EEG sisteminde kullanılan elektrotların yerleştirilmesi standartlaştırmak için mevcut ilk yöntemi önermiştir [69]. 10-20 standardı ya da uluslararası 10-20 standardı olarak adlandırılan bu yöntem insan kafasına elektrot yerleştirmeyi standartlaştırmak için geliştirilmiştir [21]. Yöntemdeki “10” ve “20” sayıları elektrotlar arasındaki mesafeyi ifade etmektedir. Elektrotların yerleştirme işlemi tamamlandıktan sonra elektrotlar Şekil 1.3’teki halini almaktadır. Gösterilen her harf bir lobu ifade etmekte ve bulunduğu bölgeye göre Tablo 1.1’de verildiği gibi adlandırılmaktadır.

Tablo 1.1. Elektrotlar ve yerleştirildikleri beyin lobları

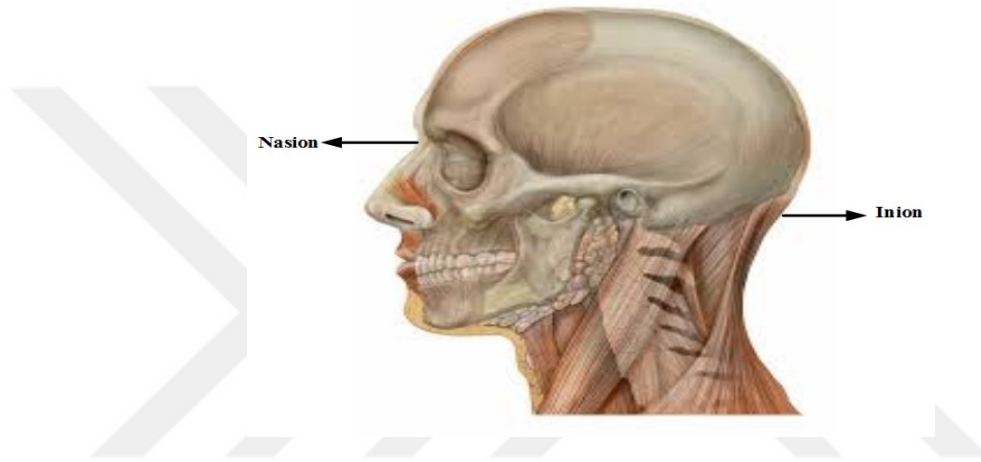
Elektrot	Lob
F	Frontal (Ön)
T	Temporal (Temporal)
C	Central (Merkez)
P	Parietal (Yan)
O	Occipital (Artkafa)



Şekil 1.3. Uluslararası 10-20 standardına göre yerleştirilmiş elektrotlar

'C' yerleşimi belirlemek amacıyla merkez noktası olarak kullanılmaktadır. 'z' (zero) elektrot çizgisinin tam ortasını ifade etmektedir. Gösterimdeki çift sayılar (2, 4, 6, 8) sağ yarımküredeki elektrot pozisyonlarını, tek sayılar ise (1, 3, 5, 7) sol yarımküredeki elektrot pozisyonlarını belirtmektedir. Anatomik işaretler elektrotların ana yerleşimi için kullanılmaktadırlar.

Elektrot yerleştirme işleminde ilk olarak insanın kafatasındaki burun kemiği ile alın kemiğinin birleşme noktası (nasion), ikinci olarak da kafatasının en alçak noktası belirlenmektedir (inion) [21].



Şekil 1.4. Kafatası üzerinde nasion-inion gösterimi

1.8.1. Elektrot Yerleştirme Prosedürü


Adım 1: Nasion-Inion arası uzunluk değeri hesaplanmaktadır. Örnek için bu değer 36 santimetre (cm) olarak belirlenmiştir. Belirlenen uzunluk değeri Şekil 1.5 (a)'da gösterilmektedir.

Adım 2: Toplam uzunluğun %50'si Şekil 1.5 (b)'de gösterildiği gibi hesaplanmaktadır. Bulunan değer C_z noktasını ifade etmektedir. Örnek için $36/2 = 18$ cm olarak bulunmaktadır.

Adım 3: Nasion ve iniondan itibaren toplam uzunluğun %10'u Şekil 1.5 (c)'de gösterildiği gibi hesaplanarak F_{pz} ve O_z noktaları tespit edilmektedir.

Adım 4: Bu adımda Şekil 1.5 (d)'de yerleşim merkezleri verilen F_z ve P_z noktaları hesaplanmaktadır. Bu noktalar C_z merkez noktasından itibaren toplam uzunluğun %20'lik

uzaklık mesafesine yerleştirilmektedirler. Örnek için bu değer $36 * (20/100) = 7.2$ cm olarak bulunmaktadır.



Şekil 1.5. Elektrot yerleştirme standardının ilk altı adımı

Adım 5: Bu adımda Şekil 1.5 (e)'de verilen T_3 ve T_4 noktalarının hesaplanması gerekmektedir. Bu örnek için 2 kulak arası mesafe 38 cm olarak ölçülmüştür. Tespit edilecek noktalar da bu uzunluğun %10'u $38 * (10/100) = 3.8$ olan kadar uzağına yerleştirilmektedir.


Adım 6: Bu adımda T_3-C_z ve C_z-T_4 ikililerinin tam orta noktalarına C_3 ve C_4 ölçüm noktaları yerleştirilmektedir. Belirtilen noktalar için yerleşim işlemi gerçekleştirildiğinde Şekil 1.5 (f)'te verilen görünüm elde edilmektedir.

Noktaların yerleşim işlemlerine ait ilk 6 adım Şekil 5'te verildiği gibi olmakta ve verilen adımlara benzer şekilde devam etmektedir. Tüm noktaların yerleşim işlemi tamamlandığında ise Şekil 1.3'te verilen görünüm elde edilmektedir. Böylece standartlara uygun olarak tüm elektrotlar kafaya yerleştirilmiş olmaktadır.

1.9. Beyin Bilgisayar Arayüzü

Beyin Bilgisayar Arayüzü (BBA) diğer adıyla Beyin Makine Arayüzü (BMA) günümüzde çok geniş bir araştırma alanına sahip olmaktadır [15, 68]. Genel çalışma prensibi Şekil 1.6'da verilen BBA; analiz, görüntüleme, ölçüm ve karmaşık psikolojik davranışların değerlendirilmesini algılama ve elektrotlar yardımıyla kafa derisinden kaydetme durumudur. Ayrıca beyin ve fiziksel dünya arasında herhangi bir fiziksel iletişim olmadan bağlantı kurulmasını sağlamakta ve bu amaçla insanlardan alınan sinyallerin işlenip bilgisayar ortamına aktarılmasını gerçekleştirmektedir [56]. Bu yöntemin temelinde beyinde nöronlar tarafından üretilen sinyallerin işlenebilmesine dayanmaktadır. En önemli uygulaması ise felçli organları ya da insan vücudunun engelli kısımlarının harekete geçirilmesini sağlamaktır. İnsanlar için, omurilik yaralanması, inme ve beyin felci gibi durumlarda BBA tek iletişim yolu olarak görülebilmektedir [57].

Beyindeki elektriksel aktivitenin keşfinden yaklaşık 100 yıl sonra ilk BBA araştırması, Jacques Vidal tarafından raporlanmıştır [58, 59]. Jacques yaptığı çalışmalarda, beyin sinyallerinin zihinsel protez olarak kullanılabileceğini göstermiştir.



Şekil 1.6. Beyin Bilgisayar Arayüzü sistemlerinin çalışma prensibi

BBA arařtırmaları, 1999 yılındaki kortikal nöron topluluklarının doğrudan bir robotla kontrol edilebileceđi fikrine dayanan ilk deneysel çalıřmadan sonra çarpıcı bir noktaya tařınmıştır [15]. Bu çalıřmadan sonra arařtırmacıların sistemin hızlı ve doğru bir şekilde çalıřabilmesi için yoğun çaba harcamaları sebebiyle sistem muazzam bir gelişme göstermiştir [30].

BBA bilinç, elektronik sensör, devreler, makine öğrenmesi, psikoloji, sinyal algılama, kümeleme ve sınıflandırmayla ilgilendiğinden beri çok disiplinli bir arařtırma alanı olmuştur.

1.9.1. Beyin Bilgisayar Arayüzüne Ait Problemler

BBA'nın en büyük problemi kontrol sinyalleriyle arka planda oluşan sinyallerin birbirinden ayrılmamasıdır [15]. Bunun yanında, kortikal bağlantı beyin aktivitesiyle alakalı çeşitli görevlerin belirlenmesinde çalışılması gereken önemli bir nokta olmaktadır. Farklı domainlerdeki çeşitli özellikleri algılamak ve değerlendirmek sinyalin kontrolünü

sağlamaktadır. Kontrol sinyallerini çıkarmak için yapay katkı (gürültü gibi) barındırmayan EEG sinyallerine sahip olmak gerekmektedir.

Sinyal üzerinde en büyük bozulma etkisine sahip olan faaliyet göz kırpma etkisidir [24]. Göz kırpma ön ve artkafa lobunda büyük etki bırakmaktadır [24, 86]. Bunları ortadan kaldırmak amacıyla literatürde birçok çalışma yapılmış ve benzeri dahili-harici gürültüleri ortadan kaldırmak amacıyla donanım destekli yeni EEG kayıt cihazları geliştirilmiştir [15]. Geliştirilen bu cihazlar sayesinde işaretler filtrelenip ham sinyal elde edilebilmektedir.

BBA için akla gelen en önemli sorulardan ilki eğer bağlantılı olduğu engelli veya felçli kişi için çok hayati bir durum söz konusu olduğunda çalışmayı durdurursa ne yapılacağı ve diğer önemli soru ise kullanımının etik açıdan doğru olup olmayacağıdır [60].

1.10. Öznitelik Çıkarım Yöntemi

1.10.1. Temel Bileşen Analizi

Temel bileşen analizi avuç izi tanıma, iris tanıma, yüz tanıma gibi örüntü tanımayla alakalı alanlarda geniş çalışma alanı bulan bir lineer dönüşüm tekniğidir [62]. Ortogonal lineer dönüşüm kullanarak veriyi yeni bir koordinat düzlemine taşımaktadır. Aynı zamanda Karhunen-Loeve (KL) dönüşümü olarak da bilinen özellik çıkarma ve boyut azaltma metodudur [63]. Temel amaç n boyutlu veriden daha az boyutlu veri elde etmek ve elde edilen anlamlı verilerle tüm veri setinin temsil edilmesini sağlayarak karmaşıklığı ve boyutu azaltmaktadır [30]. Elde edilen temel bileşenlerin sayısı temsil edilen değerlerin çeşitliliği ile alakalı olmaktadır [38].

1.10.1.1. Standart Sapma ve Varyans

Standart sapma kavramını anlayabilmek için popülasyon örneklerinden oluşan bir veri setine ihtiyaç olmaktadır [28]. Örnek olarak kullanılmak istenen bir seçim havuzu ise, popülasyon, ülkedeki tüm insanları ifade etmektedir ve seçilen her bir örnek aslında popülasyonun alt veri seti olarak kabul edilmektedir. Örnek olarak aşağıdaki veri seti verilmiş olsun;

$$X = [1\ 2\ 4\ 6\ 12\ 15\ 25\ 45\ 68\ 67\ 65\ 98]$$

X sembolü burada tüm veri setini temsil etmek ve n sembolü X veri setindeki elemanları ifade etmek için kullanılmaktadır. Bu veri seti üzerinde hesaplanabilecek çok fazla özellik mevcut olmaktadır. En basit anlamda dizinin ortalama değeri (1.1)'de verilen formülde gösterildiği gibi hesaplanabilmektedir (\bar{X} ifadesi, X veri setinin ortalama değerini göstermektedir).

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} \quad (1.1)$$

(1.1)'de verilen formülden anlaşıldığı gibi ortalama, veri setindeki tüm değerlerin toplanıp veri setindeki sayıya bölünmesiyle hesaplanmakta ve ortalama değer veri seti hakkında bilgi vermemektedir. Altta verilen iki örnek veri seti için de ortalama değer aynı olup 10 değerine sahiptir fakat setler birbirinden tamamen farklı olmaktadır.

$$[0\ 8\ 12\ 20] \text{ ve } [8\ 9\ 11\ 12]$$

Bu veri setlerinin değerleri farklı olduğundan dağılımları da farklı olmaktadır. Standart sapma değeri bu dağılımların nasıl olduğu konusunda bilgi vermektedir. En genel anlamda standart sapma, veri setinin ortalama değerinden bir noktaya olan uzaklığını ifade etmekte, her noktanın ortalama değere olan uzaklığının karesinin toplamının $(n - 1)$ 'e bölünmesinden elde edilmekte ve (1.2)'de verilen denklem yardımıyla hesaplanmaktadır (s standart sapmayı ifade eden genel semboldür).

$$s = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{(n-1)}} \quad (1.2)$$

Aşağıda belirtilmiş olan $[0\ 8\ 12\ 20]$ dizisine ait standart sapma değerinin hesaplanma aşamaları Tablo 1.2'de verilmiştir.

Tüm elemanları aynı olan $[10\ 10\ 10\ 10]$ dizisini ele alındığında dizinin ortalaması 10 olarak hesaplanmakta ve tüm elemanları aynı değere sahip olduğundan standart sapması sıfır olmaktadır.

Varyans, veri setindeki verinin dağılımını ifade eden ve standart sapmaya oldukça benzer başka bir ölçüt olmaktadır [28].

Tablo 1.2. [0 8 12 20] Dizisine ait standart sapma deęerinin hesaplanması

X	$(X - \bar{X})$	$(X - \bar{X})^2$
0	- 10	100
8	-2	4
12	2	4
20	10	100
Toplam		208
$(n - 1)$ 'e bölüm sonucu		69.333
Karekök		8.3266

$$s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{(n-1)} \quad (1.3)$$

(1.3)'teki formülden de anlaşıldığı gibi standart sapmanın karesi olarak da ifade edilmekte ve s^2 bir örneęe ait varyansın genel sembolü olmaktadır. Her iki ölçüm de verinin dağılımını ifade etmekte fakat daha çok standart sapma tercih edilmektedir.

1.10.1.2. Kovaryans Matris

Daha önceki bölümlerde bahsedilen standart sapma ve varyans deęerleri 1-Boyut (1-B) söz konusu olduğunda geçerli olmaktadır. Fakat bazı durumlarda boyut sayısı birden fazla olmakta ve bu boyutlar arasında herhangi bir ilişki olup olmadığını anlamak için veri üzerinde analiz yapmak gerekmektedir [28]. Bu tarz durumlar söz konusu olduğunda kovaryans deęeri ölçümlendirilmektedir. 1-B'de kovaryans hesaplamak aslında varyans hesaplamayı ifade etmektedir.

3-Boyutlu (3-B) (x, y, z) veri seti üzerinde kovaryans sırasıyla $(x$ ve $y)$ boyutları, $(z$ ve $y)$ boyutları ve $(x$ ve $z)$ boyutları arasında hesaplanmaktadır. Kovaryans formülü varyans formülüne çok benzemekte ve varyans formülü aynı zamanda (1.4)'teki denklemde gösterildiği gibi yazılabilmektedir.

$$var(X) = \frac{\sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})}{(n-1)} \quad (1.4)$$

(1.4)'te verilen formül, (1.5)'te olduğu gibi kovaryans hesaplanacak şekle dönüştürülebilmektedir.

$$kov(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{(n-1)} \quad (1.5)$$

Eğer veri seti 2 boyuttan daha fazlaysa, hesaplanması gereken bir boyuttan daha fazla kovaryans vardır. Genelleştirildiğinde; n -boyutlu veri seti için $\frac{n!}{(n-2)! \cdot 2}$ farklı kovaryans değeri hesaplanması gerekmektedir. Farklı boyutlar arasında olabilecek tüm kovaryans değerlerini hesaplamak için en doğru çözüm, değerleri bir matris içerisinde tutmaktır. Kovaryans matrisin en önemli özelliği simetrik olmasıdır. n boyutlu veri seti için matris tanımı (1.6)'da verildiği gibi yapılabilir. $K_{n \times n}$, n satır ve n sütundan oluşan bir matristir.

$$K_{n \times n} = (k_{i,j}, k_{i,j} = kov(Boyut_i, Boyut_j)) \quad (1.6)$$

1.10.1.3. Özdeğerler ve Özvektörler

Özvektörler matrislerin özel bir görünümü olarak ifade edilebilirler [64]. $n \times n$ 'lik bir matrisin n adet özvektörü vardır. Matrisin tüm özvektörlerinin kaç boyutlu olduğunun önemi olmadan diktirler, diğer bir deyişle bu vektörler ortogonal denilmektedir [87].

Bir vektörün uzunluğu onun özvektör olup olmasını etkilemez fakat yönü bu durumu etkilemektedir. Özvektörleri standart tutmak için, normalize etmek gerekmektedir [28]. Daha sonra tüm vektörlerin boyları aynı olmaktadır.

Özdeğerler, özvektörlerle yakından ilişkilidirler. Özdeğerler dinamik problemlerde çok önemli bir değere sahiptirler. Bir A matrisi düşünelim ve bu matrisin A^{100} 'üncü değerini hesaplamamız gerekirse A matrisini 100 defa kendisiyle çarparak değil A matrisinin özdeğeri yardımıyla sonucu hesaplamak çok daha basit olmaktadır.

1.10.1.4. Temel Bileşenler Analizi Örnek Çözüm

Temel Bileşenler Analizi veri setinin paternini belirlemede en ideal yöntemdir. Yöntem adımları ise aşağıdaki şekildedir:

Adım 1: Herhangi sayıda veri içeren veri seti alınır.

Adım 2: Veri boyutlarının her biri için ortalama vektörü hesaplanır.

Tablo 1.3. Örnek olarak verilen x ve y dizilerinin ortalama vektörleri

x	Y	\bar{x}	\bar{y}
2.5	2.4	0.69	0.49
0.5	0.7	-1.31	-1.21
2.2	2.9	0.39	0.99
1.9	2.2	0.09	0.29
3.1	3.0	1.29	1.09
2.3	2.7	0.49	0.79
2	1.6	0.19	-0.31
1	1.1	-0.81	-0.81
1.5	1.6	-0.31	-0.31
1.1	0.9	-0.71	-1.01

(x için \bar{x} ve y için \bar{y}) Bu işlem sonucunda ortalama değeri sıfır olan yeni bir veri seti üretilir.

Adım 3: Dizinin boyutu kadar kare matrise eşit olan kovaryans matris hesaplanır. Verilen diziler için kovaryans matrisin değeri aşağıda hesaplandığı gibi olmaktadır.

$$Kovaryans = \begin{bmatrix} 0.6166 & 0.6154 \\ 0.6154 & 0.7166 \end{bmatrix}$$

Adım 4: Kovaryans matrise ait özdeğerler ve özvektörler hesaplanır. Kovaryans matris, kare matris olduğundan özdeğerleri ve özvektörleri bu matris üzerinden hesaplanmaktadır.

$$Özdeğerler = \begin{bmatrix} 0.0491 \\ 1.2840 \end{bmatrix}$$

$$\text{Özvektörler} = \begin{bmatrix} -0.7352 & -0.6779 \\ 0.6779 & -0.7352 \end{bmatrix}$$

Veri setindeki en yüksek özdeğere sahip özvektörler veri setinin temel bileşenlerini ifade etmekte ve özdeğerler önem sırasına göre sıralanmaktadır. Bu esnada küçük değere sahip olan özdeğerler atılmakta dolayısıyla bir miktar veri kaybı söz konusu olmaktadır. Buna bağlı olarak işlem sonunda, asıl veri setinden daha az boyutlu bir veri seti elde edilmektedir. Eğer orijinal veri n boyutlu ise n tane özdeğer ve özvektör hesaplanmakta daha sonra ilk p tane özvektör seçilmekte, buna bağlı olarak yeni veri seti de p boyutlu olmaktadır.


Adım 5: Yeni veri seti oluşturulur.

1.11. Sınıflandırma Yöntemleri

1.11.1. k En Yakın Komşu Algoritması

k en yakın komşuluk algoritması sınıflandırma problemleri ve makine öğrenmesi uygulamalarında kullanılan basit bir öğrenme algoritması olmasının yanı sıra komşuluklara dayalı bir sınıflandırma yöntemidir [29]. Algoritmanın önemli bir avantajı model oluşturmadan sınıflandırma yaptığından çok fazla zaman harcanmamaktadır [88]. k değeri küçük seçildiğinde algoritma kötü etkilenebilmekte buna karşılık büyük seçildiğinde sadece bir sınıf varmış gibi sonuç almaya sebep olmakta olduğundan k değerini belirlemek oldukça önemli olmaktadır [89].

Eğitim örneklerine koşma zamanında (run time) ihtiyaç olduğundan bazen Hafıza Tabanlı sınıflandırıcı olarak da adlandırılmaktadır. Ayrıca örnekleri taşıma işlemi koşma zamanında gecikmeye sebep olduğundan “Lazy Learning” tekniği olarak da bilinmektedir [29]. Bunun yanında sınıflandırma eğitim örneklerine bağlı olduğundan örnek tabanlı sınıflandırma ya da durum tabanlı sınıflandırma olarak da bilinmektedir [29].



Şekil 1.7. 2-boyutlu 2 sınıflı k -EYK sınıflandırıcı örneği

Sınıflandırıcının temel mantığı Şekil 1.7’de verilmektedir. Örnek şekilde 3 tane yakın komşuluk için algoritma 2-B ve 2 sınıflı olarak belirlenmiştir. Dağılıma göre “a” örneği için karar gayet açık olmaktadır. Seçilen 3 yakın komşusu da *Sınıf 1*’den olduğundan “a” örneği de aynı sınıfa dahil edilmektedir. “b” örneği için durum biraz daha karışık olmakta çünkü yakın 2 komşusu *Sınıf 2*’ye ait iken bir komşusu da *Sınıf 1*’e ait olmakta ve problem de basit oylama işlemi yapılarak çözülebilmektedir. Tüm bu özellikler göz önüne alındığında k -EYK sınıflandırıcı için 2 önemli özellik söz konusudur [29].

- 1) En yakın komşuluklara göre karar verme durumu
- 2) Bu komşuluklardan faydalanarak örneğin ait olduğu sınıfa karar verme durumu

Elimizde D eğitim seti olduğunu ve bu eğitim setinin de x_i ’lerden oluştuğunu ve örneklerin de F özellik setinden tanımlanmış olduğunu varsayalım. Herhangi sayıda olabilen bu özellikler $[0,1]$ aralığına çekilmiş ve her eğitim örneği de bir sınıf etiketiyle $y_j \in Y$ ile etiketlenmiş olsun. Buradaki amaç bilinmeyen q örneğinin hangi sınıfa ait olduğunu tespit etmektir. Bunun için her $x_i \in D$ için q ve x_i arasındaki uzaklık denklem (1.7)’de verilen bağıntı yardımıyla hesaplanmaktadır.

$$d(q, x_i) = \sum_{f \in F} w_f f(q_f, x_{if}) \quad (1.7)$$

Bu uzaklık metriğinin hesabı için çok fazla olabilirlik mevcuttur. Sürekli ve ayrık problemler söz konusuysa sonuç denklem (1.8)’de gösterildiği gibi olmaktadır.

$$\delta(q_f, x_{if}) = \begin{cases} 0 & f \text{ ayrık ve } q_f = x_{if} \text{ olduğunda} \\ 1 & f \text{ ayrık ve } q_f \neq x_{if} \text{ olduğunda} \\ |q_f - x_{if}| & f \text{ sürekli olduğunda} \end{cases} \quad (1.8)$$

k tane en yakın komşular da bu uzaklık metriğine bağlı olarak seçilmektedirler [90]. Hangi en yakın komşuların bilinmeyen örneğin sınıfını belirlemede kullanılacağına karar vermek için de birçok yol bulunmaktadır [29].

Uzaklıkları hesaplariken en çok tercih edilen yöntem öklid uzaklık ölçütüdür. Bunun yanında Manhattan ve Minkowski uzaklık ölçütleri de sıkça tercih edilmektedir. Verilen ölçütlerin denklemleri de (1.9), (1.10) ve (1.11)'de sıralandığı gibi olmaktadır.

$$d_E = \sqrt{\sum_{i=0}^N (x_i - y_i)^2} \quad (1.9)$$

$$d_M = \sum_{i=0}^N |x_i - y_i| \quad (1.10)$$

$$d_m = (\sum_{i=0}^{n-1} |x_i - y_i|^p)^{\frac{1}{p}} \quad (1.11)$$

Tablo 1.4. x_1 ve x_2 dizileri ve bu dizilerin ait olduğu sınıflar

x_1	x_2	Sınıf
2	4	A
3	6	B
3	4	B
4	10	A
5	8	A
6	3	B
7	9	B
9	7	A
11	7	A

Tablo 1.4'te verildiği gibi 10 tane örneğimiz olduğunu varsayalım [49]. Yeni gelen örneğe ait (x_1, x_2) değerleri $(8, 4)$ olarak verilirse k -EYK sınıflandırıcı yardımıyla hangi

sınıfa ait olduğunu $k = 4$ için bulalım. Her bir noktaya olan uzaklıklar öklid ölçütü (1.9) yardımıyla hesaplanırsa;

$$d_1(i, j) = \sqrt{(2 - 8)^2 + (4 - 4)^2} = \sqrt{36} = 6$$

$$d_2(i, j) = \sqrt{(3 - 8)^2 + (6 - 4)^2} = \sqrt{29} = 5.39$$

$$d_3(i, j) = \sqrt{(3 - 8)^2 + (4 - 4)^2} = \sqrt{25} = 5$$

$$d_4(i, j) = \sqrt{(4 - 8)^2 + (10 - 4)^2} = \sqrt{36} = 7.21$$

$$d_5(i, j) = \sqrt{(5 - 8)^2 + (8 - 4)^2} = \sqrt{25} = 5$$

$$d_6(i, j) = \sqrt{(6 - 8)^2 + (3 - 4)^2} = \sqrt{5} = \mathbf{2.24}$$

$$d_7(i, j) = \sqrt{(7 - 8)^2 + (9 - 4)^2} = \sqrt{26} = 5.10$$

$$d_8(i, j) = \sqrt{(9 - 8)^2 + (7 - 4)^2} = \sqrt{10} = \mathbf{3.16}$$

$$d_9(i, j) = \sqrt{(11 - 8)^2 + (7 - 4)^2} = \sqrt{18} = \mathbf{4.24}$$

$$d_{10}(i, j) = \sqrt{(10 - 8)^2 + (2 - 4)^2} = \sqrt{8} = \mathbf{2.83}$$

Hesaplanan bu değerlerden en yakın 4 komşusu d_6 , d_8 , d_9 , ve d_{10} olmaktadır. Buradan çoğunluk A sınıfına ait olduğundan, örnek de A sınıfına dahil edilmektedir.

k -EYK algoritmasını genel olarak aşağıdaki gibi özetlemek mümkündür:

- k tane yakın komşuluk belirlenir.
- Yeni gelen örnek ile özellik uzayında bulunan ve seçilmiş yakın komşuluklar arasında uzaklık ölçütlerini kullanarak uzaklık hesabı yapılır.
- Uzaklıklar sıralanır.
- Yeni gelen örneğin hangi sınıfa ait olduğu belirlenir.
- Değeri yakın olan sınıf belirlenir.

1.11.2. Destek Vektör Makineleri

1980'lerden önde neredeyse tüm öğrenme yöntemleri basit teorik özellikler içeren lineer karar yüzeylerini kullanmışlardır [33]. 1980'lerde Karar Ağaçları ve Yakın Komşuluklar gibi lineer olmayan karar yüzeyleri kullanılmaya başlanmıştır. 1990'larda ise öğrenme teorisine dayalı lineer olmayan fonksiyonlar için etkili öğrenme algoritmaları geliştirilmiştir [31]. Bu algoritmalar genel olarak istatistiksel öğrenme algoritmaları olarak adlandırılmakta ve istatistiksel öğrenme teorisi bir tahmin problemi olarak da düşünülmektedirler [48].

DVM sınıflandırma, regresyon (iki ya da daha çok değişken arasındaki ilişkiyi ölçmek için kullanılan analiz metodu) ve yoğunluk tahmini için Vapnik tarafından ortaya atılmış bir makine öğrenmesi algoritması olmaktadır [3,32]. Yöntem ismini ayırıcı düzlem üzerinde bulunup destek vektörleri olarak adlandırılan vektörlerden almaktadır [38]. Bu vektörlerin karar doğrularının yerleşimi üzerinde oldukça büyük bir etkisi bulunmakta ve sınıflandırılmaları da oldukça zor olmaktadır. Doğruların en doğru şekilde düzleme yerleştirilmesi optimizasyon problemi olarak adlandırılmaktadır [40].

DVM, veriyi doğrusal ayırışamadığı durumda daha yüksek boyuta taşıyıp üst boyutta lineer ayrıştırılmasını sağlamaktadır. Bu lineer ayrışımın gerçekleşebilmesi için parametre optimizasyonu ve kernel fonksiyon seçimi çok önemli bir rol oynamaktadır [40].

1.11.2.1. Doğrusal Destek Vektör Makineleri

1.11.2.1.1. Doğrusal Ayrılabilen Veriler İçin İkili Sınıflandırma Teorisi


D – boyutlu L adet eğitim noktası $\{x_i, y_i\}$ formunda gösterilmiş ve $y_i \in \{-1, 1\}$ etiketlerine sahip olsun ($i = 1 \dots L$). Veriler lineer ayrılabilir olduklarında tek bir ayırıcı doğru yardımıyla sınıfları birbirlerinden ayırmak mümkün olmaktadır [33]. Ayırıcı hiper düzlem (1.12)'deki denklemde gösterildiği gibi hesaplanmaktadır.

$$w \cdot x + b = 0 \quad (1.12)$$

Denklemdaki w değeri, Şekil 1.8'de görüldüğü gibi hiper düzlemin normali, $b/\|w\|$ ise hiper düzlemden merkeze olan dik uzaklığı ifade etmektedir. Şekil 1.8'deki bilgilerden yola çıkılarak hiper düzlemin hesaplanması için gerekli olan w ve b değişkenleri farklı sınıflara ait eğitim verileri (1.13) ve (1.14)'teki eşitsizliklerle ifade edilmektedirler.

$$x_i \cdot w + b \geq +1 \quad y_i = +1 \quad (1.13)$$

$$x_i \cdot w + b \leq -1 \quad y_i = -1 \quad (1.14)$$



Şekil 1.8. Doğrusal ayrılabilen iki sınıfı ayıran hiper düzlem

Yukarıda verilen denklemler düzenlenip birleştirildiğinde (1.15)'te gösterilen formda ifade edilmektedir.

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad (1.15)$$

Destek vektörlerinin üzerinde bulunduğu ayırıcı yüzeyler için denklemler aşağıda verilen (1.16) ve (1.17)'de verildiği gibi olmaktadır.

$$x_i \cdot w + b = +1, \quad H_1 \text{ doğrusu söz konusu olduğunda} \quad (1.16)$$

$$x_i \cdot w + b = -1, \quad H_2 \text{ doğrusu söz konusu olduğunda} \quad (1.17)$$

Şekil 1.8'de d_1 değeri H_1 ile ifade edilen ayırıcı yüzeyden hiper düzleme olan uzaklığı ve d_2 değeri H_2 ile ifade edilen ayırıcı yüzeyden hiper düzleme olan uzaklığı göstermektedir.

Hiper düzlemin destek vektörlerinin üzerinde bulunduğu ayırıcı yüzeylerden olabildiğince uzağa yerleştirilmesi gerekmektedir [33]. Yani marjinin maksimum olmasını sağlamalıdır [37]. Basit vektör geometrisi düşünüldüğünde $margin = 1/\|w\|$ formülüyle hesaplanmaktadır. Denklem kısıtlara bağlı olarak yeniden düzenlendiğinde (1.18)'deki formül elde edilmektedir.

$$\text{minimum } \|w\| \rightarrow y_i(x_i \cdot w + b) - 1 \geq 0 \quad \forall_i \text{ için} \quad (1.18)$$

$\|w\|$ 'yi minimum yapmak demek aynı zamanda $\frac{1}{2} \|w\|^2$ işleminden elde edilen sonucu da minimum yapmak demektir. Dolayısıyla formülde $\|w\|$ yerine $\frac{1}{2} \|w\|^2$ değeri kullanılabilir. (1.18)'de verilen denklem (1.19)'da olduğu gibi yeniden düzenlenebilir.

$$\text{minimum } \frac{1}{2} \|w\|^2 \rightarrow y_i(x_i \cdot w + b) - 1 \geq 0 \quad \forall_i \text{ için} \quad (1.19)$$

Ortaya çıkan kısıtlamalı optimizasyon probleminin çözümü için Lagrange Çarpanları metodu (1.20), (1.21) ve (1.22)'de verilen denklemlerde gösterildiği gibi kullanılmaktadır. Yöntem kullanılırken $a_i > 0$ koşulu dikkate alınmaktadır.

$$L_p = \frac{1}{2} \|w\|^2 - a[y_i(x_i \cdot w + b) - 1] \quad \forall_i \text{ için} \quad (1.20)$$

$$= \frac{1}{2} \|w\|^2 - \sum_{i=1}^L a_i [y_i(x_i \cdot w + b) - 1] \quad (1.21)$$

$$= \frac{1}{2} \|w\|^2 - \sum_{i=1}^L a_i y_i [(x_i \cdot w + b)] + \sum_{i=1}^L a_i \quad (1.22)$$

Denklemin çözümünde w katsayısını ve b sabit değerini minimize, a değerini de maksimize etmek gerekmektedir. Bu işlemler yapılırken $a_i > 0$ koşulunun da her zaman sağlanıyor olması gerekmektedir. Değerlerin hesaplanabilmesi için yukarıda verilen denklemin sırasıyla w (1.23) ve b 'ye (1.24) göre türevlerinin alınması gerekmektedir.

$$\frac{\partial L_p}{\partial w} = 0 \rightarrow w = \sum_{i=1}^L a_i y_i x_i \quad (1.23)$$

$$\frac{\partial L_p}{\partial b} = 0 \rightarrow w = \sum_{i=1}^L a_i y_i = 0 \quad (1.24)$$

Yukarıda verilen (1.23) ve (1.24) denklemlerinden yola çıkarak, a değerine bağlı olarak çözümün dual formu (1.25), (1.26) ve (1.27)'de verilen denklemlerde olduğu gibi elde edilmektedir.

$$L_D = \sum_{i=1}^L a_i - \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j x_i \cdot x_j \quad a_i > 0 \quad \forall_i \text{ için}, \quad \sum_{i=1}^L a_i y_i = 0 \quad (1.25)$$

$$= \sum_{i=1}^L a_i - \frac{1}{2} \sum_{i,j} a_i H_{i,j} a_j \quad \text{ve} \quad H_i = y_i y_j x_i \cdot x_j \quad (1.26)$$

$$= \sum_{i=1}^L a_i - \frac{1}{2} a^T H a \quad a_i > 0 \quad \forall_i \text{ için}, \quad \sum_{i=1}^L a_i y_i = 0 \quad (1.27)$$

Lagrange çarpanları yardımıyla, denklem (1.28)'de gösterildiği gibi çözülmektedir.

$$\text{maks}_a \left[\sum_{i=1}^L a_i - \frac{1}{2} a^T H a \right] \quad a_i > 0 \quad \forall_i \text{ için}, \quad \sum_{i=1}^L a_i y_i = 0 \quad (1.28)$$

Verilen denklemlerde de görüldüğü gibi primal formda değerler minimize edilmeye çalışılırken dual formda maksimize edilmeye çalışılmaktadır [33]. İşlemin bu aşamasında en optimum hiper düzlemin hesaplanması için sadece b değerinin hesaplanması kalmaktadır. Bu değere göre türev aldığımız (1.29)'daki denklemde herhangi bir x_s noktası destek vektörü olarak adlandırılmaktadır.

$$y_s (x_s \cdot w + b) = 1 \quad (1.29)$$

$$y_s (\sum_{m \in S} a_m y_m x_m \cdot x_s + b) = 1 \quad (1.30)$$

(1.30)'da verilen denklemin her iki tarafı y_s (denklem (1.31)'deki gibi) ile çarpılmakta, verilen ilk iki denklemden $y_s^2 = 1$ olmakta ve denklemin yeni hali (1.32)'deki halini almaktadır.

$$y_s^2 (\sum_{m \in S} a_m y_m x_m \cdot x_s + b) = y_s \quad (1.31)$$

$$b = y_s - \sum_{m \in S} a_m y_m x_m \cdot x_s \quad (1.32)$$

Keyfi destek vektörleri olan x_s 'yi kullanmak yerine tüm destek vektörlerinin ortalamasını alarak kullanmak daha doğru bir yaklaşımdır.

$$b = \frac{1}{N} \sum_{s \in S} (y_s - \sum_{m \in S} a_m y_m x_m \cdot x_s) \quad (1.33)$$

Bu işlem de tamamlandıktan sonra en optimum hiper düzlemi hesaplamamızı sağlayan w ve b değerleri (1.33)'teki denklemde verildiği gibi elde edilmiş olmaktadır.

1.11.2.1.2. Doğrusal Ayrılamayan Veriler İçin İkili Sınıflandırma Teorisi

Uygulamalarda veri setindeki örneklerin, genellikle doğrusal olarak ayrılması Şekil 1.16'da görüldüğü gibi mümkün olmamaktadır. Bu durumda sınıflar birbirlerinden ufak bir hata payı ile ayrılabilirler. Hatalı ayırmanın sebebi ise veri setinde çok fazla gürültülü veri bulunması, verinin çok boyutlu olması ya da karmaşık yapıda olmasından kaynaklanmaktadır [40]. Literatürde doğrusal olarak ayrılamayan veriler için farklı DVM yöntemleri geliştirilmiştir.


Veriler doğrusal olarak ayrılamadığında Şekil 1.9'da olduğu gibi bir veri yanlış sınıfa ait kısımda kalabilmektedir. Bu durumda sınıflandırma yanlış gerçekleşmektedir. Bu problemin önüne geçebilmek amacıyla aşağıdaki denklemlere $\xi_i \geq 0 \forall_i$ ($i = 1 \dots L$) koşulunu sağlayan gevşek değişken (1.34) ve (1.35)'de verilen denklemlerde olduğu gibi eklenmektedir [33, 35].

$$x_i \cdot w + b \geq +1 - \xi_i \quad y_i = +1 \text{ için} \quad (1.34)$$

$$x_i \cdot w + b \leq -1 + \xi_i \quad y_i = -1 \text{ için} \quad (1.35)$$

Yukarıda verilen iki denklem de (1.36)'da verilen denklemdeki gibi birleştirilebilmektedir.

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad \xi_i \geq 0 \forall_i \quad (1.36)$$



Şekil 1.9. Doğrusal olarak ayrılmayan veriler için ayırıcı hiper düzlem örneği

Şekil 1.9'da görüldüğü gibi oluşan yanlış sınıflandırma hatalarını minimize edebilmek ve marjin büyüklüğünü de olabilecek en büyük değere çekmek amacıyla fonksiyon (1.37)'deki denklemde olduğu gibi düzenlenmektedir.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^L \xi_i \quad (1.37)$$

(1.37)'de görüldüğü gibi C parametresi denkleme eklenmekte olup bu parametre gevşek değişken ile marjin büyüklüğü arasındaki trade-off'u (bir değer artarken diğerinin azalması) kontrol etmektedir [33]. Ayrıca C parametresi ile Lagrange çarpanı olan a değerinin eşit olması destek vektörlerinin ayırıcı hiper düzlem üzerinde bulunduğunu ifade etmektedir [40]. Formül Lagrange metoduyla ve $a_i \geq 0$ ve $\mu_i \geq 0 \quad \forall_i$ şartları altında yeniden (1.38)'deki denklemde gösterildiği gibi düzenlenebilmektedir.

$$L_p = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^L \xi_i - \sum_{i=1}^L a_i [y_i(x_i \cdot w + b) - 1 + \xi_i] - \sum_{i=1}^L \mu_i \xi_i \quad (1.38)$$

Verilen denklemin w, b ve ξ'_i ye göre ayrı ayrı türevleri alınıp sifıra eşitlenirlerse (1.39), (1.40) ve (1.41)'de verilen denklemler elde edilmektedir.

$$\frac{\partial L_p}{\partial w} = 0 \quad \rightarrow \quad w = \sum_{i=1}^L a_i y_i x_i \quad (1.39)$$

$$\frac{\partial L_p}{\partial b} = 0 \quad \rightarrow \quad \sum_{i=1}^L a_i y_i = 0 \quad (1.40)$$

$$\frac{\partial L_p}{\partial \xi_i} = 0 \quad \rightarrow \quad C = a_i + \mu_i \quad (1.41)$$


Bu eşitlikler elde edildikten sonra formülün dual formu $0 \leq a_i < C$ şartına bağlı olarak düzenlenebilmektedir. Dual formdan a 'nın maksimum değeri aşağıdaki (1.42) ve (1.43)'te verilen denklemlerde olduğu gibi hesaplanmaktadır.

$$\max_a \left[\sum_{i=1}^L a_i - \frac{1}{2} a^T H a \right] \quad (1.42)$$

$$\sum_{i=1}^L a_i y_i = 0 \quad (1.43)$$

1.11.2.2. Doğrusal Olmayan Destek Vektör Makineleri

Verilerin doğrusal olarak da belirli bir hata miktarıyla da birbirinden ayıramaması durumunda kullanılması gereken DVM türüdür [35]. Bu durumda Şekil 1.10'da görülen dağılım söz konusu olmaktadır ki gerçek yaşamdaki veri setlerinin doğrusal olarak ayrışması çoğunlukla söz konusu olmadığından bu yöntem literatürde çokça rastlanılan yöntemler arasında yerini almaktadır [33]. Bu tarz problemlerde ayırıcı düzlemin yerleştirileceği en ideal yeri tespit etmek amacıyla kernel fonksiyonlardan faydalanılmaktadır.




Şekil 1.10. Doğrusal ayrılamayan verilere ait örnek gösterim

Verilerin doğrusal ayrılmadığı ve belirli bir hata oranıyla da ayrılmadığı durumda verileri kernel fonksiyonlar yardımıyla daha yüksek boyutlu bir uzaya taşıyıp, Şekil 1.11’de görüldüğü gibi bu uzayda lineer ayrıştırma işlemi gerçekleştirilmektedir [38].

Literatürde yüksek boyutta ayrıştırma gerçekleştirmek için kullanılan çok sayıda kernel fonksiyonu bulunmakta ve bunlardan bazıları aşağıda listelenmektedir.

- $K(u, v) = v^T u$ (Lineer Çekirdek Fonksiyonu)
- $K(u, v) = (v^T u + 1)^n$ (Polinomsal Çekirdek Fonksiyonu)
- $K(u, v) = \exp(-\|u - v\|^2 / 2\sigma^2)$ (Radyal Tabanlı Çekirdek Fonksiyonu)

Bir fonksiyonun çekirdek fonksiyonu olabilmesi için Mercer Şartlarını sağlaması gerekmektedir [33]. Uygun çekirdek fonksiyonunun seçimi ve seçilen fonksiyon için en ideal parametre değerinin belirlenmesi oldukça önemlidir.



Şekil 1.11. Bir üst boyuta taşınarak doğrusal ayrışması sağlanmış örnek veri dağılımı

Mercer Şartları

Yüksek boyuta taşınacak problemlerde göz önüne alınması gereken önemli bir kıstas olmaktadır [34]. Doğrusal olarak ayrışmayan DVM'nin temelinde kernel fonksiyonları yardımıyla veriyi üst uzaya taşımak ve yeni uzayda en uygun hiper düzlem yardımıyla doğrusal ayrışmalarını sağlamak vardır. Kullanılan kernel fonksiyonu aşağıda listelenen mercer şartlarını sağlamak zorundadır.

- $K(x, y) = K(y, x)$
- $\iint K(x, y)f(x)f(y)dxdy \geq 0$

1.11.3. Yapay Sinir Ağları

Karmaşık problemlerin çözümünde en etkili yol “böl ve yönet” mantığı olmaktadır [70]. Karmaşık sistemler daha basit parçalara bölündüğünde elde edilen sonuçlar daha etkili olmaktadır ki yapay sinir ağları da bu tarz problemlerin üstesinden gelebilecek bir yöntem olmaktadır. Yöntem basit veya karmaşık olarak nitelendirilebilmekte ve basit olması girişten verilen değer hesaplanıp çıkışa verilmesini, karmaşık olması ise bir düğümde bir ağ daha olmasını ifade etmektedir [70].

Yapay sinir ağı, insan beyninde oluşan anlam gücüne benzer bir hesaplamayı gerçek yaşamda sağlamaktadır [71]. Yapay sinir ağının temel elemanı yapay nöronlar ya da nöronlar olarak adlandırılmaktadırlar. Nöronlar katmanlarda çalışmakta, birbirlerine bağlantılarla bağlanmakta ve bağlantılar da düğümler arasındaki bilgi akışını belirlemektedirler [72]. Her bağlantının sayısal bir değeri bulunmaktadır ki buna da ağırlık yani “weight” denilmektedir.

1.11.3.1. Yapay Sinir Ağlarının Tarihçesi

YSA'nın ilginç bir hikâyesi vardır. 1943 yılı genellikle yapay sinir sistemlerinin gelişmeye başladığı ilk yıllar olarak kabul edilmektedir. McCulloch ve Pitts, 1943 yılında ilk temel bilgisayar nöron modelinin taslağını çizmişlerdir [73,74]. Model aritmetik işlemleri gerçekleştirebilmek için gerekli tüm elemanları içermekteydi [75].

Donald Hebb 1949 yılında nöron bağlantılarını güncellemek için ilk öğrenme şemasını önermiştir ki bu işlem “Hebbian Öğrenme Kuralı” olarak bilinmektedir [75,76].

Hebb, bilgilerin bağlantılarda saklanabileceğini duyurmuş ve Hebb'in öğrenme kuralı yapay sinir ağı teorisine büyük katkıda bulunmuştur.

1950'lerde ilk nöral bilgisayarlar Minsky tarafından yapılmış ve test edilmiştir [77]. Bu süreçte, nörona benzer eleman olan perseptron Frank Rosenblatt tarafından keşfedilmiştir [75,78].

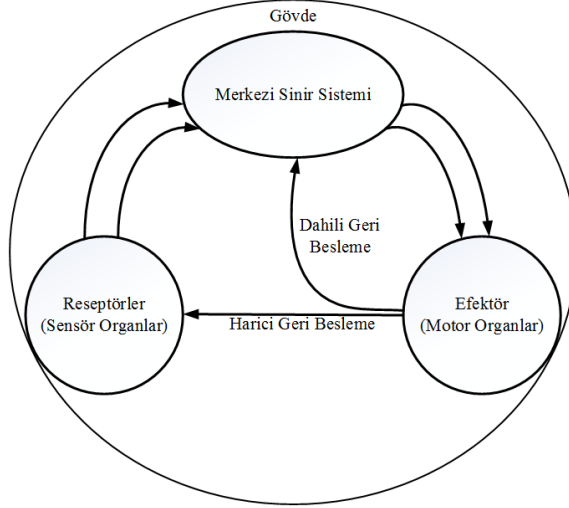
1960'ın ilk zamanlarında ADALINE (ADaptive LINEar combiner) olarak adlandırılan cihaz tanıtılmış ve yeni, güçlü öğrenme kuralı olarak adlandırılan Widrow-Hoff öğrenme kuralı Bernard Widrow ve Marcian Hoff tarafından geliştirilmiştir [75]. ADALINE'in ilk uygulamaları ve onun geliştirilmiş sürümü olan MADALINE (Many ADALINE) ise örüntü tanıma, hava tahmini ve adaptif kontroller yapabilmekteydi [75].

1960'lardaki başarı ve ilgiye rağmen var olan makine öğrenmesi teorileri karmaşık problemlerin çözümünde çok zayıf kalmaktaydı. 1965'ten 1984'e kadar az sayıda araştırmacı tarafından kendinden sonraki çalışmalara öncü olacak araştırmalar gerçekleştirilmiştir. Japonya'da Kunihiro Fukushima tarafından "neocognitrons" olarak bilinen ve görsel örüntü tanıma modeli olan sinir ağı mimarisi geliştirilmiştir [75,79].

1986-1987'nin başlarında ise çok sayıda yeni sinir ağı programı ortaya atılmış ve buna bağlı olarak araştırmaların yoğunluğu artan konferans ve dergilerle desteklenmiştir.

1.11.3.2. Biyolojik Nöronlar ve Yapay Nöron Modelleri

İnsan beyni yaklaşık olarak 10^{11} tane nöron içermektedir [72]. Nöronlar birbirleriyle iletişime aksonlar ve sinapslar üzerinden geçmektedirler. Sinir ağı çok sayıda bağlantıdan oluşan karmaşık bir yapı olmaktadır. Ağa giriş, duyu organları kadar iyi uyarıcı (nöronların ağı boyunca akan elektriksel işaretler) alan duyu reseptörleri tarafından sağlanmaktadır [75]. Sonuç olarak bilgi, merkezi sinir sisteminde işlenmekte ve çeşitli cevaplar şeklinde insan vücuduna cevap verilmektedir.

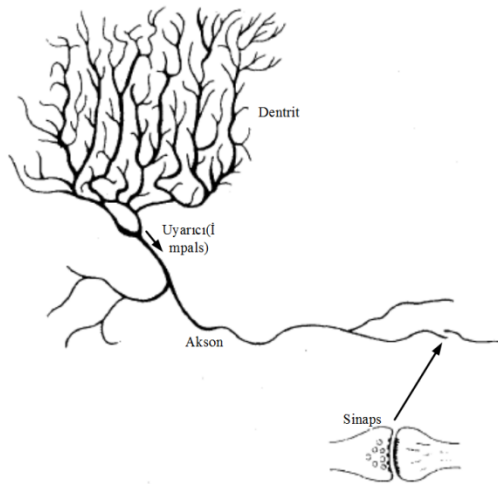


Şekil 1.12. Sinir sisteminde bilgi akışı

Şekil 1.12’de görüldüğü gibi bilgiler işlenmiş, değerlendirilmiş ve sinir sistemindeki bilgiyle karşılaştırılmıştır.

1.11.3.2.1. Biyolojik Nöron Yapısı

Şekil 1.13’te genel yapısı verilen ve nöron olarak adlandırılan temel sinir hücreleri, biyolojik nöral yapının temelini oluşturmaktadırlar. Bu gösterim 3 ana kısımdan oluşmaktadır: soma, akson ve dentrit [80]. Dentritler, bilgileri nöronlardan almakta ve aksonlarda bilgiyi nöron boyunca taşımaktadırlar. Akson-dentrit iletişim organı, nöronun komşu nörona sinyali tanıttığı yer olan sinaps olmaktadır [80].




Şekil 1.13. Basit bir nöron yapısı

1.11.3.2.2. McCulloch-Pitts Nöron Modeli

Yapay nöron modelinin ilk resmi tanımı McCulloch ve Pitts tarafından yapılmıştır [75]. McCulloch-Pitts nöron modeli Şekil 1.14'te görüldüğü gibi olmaktadır. x_i girişleri ve o değeri de çıkışı ifade etmektedir ($i = 1 \dots n$). Bu modele ait kurallar da (1.44)'te verilen formülde belirtildiği gibi olmaktadır. Şekilde gösterilen $k = 0, 1, \dots, n$ değerleri ayırık zamanlı örnekleri ifade etmektedir. w_i değerleri ağırlık değerlerini, T değeri ise ağırlık threshold değerini ifade etmektedir.

$$o^{k+1} = \begin{cases} 1, & \sum_{i=1}^n w_i x_i^k \geq T \\ 0, & \sum_{i=1}^n w_i x_i^k < T \end{cases} \quad (1.44)$$



Şekil 1.14. McCulloch ve Pitt Modeli

1.11.3.2.3. Yapay Sinir Sistemleri için Nöron Modeli

McCulloch ve Pitt Modeli sadece ikili (0 ve 1) değerlere izin vermekte ve her nöron modeli giriş, bağlantılar ve çıkıştan oluşmaktadır [75, 91]. Sembolik temsil ağırlık setini ve düğümleri içermektedir. Nöron çıkış sinyali de aşağıda verilen (1.45) ve (1.46) denklemlerindeki ilişkiyle verilmektedir.

$$o = f(w^t x) \quad (1.45)$$

$$\text{Ya da } o = f(\sum_{i=1}^n w_i x_i) \quad (1.46)$$

w ağırlık vektörü ve x giriş vektörlerinin gösterimleri de (1.47) ve (1.48)'deki formüllerde verildiği gibi olmaktadır. t değeri ise vektörün transpozunu ifade etmektedir.

$$w = [w_1 w_2 \dots w_n]^t \quad (1.47)$$

$$x = [x_1 x_2 \dots x_n]^t \quad (1.48)$$

$f(w^t x)$ fonksiyonu, aktivasyon fonksiyonu olmakta ve bu fonksiyonun tanım kümesi de aktivasyon fonksiyonunun değerlerini ifade etmektedir. Dolayısıyla verilen nöron modeli de $f(net)$ şeklinde gösterilebilmektedir. (1.49)'daki formülde verilen net değeri giriş vektörleriyle ağırlık değerlerinin skaler çarpımını ifade etmektedir.

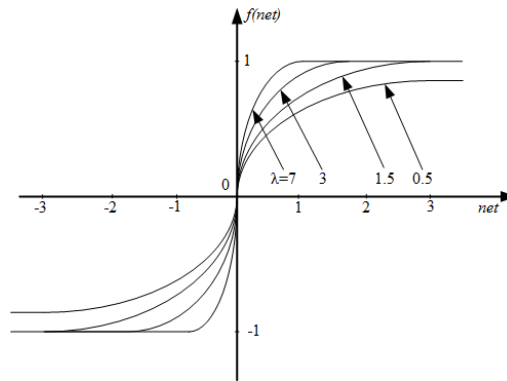
$$net = w^t x \quad (1.49)$$

Aktivasyon fonksiyonu ise tipik olarak aşağıda verilen (1.50) ve (1.51)'deki denklemlerde belirtildiği gibi olmaktadır.

$$f(net) = \frac{2}{1 + \exp(-\lambda net)} - 1 \quad (1.50)$$

$$f(net) = \text{sgn}(net) = \begin{cases} +1, & net > 0 \\ -1, & net < 0 \end{cases} \quad (1.51)$$

Sürekli aktivasyon fonksiyonu, değişen λ değerlerine bağlı olarak Şekil 1.15'te gösterildiği gibi olmaktadır.



Şekil 1.15. Bipolar sürekli ikili aktivasyon fonksiyonu

1.11.3.3. Yapay Sinir Ağları Modeli

1.11.3.3.1. İleri Beslemeli Ağlar


m nöron ve n girişten oluşan ileri beslemeli ağ mimarisi üzerine düşünürsek giriş (1.52) ve çıkış vektörleri (1.53)'de verildiği gibi ifade edilmektedirler. Basit olarak çizilmiş tek katmanlı ve ileri beslemeli örnek bir ağ yapısı Şekil 1.16'da gösterilmektedir.

$$x = [x_1 \ x_2 \ \dots \ x_n]^t \quad (1.52)$$

$$o = [o_1 \ o_2 \ \dots \ o_m]^t \quad (1.53)$$

w_{ij} ağırlığı i . nöron ve j . girişi bağlar ve i . nöron için aktivasyon fonksiyonu (1.54)'te verilen denklemdeki gibi olmaktadır.

$$net_i = \sum_{j=1}^n w_{ij}x_j \quad i = 1, 2, \dots, m \text{ için} \quad (1.54)$$



Şekil 1.16. İleri beslemeli ağ modeli (a) Bağlantı şeması, (b) Blok diyagram

Aşağıda verilmiş olan lineer olmayan eşitlik için aktivasyon fonksiyonu $f(net_i)$ olmaktadır. Ağ tarafından oluşturulan çıkış uzayını ifade eden o değeri, $o = \Gamma[Wx]$ formülüyle hesaplanmaktadır. W ağırlık, aynı zamanda da bağlantı matrisi ise (1.55)'deki gösterimde verildiği gibi olmaktadır.

$$W = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ w_{m1} & w_{m2} & \cdots & w_{mn} \end{bmatrix} \quad (1.55)$$

Bu örnek 2 katmanlı ileri beslemeli ağı temsil etmekte ve ağın yapısı Şekil 1.17'de belirtilmektedir. Aktivasyon fonksiyonu olarak bipolar ikili aktivasyon fonksiyonu kullanılmıştır. Ağın her katmanı (1.56)'daki gibi tanımlanmaktadır.

$$o = \Gamma[Wx] \quad (1.56)$$

İlk katman için giriş, ağırlık ve çıkış vektörleri sırasıyla aşağıdaki gibi olmaktadır.

$$o = [o_1 \ o_2 \ o_3 \ o_4]^t$$

$$x = [x_1 \ x_2 \ -1]^t$$

$$W_1 = \begin{bmatrix} 1 & 0 & 1 \\ -1 & 0 & -2 \\ 0 & 1 & 0 \\ 0 & -1 & -3 \end{bmatrix}$$

Benzer olarak 2. katman için:

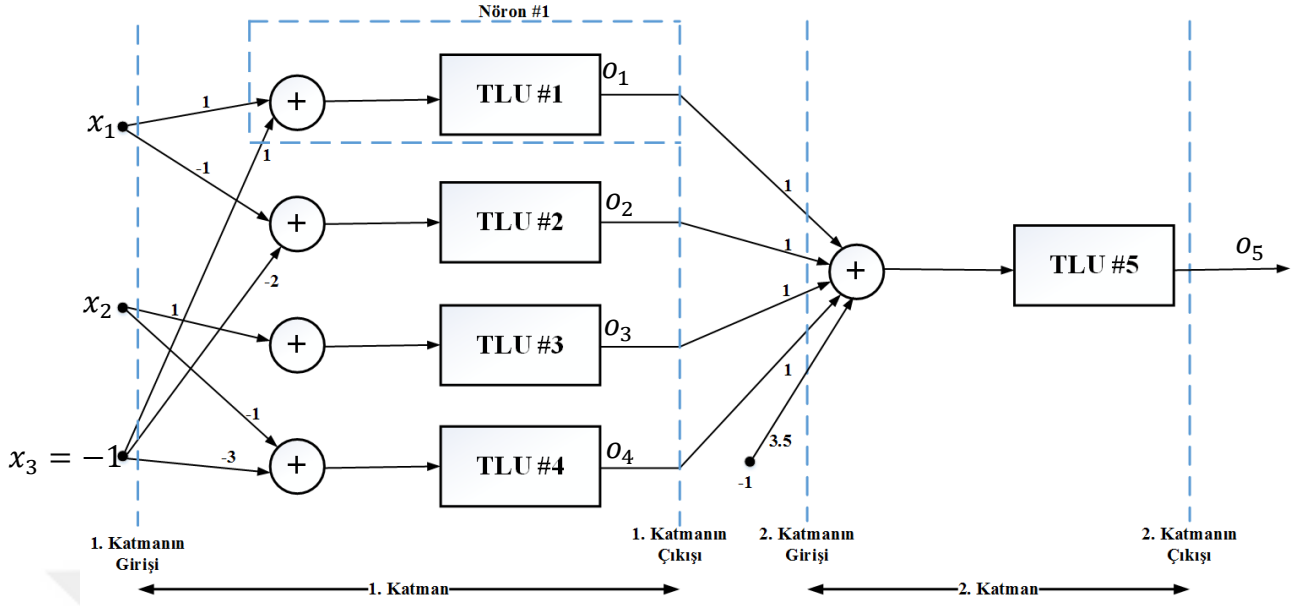
$$o = [o_5]^t$$

$$x = [o_1 \ o_2 \ o_3 \ o_4 \ -1]^t$$

$$W_2 = [1 \ 1 \ 1 \ 3.5]$$

İlk katmandan alınan cevap bipolar ikili aktivasyon fonksiyonu için aşağıdaki gibi hesaplanmaktadır:

$$o = [\text{sgn}(x_1 - 1) \ \text{sgn}(-x_1 + 2) \ \text{sgn}(x_2) \ \text{sgn}(-x_2 + 3)]^t$$



Şekil 1.17. İki katmanlı ileri beslemeli ağ modeli

2. katmanın çıkışı $o_5 = \text{sgn}(o_1 + o_2 + o_3 + o_4 - 3.5)$ formülü yardımıyla hesaplanmaktadır.

5. nöronun çıkışından sadece ve sadece $o_1 = o_2 = o_3 = o_4 = 1$ olduğu durumda +1 değeri elde edilmektedir.

Aktivasyon fonksiyonu sürekli bipolar fonksiyon olarak tercih edildiğinde ilk katman için çıkış değeri verilen (1.57)'de verilen denklemdeki gibi olmaktadır. İkinci katman için ise $o_5 = \frac{2}{1 + \exp(3.5 - o_1 - o_2 - o_3 - o_4)\lambda} - 1$ formülüyle hesaplanmaktadır.

$$o = \begin{bmatrix} \frac{2}{1 + \exp(1 - x_1)\lambda} - 1 \\ \frac{2}{1 + \exp(x_1 - 2)\lambda} - 1 \\ \frac{2}{1 + \exp(-x_2)\lambda} - 1 \\ \frac{2}{1 + \exp(x_2 - 3)\lambda} - 1 \end{bmatrix} \quad (1.57)$$

1.11.3.3.2. Geri Beslemeli Ağlar

Genel yapısı Şekil 1.18'de verilen geri beslemeli bir ağ aslında ileri beslemeli ağın nöron çıkışlarının tekrar girişlere bağlanmasıyla elde edilmektedir [42]. Bu ağ için şu anki çıkış $o(t)$, ise bir süre sonraki çıkış ise $o(t + \Delta)$ olmakta ve (1.58)'de verilen formül

yardımıyla hesaplanmaktadır. Δ ifadesi sembolik bir ifade olmakta ve döngü esnasında oluşan gecikmeyi ifade etmektedir [92]. Ağı harekete geçirmek için ilk değer olarak girişlere $x(t)$ değerleri verilmektedir. Bundan dolayı da $o(0) = x(0)$ 'dır.

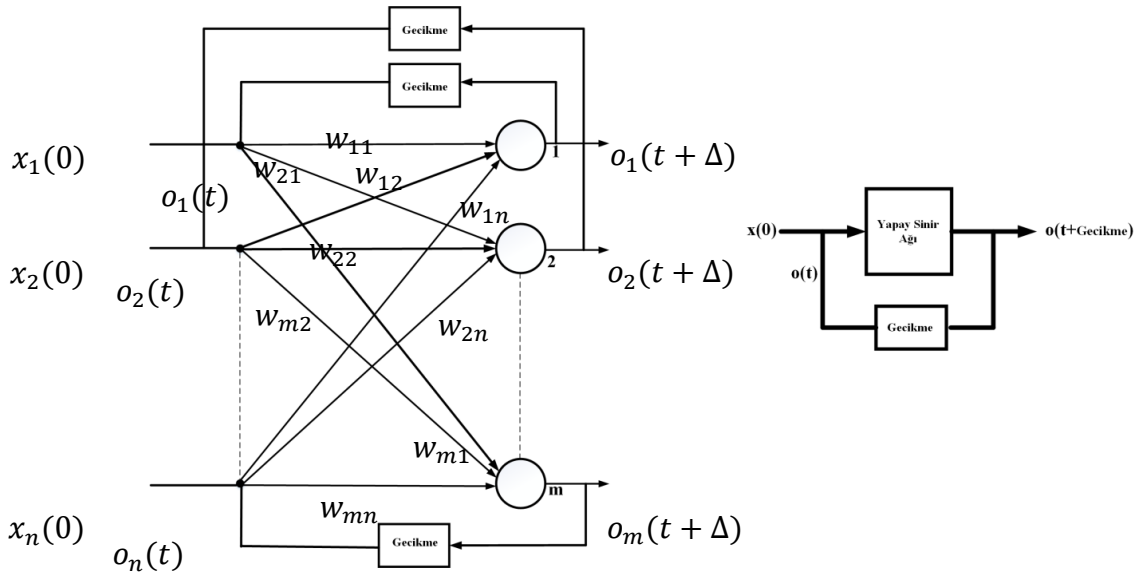
$$o(t + \Delta) = \Gamma[W_0(t)] \quad (1.58)$$

$o(t)$ ifadesini bir sonraki durum olan $o(t + \Delta)$ formülle ifade etmek istersek (1.58)'deki denklem oluşmaktadır. Tek katmanlı geri beslemeli ağlar için 2 kategori söz konusudur. Eğer zamanı ayırık olarak düşünürsek ve sistemi bu şekilde örneklersek, sistem ayırık zamanlı diye adlandırılmaktadır. Ayırık zamanlı yapay sinir ağları için formül (1.59)'daki şekle dönüşmektedir. Formülde verilen k değeri örnek sayısını ifade etmektedir.

$$o^{k+1} = \Gamma[W_0^k] \quad k = 1, 2, \dots \quad (1.59)$$

1.11.3.4. Öğrenme ve Adaptasyon Yöntemleri

Sinir ağlarında öğrenme, çok önemli bir süreç olmakta ve herhangi bir işlemi gerçekleştirmek için sinir ağının giriş-çıkış haritasını çok iyi öğrenmesi gerekmektedir.



Şekil 1.18. Geri beslemeli ağ modeli (a) Bağlantı şeması, (b) Blok diyagram

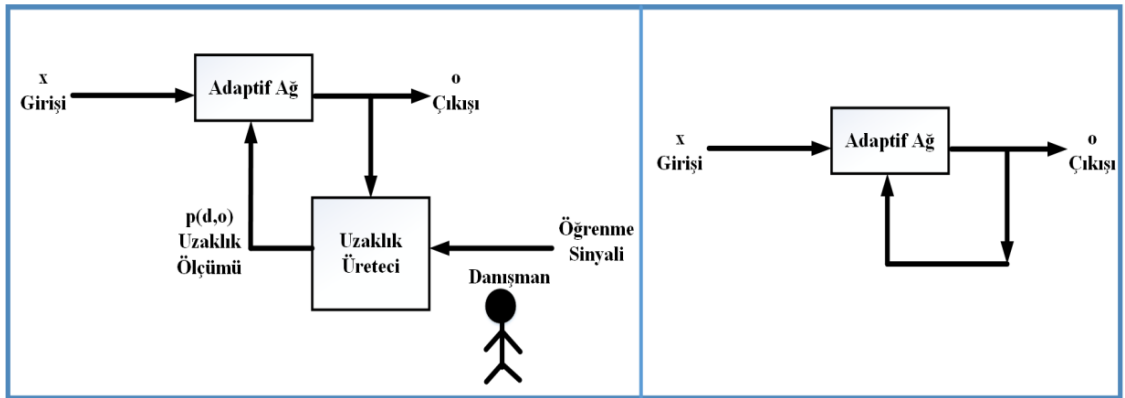
1.11.3.4.1. Danışmanlı ve Danışmansız Öğrenme

Danışmanlı öğrenmede her örnek sisteme uygulanmakta ve alınan sonuç danışman (d) tarafından onaylanmaktadır [75, 81]. Şekilde belirtilen $\rho[d, o]$ ifadesi elde edilen ve beklenen cevap arasındaki farkı ifade etmektedir. Danışmanla yapılan öğrenme daha doğru öğrenme sonuçları vermekte ve danışman hatanın yönünü tahmin edip hatayı azaltan yönde öğrenmeye katkı sağlamaktadır.

Danışmansız öğrenmede ise beklenen sonuçlar hakkında bilgi sahibi olunmamaktadır [92]. Elde edilen cevabın doğruluğu ya da yanlışlığı konusunda bilgi sahibi olunmadığından da öğrenme işlemi girişlerden gelen cevaplara dayalı olarak yapılmaktadır. Danışmanlı ve danışmansız öğrenme yapısına ait genel temsiller Şekil 1.19'da verilmiştir.

1.11.3.5. Yapay Sinir Ağlarında Öğrenme Kuralları

Yapay sinir ağındaki bir nöron adaptif bir eleman olarak düşünülmektedir. Nöronun ağırlıkları da girişlerden gelen değerlere bağlı olarak değişmektedirler. Tüm öğrenme kuralları ve bu kurallara ait genel bilgiler Tablo 1.5'te olduğu gibi özetlenmektedir.



Şekil 1.19.(a) Danışmanlı, (b) Danışmansız öğrenme blok gösterimi

1.11.3.5.1. Hebbian Öğrenme Kuralı


Hebbian danışmansız ve ileri beslemeli bir ağ modeli olmakla birlikte öğrenme sinyalini direk olarak nöron çıkışına bağlayan ve şematik gösterimi Şekil 1.20'deki gibi

olan bir öğrenme kuralıdır [75]. Verilen öğrenme kuralına ait denklem de (1.60)'da verilmiştir.

$$r = f(w_i^t x) \quad (1.60)$$

Ağırlık vektörü Δw_i ise $\Delta w_i = cf(w_i^t x)x$ formülüyle hesaplanmaktadır. Her nöron için ağırlık vektörü hesaplamak gerektiğinde ise formül $\Delta w_{ij} = cf(w_i^t x)x_j$ şekline dönüştürülmektedir. Bu formül de kısaca $\Delta w_{ij} = c o_i x_j \quad j = 1, 2, \dots, n$ gösterimiyle ifade edilmektedir.

İlgili öğrenme kuralında, ağırlık değerleri ilk olarak küçük rastgele değerler olarak seçilmelidir.



Şekil 1.20. Hebbian öğrenme kuralı şematik gösterimi

1.11.3.5.2. Perceptron Öğrenme Kuralı

Perceptron danışmanlı bir öğrenme kuralıdır. Öğrenme işlemi beklenen ve elde edilen cevaplar arasındaki farktan elde edilmekte ve öğrenme sinyali (1.61)'de ki bağıntıyla hesaplanmaktadır.

$$r = d_i - o_i \quad (1.61)$$

Formülde gösterilen o_i değeri elde edilen çıkış değerini göstermekte ve $o_i = \text{sgn}(w_i^t x)$ bağıntısıyla hesaplanmaktadır. d_i değeri ise beklenen çıkışı ifade etmektedir. Bu kural için ağırlık değerlerinin hesaplanması (1.62) ve (1.63)'te verilen denklemlerde belirtildiği gibi olmaktadır.

$$\Delta w_i = c[d_i - \text{sgn}(w_i^t x)]x \quad (1.62)$$


$$\Delta w_{ij} = c[d_i - \text{sgn}(w_i^t x)]x_j \quad j = 1, 2, \dots, n \quad (1.63)$$

Bu kurallar bütününde ağırlıklar sadece ve sadece o_i değeri yanlış olduğunda güncellenmektedir [75]. Perceptron kuralında hata değeri öğrenmenin gerekli şartı olmakta ve beklenen değer de ya -1 ya da $+1$ değerini almaktadır.

Ağırlık ayarlama için kullanılan formül ise (1.64)'te verilen denklemde olduğu gibi indirgenebilmektedir.

$$\Delta w_i = \mp 2cx \quad (1.64)$$

Beklenen ve elde edilen değerler aynı olduğunda $d_i = \text{sgn}(w_i^t x)$ ağırlık değeri sıfırlanmaktadır. Bu nedenle ilgili kural için daha önce verilmiş olan formüller geçersiz olmaktadır. Perceptron öğrenme kuralı Şekil 1.21'de verildiği gibi olmakta ve danışmanlı öğrenmenin temellerini oluşturmaktadır.



Şekil 1.21. Perceptron öğrenme kuralının şematik gösterimi


1.11.3.5.3. Delta Öğrenme Kuralı

Yapısal gösterimi Şekil 1.22’de verilen delta öğrenme kuralı, yalnızca sürekli aktivasyon fonksiyonları için geçerli olan bir danışmanlı öğrenme kuralı olmaktadır.

$$r = [d_i - f(w_i^t x)] f'(w_i^t x) \quad (1.65)$$

(1.65)’te verilen formülde yer alan $f'(w_i^t x)$ değeri $f(net)$ aktivasyon fonksiyonunun türevini ifade etmektedir. Bu öğrenme kuralı da d_i ve o_i değerleri arasındaki küçük karesel hata farkından hesaplanmaktadır [93]. Kurala ait gradiyent vektörü (1.66)’da verilen denklemde belirtildiği gibi olmaktadır.

$$E = \frac{1}{2} (d_i - o_i)^2 \quad (1.66)$$



Şekil 1.22. Delta öğrenme kuralına ait şema

(1.66)’da verilen denklem açık haliyle verilecek olursa $E = \frac{1}{2} [d_i - f(w_i^t x)]^2$ şekline dönüşmektedir. İlgili kuralda hatanın minimize edilmesi gerektiğinden, ağırlıklar negatif türev yönünde (1.67)’deki denklemde verildiği gibi değişmektedirler.

$$\Delta w_i = -\eta \nabla E \quad (1.67)$$

Formüldeki η değeri, pozitif bir sabiti belirtmektedir. Ağırlık değerleri (1.68) ve (1.69)'da verilen denklemlerdeki gibi hesaplanmaktadır.

$$\Delta w_i = -\eta(d_i - o_i)f'(net_i)x \quad (1.68)$$

$$\Delta w_{ij} = -\eta(d_i - o_i)f'(net_i)x_j \quad j = 1, 2, \dots, n \quad (1.69)$$

Delta öğrenme kuralının söz konusu olduğu durumlarda ağırlıklara herhangi bir ilk değer verilmesi mümkün olmaktadır.

1.11.3.5.4. Widrow-Hoff Öğrenme Kuralı

Widrow-Hoff öğrenme kuralı, yapay sinir ağlarının danışmanlı eğitiminde kullanılmaktadır. Kural, beklenen d_i ve elde edilen $net_i = w_i^t x$ değerleri arasındaki karesel hatayı minimize etmekte ve denklem ifadesi de (1.70)'de verilmektedir.

$$r = d_i - w_i^t x \quad (1.70)$$

Ağırlık vektörü aşağıda belirtilen (1.71) ve (1.72) formülleri yardımıyla hesaplanmaktadır.

$$\Delta w_i = c(d_i - w_i^t x)x \quad (1.71)$$

$$\Delta w_{ij} = c(d_i - w_i^t x)x_j \quad j = 1, 2, \dots, n \quad (1.72)$$

Bu kural delta kuralının özel bir versiyonu olarak kabul edilmekte ve LMS (Least Mean Square) öğrenme kuralı olarak da bilinmektedir [75].

1.11.3.5.5. Correlation Öğrenme Kuralı

Correlation öğrenme kuralı genelde ikili sinirleri olan ağlardaki verilere uygulanmakta ve öğrenme işareti olan r değeri d_i değerine eşit olmaktadır. Ağırlıklar için kullanılacak denklemler (1.73) ve (1.74)'te verildiği gibi hesaplanmaktadır.

$$\Delta w_i = c d_i x \quad (1.73)$$


$$\Delta w_{ij} = c d_i x_j \quad j = 1, 2, \dots, n \quad (1.74)$$

Bu kural ikili aktivasyon fonksiyonu ve $d_i = o_i$ kuralıyla Hebbian'ın özel bir durumu olarak yorumlanabilmektedir.

1.11.3.5.6. Winner-Take-All Öğrenme Kuralı

Genel gösterimi Şekil 1.23'te verilen Winner-Take-All öğrenme kuralı, danışmansız bir öğrenme yöntemi olmakla birlikte maksimum değere sahip olan çıkışa gelen ağırlık değerlerini güncellemektedir [75]. Ağırlık vektörü (1.75)'te ifade edildiği gibi olmaktadır.

$$w_m = [w_{m1} \ w_{m2} \ \dots \ w_{mn}]^t \quad (1.75)$$



Şekil 1.23. Winner-Take-All öğrenme kuralı

Ağırlık vektörlerinin güncellenmesi ise (1.76), (1.77) ve (1.78)'de verilen denklemler yardımıyla gerçekleştirilmektedir. Formüldeki α değeri pozitif bir sabiti ifade etmektedir.

$$\Delta w_m = \alpha (x - w_m) \quad (1.76)$$

$$\Delta w_{mj} = \alpha (x_j - w_{mj}) \quad j = 1, 2, \dots, n \quad (1.77)$$

Tüm nöronlar arasından kazanan nöronun belirlenmesi de aşağıda verilen (1.78)'deki ölçüte bağlı olmaktadır.


$$w_m^t x = \max(w_i^t x) \quad i = 1, 2, \dots, p \quad (1.78)$$

1.11.3.5.7. Outstar Öğrenme Kuralı

Şekil 1.24'te verilen outstar öğrenme kuralı, p tane nöronun katmanlarından beklenen d cevabını üretmesi için tasarlanmıştır [75]. Kural aynı zamanda giriş/çıkış ilişkisini tekrarlamak ve karakteristik özellikleri öğrenmeyi sağlamak için kullanılmaktadır. Kurala ait ağırlıklar ise aşağıdaki gibi hesaplanmakta ve β eğitim boyunca azalan küçük pozitif bir öğrenme sabitini ifade etmektedir. Her iterasyonda sadece bir çıkış (1.79) ve (1.80)'de verilen denklemlerde olduğu gibi güncellenmektedir.

$$\Delta w_j = \beta(d - w_j) \quad (1.79)$$

$$\Delta w_{mj} = \beta(d_m - w_{mj}) \quad m = 1, 2, \dots, p \quad (1.80)$$



Şekil 1.24. Outstar öğrenme kuralının şekilsel gösterimi

Tablo 1.5. Öğrenme kuralları ve bu kurallara ait özet tablosu

Öğrenme Kuralı	Basit Ağırlık Ayarı Δw_{ij}	İlk Ağırlıklar	Öğrenme	Nöron Karakteristiği
Hebbian	$c o_i x_j$ $j = 1, 2, \dots, n$	0	Danışmansız	Yok
Perceptron	$c [d_i - \text{sgn}(w_i^t x)] x_j$ $j = 1, 2, \dots, n$	Yok	Danışmanlı	İkili Bipolar ya da İkili Unipolar
Delta	$c (d_i - o_i) f'(net_i) x_j$ $j = 1, 2, \dots, n$	Yok	Danışmanlı	Sürekli
Widrow-Hoff	$c (d_i - w_i^t x) x_j$ $j = 1, 2, \dots, n$	Yok	Danışmanlı	Yok
Correlation	$c d_i x_j$ $j = 1, 2, \dots, n$	0	Danışmanlı	Yok
Winner-Take-All	$\alpha (x_j - w_{mj})$ $j = 1, 2, \dots, n$ m : kazanan nöron numarasıdır	Rastgele ilk değer ataması	Danışmansız	Sürekli
Outstar	$\beta (d_m - w_{mj})$ $m = 1, 2, \dots, p$	0	Danışmanlı	Sürekli

2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME

2.1. Giriş

Bu bölümde, elde edilen açı-genlik grafiği görüntülerinin en iyi şekilde sınıflandırılmasını sağlayacak yöntemler tespit edilmiş ve bunlara ait sonuçlar da detaylı bir şekilde irdelenmiştir. Her bir sınıflandırıcı farklı parametre değerleri için denenmiş olup farklı k -fold çapraz doğrulama yöntemi yardımıyla elde edilen sonuçlar çalışmaya eklenmiştir.

Öznitelik çıkarım yöntemi olarak kullanılan TBA ve sınıflandırma yöntemleri olarak kullanılan DVM, YSA ve k -EYK yöntemlerinde bruteforce arama yoluyla elde edilen ve sınıflandırma başarısını arttırmada katkısı olan parametre değerleri detaylı bir şekilde açıklanmıştır. Bu bölümde son olarak, her bir kanala ait elde edilen sınıflandırma doğrulukları verilmiş ve elde edilen sonuçlar kendi aralarında karşılaştırılarak önerilen yöntemlerin avantaj ve dezavantajları irdelenmiştir.


2.2. Çalışmada Kullanılan Veri Setinin Tanımı

Yapılan bu çalışmada 2003 yılındaki Beyin Bilgisayar Etkileşimi yarışmasında yayınlanan ve Almanya'da Tübingen Üniversitesinde hazırlanan Dataset I(a) kullanılmıştır [22]. Kayıtlar sağlıklı bir denegın bilgisayar ekranındaki imleci aşağı ve yukarı hareket ettirmesi sonucunda 256 Hz. frekansla örneklerek oluşturulmuştur [23]. Kayıtta Şekil 2.1'de görülen 6 elektrottan faydalanılmış ve elektrotlar kafa yüzeyine Uluslararası 10-20 standardına göre yerleştirilmiştir. Referans elektrot olarak C_z elektrodu belirlenmiştir. Yerleştirilen diğer elektrotlar ve isimleri aşağıda listelendiđi gibidir:

- Kanal 1: A1 (sol mastoid: tıpta kulak ardı tümüğü olarak bilinmektedir)
- Kanal 2: A2 (sađ mastoid)
- Kanal 3: FC3 (C3'ün 2 cm önü)
- Kanal 4: CP3 (C3'ün 2 cm yanı)
- Kanal 5: FC4 (C4' ün 2 cm önü)

- Kanal 6: CP4 (C4' ün 2 cm yanı)

Oluşturulan veri setinde 268 eğitim ve 293 de test verisi bulunmaktadır.



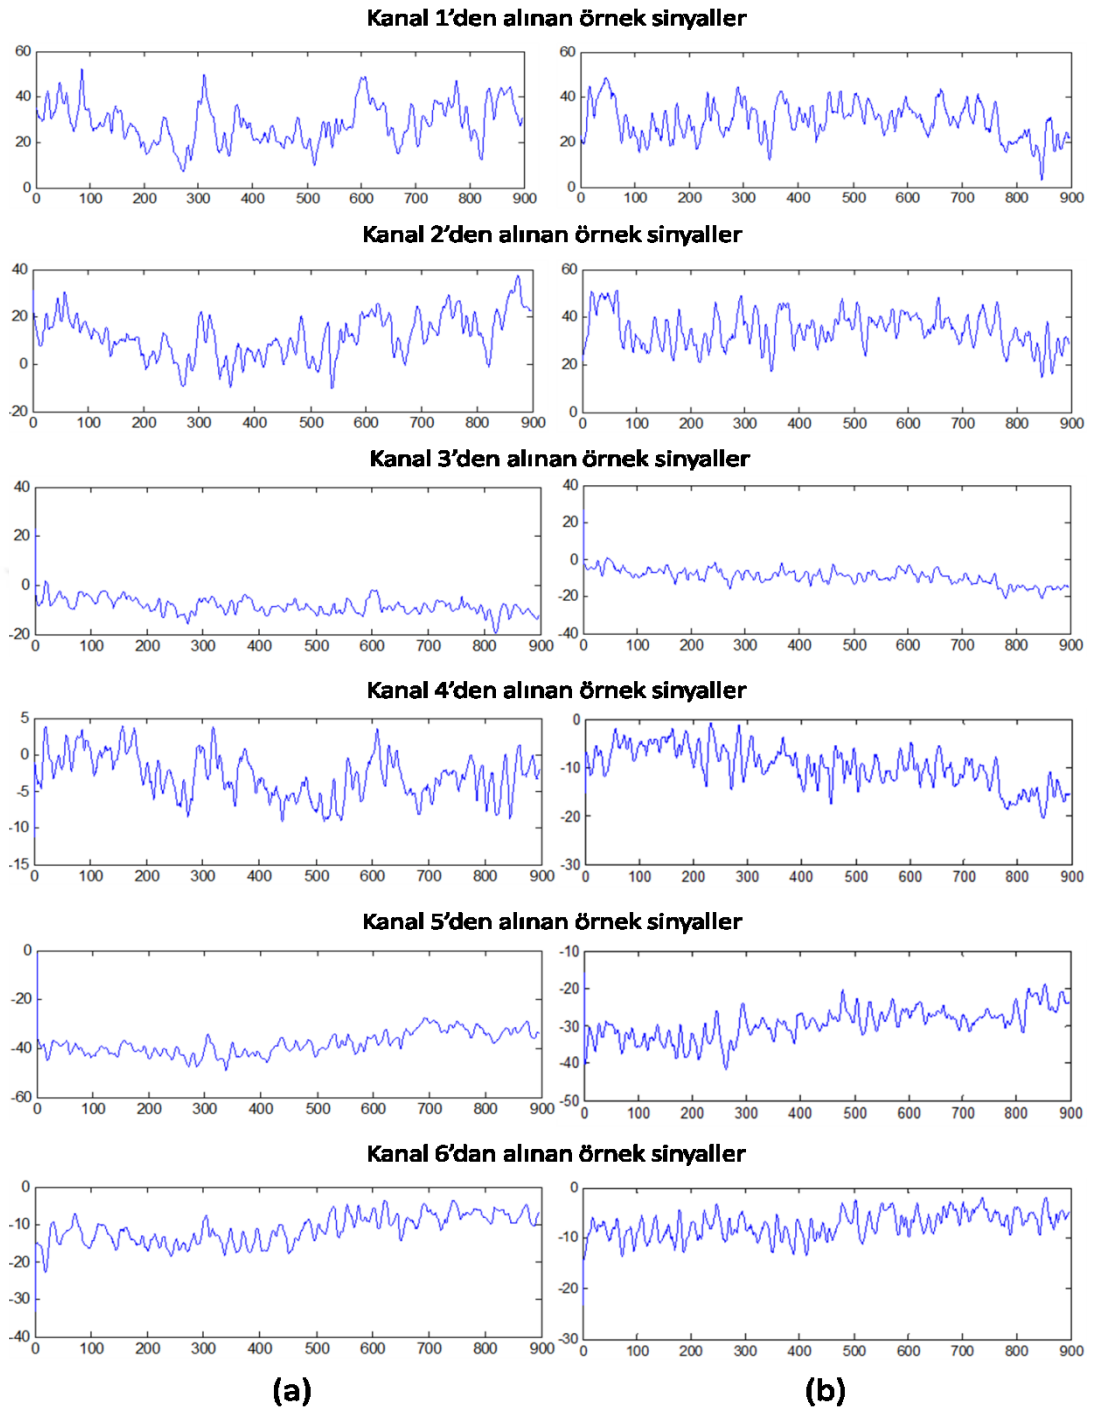
Şekil 2.1. Veri setinin kafaya yerleştirilme durumu

2.2.1. Eğitim Verileri

268 deneme iki farklı günde kaydedilmiştir. Denemelerin 168 tanesi bir günde, geri kalan 100 tanesi de diğer günde yapılmıştır. Sınıf 1 imlecin yukarı hareket ettiği EEG işaretlerini göstermekte ve “Traindata_1.txt” isimli dosyada yer almaktadır. Sınıf 0 ise imlecin aşağıya hareket ettiği EEG işaretlerini göstermekte ve “Traindata_0.txt” isimli dosyada yer almaktadır. Metin dosyası formatında tutulan eğitim verilerinin ilk sütunu sınıflara ait etiket değerlerini (0/1), geriye kalan tüm sütunlar da 6 kanaldan kaydedilen verileri tutmaktadır. Matris boyutları Sınıf 1 için 133×5377 ve Sınıf 0 için de 135×5377 olmaktadır. Verilerin matrise yerleştirme işlemi ise ilk 896 tane örnek 1. kanala, ikinci 896 tane örnek 2. kanala ve sırasıyla diğer kanallara şeklinde devam etmektedir. Farklı kanallardan alınan Sınıf 1 ve Sınıf 0'a ait örnek sinyaller Şekil 2.2'de verilmiştir.

2.2.2. Test Verileri

Test verileri 293×5376 boyutlu bir matris içerisinde tutulmaktadır. Yapısal olarak da eğitim verileriyle aynı standartta oluşturulmuştur.



Şekil 2.2. (a) Sınıf 1'e ait sinyal örnekleri, (b) Sınıf 0'a ait sinyal örnekleri

2.3. Önerilen Yöntem

2.3.1. Açık-Genlik Grafiğinin Elde Edilmesi

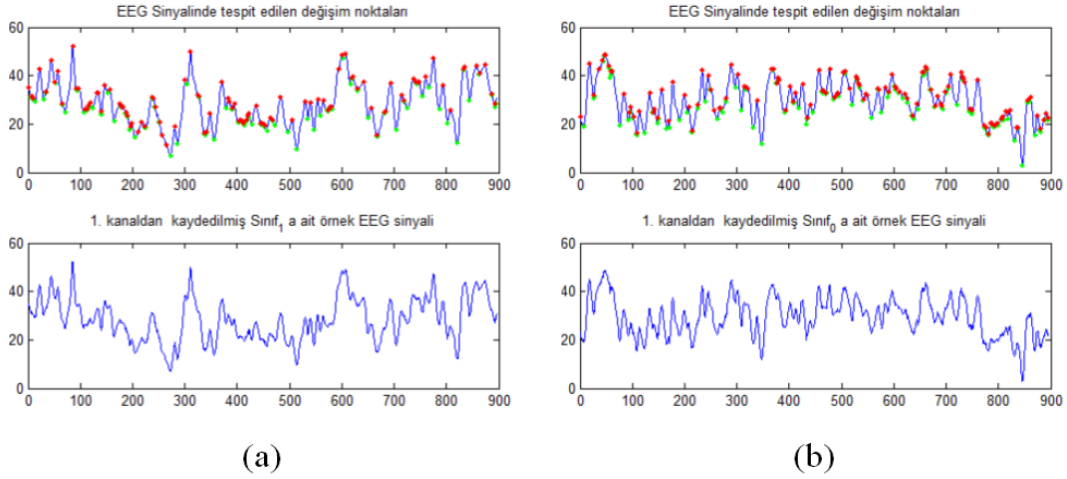
EEG sinyalini herhangi bir filtreden geçirerek kullanmak orijinal sinyalde hem veri kaybına sebep olmakta hem de orijinal verinin kullanılmasını engellemektedir.

Çalışmada önerilen dönüşüm özellik çıkarma işleminden önce kullanılmıştır. Herhangi bir ön işlem olmadığından ham sinyal kayıpsız kullanılmış ve tüm işlemler de dönüşüm sonrasında elde edilen görüntüler üzerinde gerçekleştirilmiştir.

Yöntemde ilk olarak sinyal üzerindeki tüm değişim noktaları tespit edilmiştir (pozitiften negatife ve tam tersi yönde). İkinci olarak tüm değişim noktaları arasındaki uzaklıklar ve uzaklıklar arasındaki açılar sırasıyla hesaplanmıştır. Son olarak da tüm bu uzaklık ve açı değerleri görüntüye dönüşüm işlemi için kullanılmıştır. Bu dönüşümle amaçlanan literatürde ön işlem olarak çokça uygulanmış olan ADD vb. ön işlemleri ortadan kaldırılmasını sağlamaktır. Sonuçlardan da görüldüğü gibi bu basit dönüşüm EEG sınıflandırılması kolaylaştırmıştır. Çalışmada en etkili sonuçlar TBA yöntemi özellik çıkarıcı ve DVM yöntemi de sınıflandırıcı olarak kullanıldığında elde edilmiştir.

2.3.2. Dönüşüm Tekniğinin Adımları

Veri tabanında yer alan tüm sinyallerin değişim noktaları Şekil 2.3'de gösterildiği gibi tespit edilmiştir. Şekilde gösterilen kırmızı noktalar yerel maksimumları, yeşil noktalar da yerel minimumları göstermektedirler. Sinyal üzerinde tespit edilen her tepe ve çukur noktaları için bu işlemler gerçekleştirilmiş olmaktadır.



Şekil 2.3. (a) Sınıf 1, (b) Sınıf 0'a ait örnek EEG sinyali ve sinyale ait tepe-çukur noktaları


Değişim noktaları belirlendikten sonra sağ ve sol uzaklık değerleri $(a: a_1, a_2, a_3, \dots, a_n)$, $(b: b_1, b_2, b_3, \dots, b_n)$ ve bu uzaklıklar arasındaki açı değerleri $(\alpha: \alpha_0, \alpha_1, \alpha_2, \dots, \alpha_n)$ Şekil 2.4'de gösterildiği gibi hesaplanmıştır.

Uzaklık değerlerinin hesaplanması aşamasında basit öklid uzaklık hesabından faydalanılmıştır. Kullanılan formüller, (2.1) ve (2.2) denklemlerinde verildiği gibidir.

$$a_k(t) = \sqrt{(x_k(t) - x_{k-1}(t))^2 + (y_k(t) - y_{k-1}(t))^2} \quad (2.1)$$

$$b_k(t) = \sqrt{(x_k(t) - x_{k+1}(t))^2 + (y_k(t) - y_{k+1}(t))^2} \quad (2.2)$$

Doğruların uzaklık değerleri hesaplandıktan sonra bu doğrular arasındaki açı değerlerinin hesaplanması aşamasına geçilmiştir. Açı değerleri Açı-Genlik grafiği üzerinde noktaların hangi bölgeye yerleştirileceğinin tespit edilmesi aşamasında kullanılmıştır.



Şekil 2.4. Örnek sinyal üzerindeki açı ve uzaklıkların gösterimi

Açılar ($\alpha: \alpha_1, \alpha_2, \dots, \alpha_n$) buldukları konuma göre pozitif veya negatif olarak konumlandırılmıştır. Açı hesabı ise elde edilen doğruların eğimlerinin (2.3)'te verilen denklem yardımıyla hesaplanmasının ardından (2.4)'teki tanjant değerinin açısal formülü yardımıyla yapılmıştır.

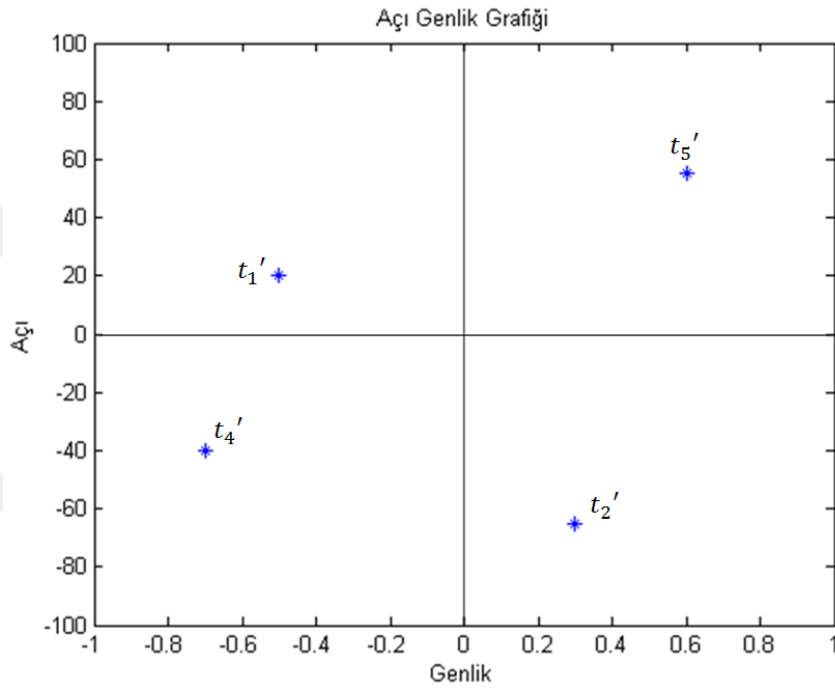
$$m_k = \frac{y_{n+1} - y_n}{x_{n+1} - x_n} \quad (2.3)$$

$$\alpha_k(t) = \begin{cases} (m_n - m_{n+1}) / (1 - (m_n * m_{n+1})) & \text{Nokta yerel maksimum ise} \\ -(m_n - m_{n+1}) / (1 - (m_n * m_{n+1})) & \text{Diğer durumlarda} \end{cases} \quad (2.4)$$

Sağ ve sol uzaklık değerleri tespit edildikten sonra sinyal üzerindeki her tepe veya çukur bölgesinde büyük değere sahip olan kenar belirlenmiş ve büyük değere sahip olan kenar, küçük değere sahip olan kenara bölünmüştür. Aşağıdaki verilen (2.5) ile ifade edilen denklemle birlikte hem her bölge için bir uzaklık değeri tespit edilmiş hem de değer aralıkları +1 ile -1 aralığına çekilmiştir. Sonuç olarak Açı-Genlik grafiğinde kullanılacak olan genlik değerleri $R_k(t)$, (2.5)'teki denklem yardımıyla normalize edilmiştir.

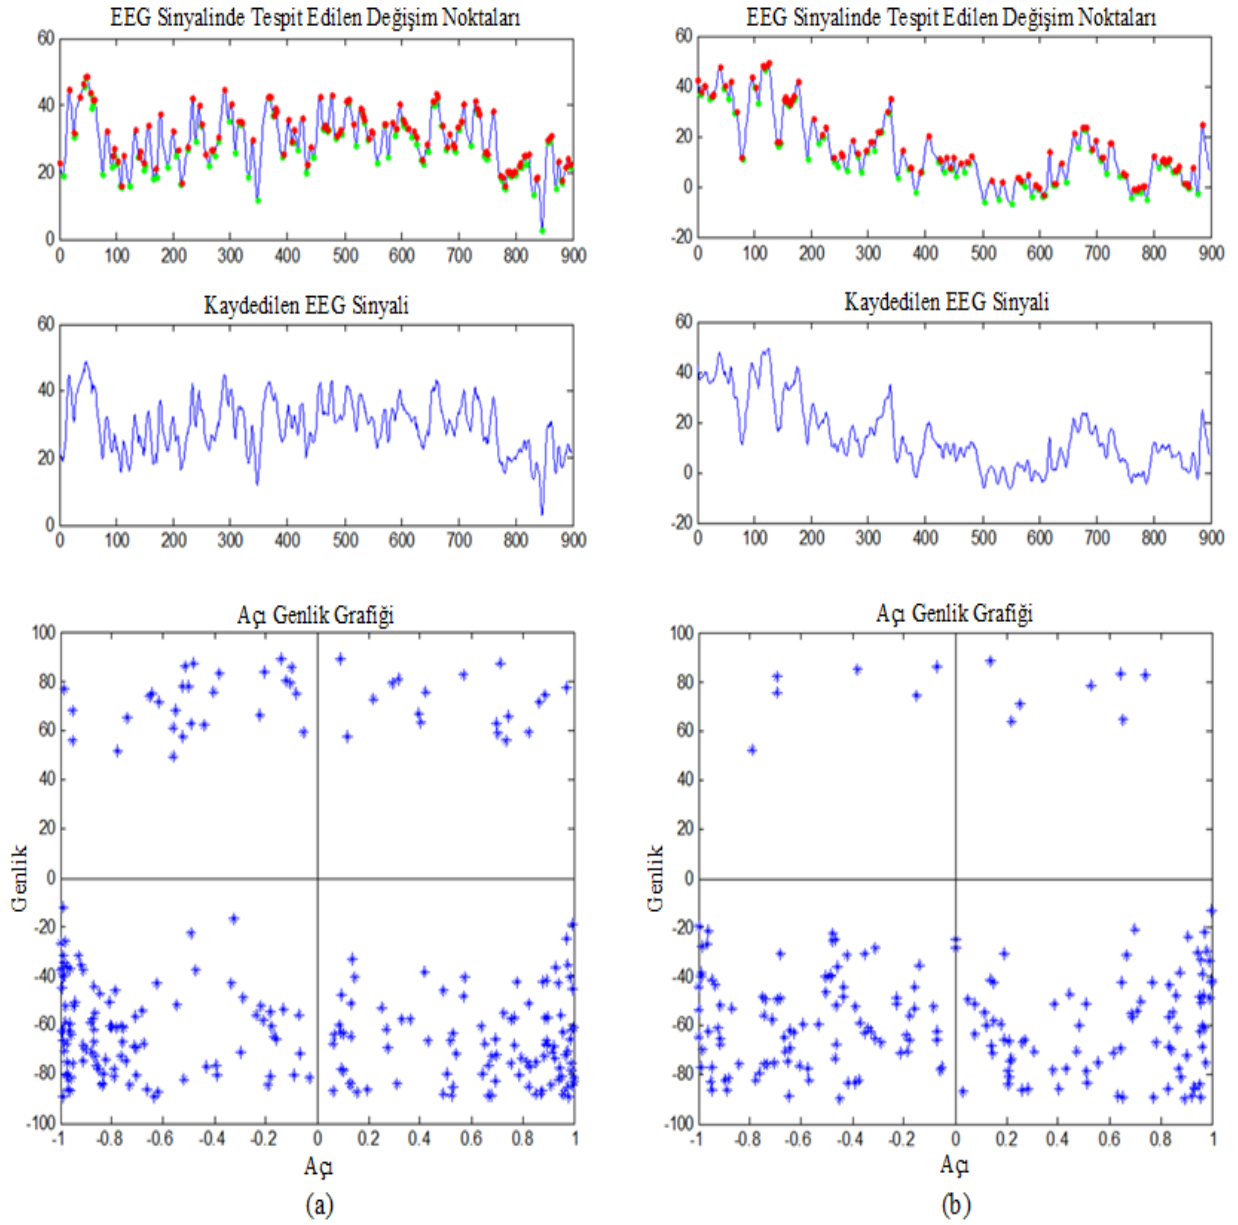
$$R_k(t) = \begin{cases} \frac{b_k(t)}{a_k(t)} & b_k(t) < a_k(t) \\ -\frac{a_k(t)}{b_k(t)} & \text{Diğer durumda} \end{cases} \quad (2.5)$$

Yapılan tüm bu işlem adımlarından sonra Şekil 2.4'te gösterilen t_1 , t_2 , t_4 ve t_5 noktalarının görüntü üzerindeki yerleşim noktaları da Şekil 2.5'te verildiği gibi t_1' , t_2' , t_4' ve t_5' olmaktadır. Elde edilen grafiklerdeki tanjant açısının değeri $[-90, 90]$ aralığında yer almaktadır.



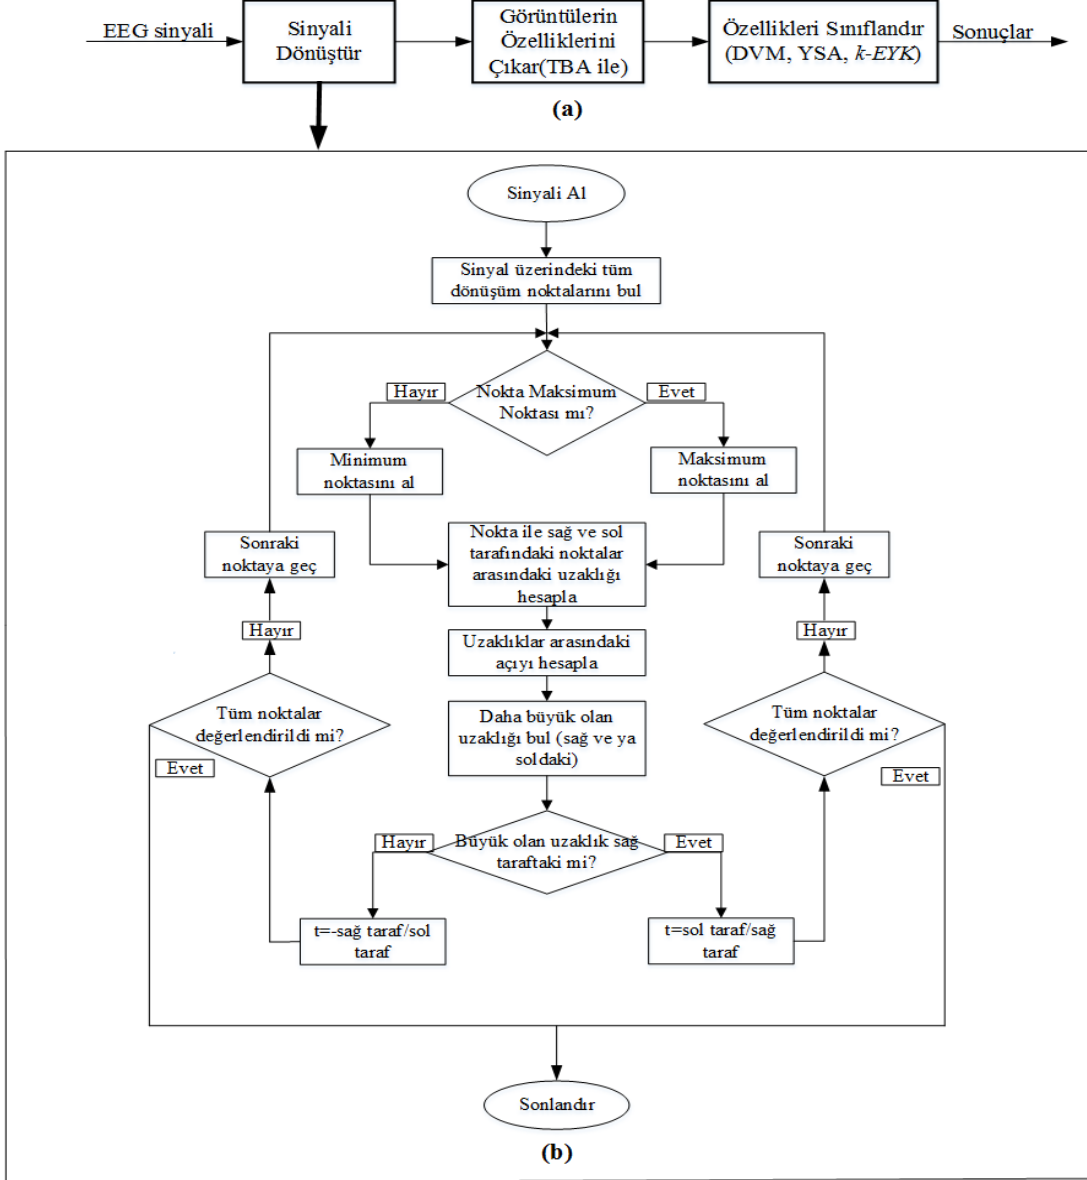
Şekil 2.5. Açı – Genlik grafiği temsili gösterimi (Img (i, j))

Tüm bu işlemler sonrasında elde edilen iki farklı sınıfa ait örnek grafikler Şekil 2.6' da gösterildiği gibi olmaktadır. Önerilen yöntemin işleyişini gösteren akış diyagramı ise Şekil 2.7'de verilmektedir.



Şekil 2.6. (a) Sınıf 0'a ait örnek sinyal dönüşümü, (b) Sınıf 1'e ait örnek sinyal dönüşümü

2.3.3. Dönüşüm Yöntemin Akışı



Şekil 2.7.(a) Metodun blok diyagramı, (b) Önerilen dönüşüm metodunun blok diyagramı

Önerilen yöntemde izlenen yolun temel adımları Şekil 2.7’de akış diyagramı olarak verilmiştir.

2.4. TBA ile Öznitelik Çıkarımı ve Boyut İndirgeme

TBA'nın ana fikri içindeki mevcut yapıyı koruyarak veri setinin boyutluluğunu küçültmek ve daha küçük boyutlu yeni bir veri seti elde etmektir [37]. Teorik olarak TBA'nın mantığı oldukça basittir. İlk olarak d -boyutlu ortalama vektörü olan μ , ikinci olarak $d \times d$ boyutunda kovaryans matrisi tüm veri setinden faydalanarak hesaplanır. Bir sonraki aşamada özdeğerler ve özvektörler hesaplanır ve özdeğerlere bağlı olarak özvektörler azalan şekilde sıralanırlar. Tüm bu işlemlerden sonra ilk k tane özvektör seçilir ve geri kalanı da göz ardı edilir [38].

TBA yöntemiyle, elde edilen Açık-Genlik grafiği görüntülerinden özellik çıkarımı yapılırken farklı sayıda bileşenler için denemeler yapılmış elde edilen sonuçlar da tablolarda detaylı olarak verilmiştir.

2.5. Açık-Genlik Grafiği Görüntülerinin Sınıflandırılması

2.5.1. k -EYK ile Sınıflandırma Sonuçları

k -EYK algoritması kolay anlaşılabilir ve uygulanabilir bir algoritma oluşuyla literatürde sıkça tercih edilen ve parametrik olmayan bir yöntem olmaktadır [39,41]. Algoritma için k parametresinin belirlenmesi oldukça önemlidir. Mevcut birçok yöntem arasından en iyi k değeri, toplam eğitim vektörleri sayısının karekökünden daha az sayıda seçildiğinde elde edilmektedir [17].

Çalışmada farklı k değerleri için sonuçlar her bir kanaldan alınan sinyal üzerinde ayrı ayrı denenmiş, k -fold çapraz doğrulama yöntemiyle doğruluğu test edilmiş ve sırasıyla tablolarda verilmiştir. Tabloların her birinde doğruluk değerlerinin yanında parantez içerisinde verilen değerler, TBA özellik çıkarma yönteminden elde edilen ve k -EYK'ya verilen temel bileşen sayısını göstermektedir. Örneğin Tablo 2.1'de Kanal 1 için 3-fold çapraz doğrulama yapılırken ($k = 1$ olarak seçildiğinde) denenilen farklı uzunlukta temel bileşen sayısından sonra en uygun değer ilk 30 temel bileşen olarak belirlenmiştir.

Tablo 2.1. Değişen temel bileşen sayısına göre Kanal 1'den elde edilen k -EYK sınıflandırma doğrulukları

Kanal 1	3-Fold	5-Fold	7-Fold
$k = 1$	50.8391(30)	58.0531(30)	66.6071(40)
$k = 2$	51.4422(30)	58.9380(40)	64.2143(40)
$k = 3$	59.3380(30)	61.4159(40)	70.8929(40)

Tablo 2.2. Değişen temel bileşen sayısına göre Kanal 2'den elde edilen k -EYK sınıflandırma doğrulukları

Kanal 2	3-Fold	5-Fold	7-Fold
$k = 1$	52.1343(30)	51.5044(30)	52.0282(30)
$k = 2$	53.7215(30)	53.9823(30)	51.6755(30)
$k = 3$	58.7473(60)	61.4159(40)	66.4903(70)

Tablo 2.3. Değişen temel bileşen sayısına göre Kanal 3'ten elde edilen k -EYK sınıflandırma doğrulukları

Kanal 3	3-Fold	5-Fold	7-Fold
$k = 1$	61.5695(30)	51.5868(50)	51.9713(50)
$k = 2$	60.6269(30)	50.5311(50)	50.1641(70)
$k = 3$	60.1275(30)	51.5867(70)	52.3737(60)

Tablo 2.4. Değişen temel bileşen sayısına göre Kanal 4'ten elde edilen k -EYK sınıflandırma doğrulukları

Kanal 4	3-Fold	5-Fold	7-Fold
$k = 1$	56.2746(30)	59.9257(30)	57.8209(30)
$k = 2$	58.3627(30)	59.0426(30)	57.621(30)
$k = 3$	56.5548(30)	64.1893(30)	57.3303(30)

Tablo 2.5. Değişen temel bileşen sayısına göre Kanal 5'ten elde edilen k -EYK sınıflandırma doğrulukları

Kanal 5	3-Fold	5-Fold	7-Fold
$k = 1$	50.9785(30)	51.1504(30)	59.0432(30)
$k = 2$	51.8888(30)	52.9203(40)	60.7932(70)
$k = 3$	52.2469(40)	52.5664(30)	58.7901(50)

Tablo 2.6. Değişen temel bileşen sayısına göre Kanal 6'dan elde edilen k -EYK sınıflandırma doğrulukları

Kanal 6	3-Fold	5-Fold	7-Fold
$k = 1$	50.7641(70)	53.9823(70)	52.8395(70)
$k = 2$	52.5413(70)	52.7433(50)	53.3333(40)
$k = 3$	52.7554(30)	53.9823(60)	57.0370(30)

Yukarıdaki tablolarda alitmadan en iyi sonuçların alınmasını sağlayan k değerleri için doğruluklar verilmiş olup başarıyı olumsuz yönde etkilediği görüldüğünden daha büyük k değerleri sonuçlara eklenmemişlerdir.

2.5.2. YSA ile Sınıflandırma Sonuçları

Yapay sinir ağı biyolojik sinir hücresinin işleyişinden esinlenerek oluşturulmuş bir yapı olmasının yanı sıra karmaşık örüntü tanıma ve sınıflandırma problemleri için çok uygun bir yöntem olarak bilinmektedir [42, 92]. İşleme elemanları beyindeki nöronların çalışmasına benzer şekilde çalışmakta ve nöron ya da yapay nöronlar olarak da adlandırılmaktadırlar [42]. Ağın öğrenme yeteneği ise bağlantı yapısına, transfer fonksiyonuna, gizli katman sayısına ve her gizli katmandaki nöron miktarına bağlı olmaktadır [24,43].

Yapay sinir ağlarında nöronlar arasındaki bağlantıların ve bu bağlantılara ait ağırlık değerlerinin doğru bir şekilde ayarlanması oldukça önemli olmaktadır. YSA'nın sahip olduğu yapı sebebiyle doğru değerlerin tespit edilmesi önceden gerçekleşemeyecek bir durum olmakta ve ağın eğitilmesi ile gerçekleştirilmektedir. YSA'da bilinen adıyla aktivasyon fonksiyonu ya da diğer adlarıyla transfer, eşik fonksiyonu net girdi değerlerinden işlem çıktısını üretmeyi sağladığından oldukça önemli bir yere sahip olmaktadır. Bu çalışmada Sigmoid aktivasyon fonksiyonu kullanılmıştır. Literatürde bilinen diğer aktivasyon fonksiyonları aşağıdaki gibi listelenmektedir.

- Doğrusal Aktivasyon Fonksiyonu
- Step Aktivasyon Fonksiyonu
- Hiperbolik Tanjant Aktivasyon Fonksiyonu

YSA temelde eğitilecek örneklerin verildiği giriş katmanı, sonuçların alındığı çıkış katmanı ve asıl eğitim işlemlerinin gerçekleştirildiği ara katman olmak üzere 3 katmandan oluşmaktadır. Bu çalışmada geri beslemeli ve Çok Katmanlı Perceptron (ÇKP) modeli

kullanılarak sınıflandırılma yapılmış ve elde edilen sonuçlar diğer sınıflandırıcılardan elde edilen sonuçlarla karşılaştırılmıştır.

Geri beslemeli ağ yapısı söz konusu olduğunda bir hücrenin çıkışı söz konusu hücreye ya da başka bir hücreye verilerek sonucun önceden tahmin edilmesi sağlanmaktadır [45]. Geri beslemeli ağlarda gecikme söz konusu olmakla birlikte sistemde bir hafıza söz konusu olduğu bilinmektedir. Dolayısıyla geri beslemeli ağlar önceden tahmin yapılması gereken uygulamalar için oldukça uygun olmaktadır.

YSA'da nöronlar arasındaki ağırlık değerlerinin güncellenmesi ağın eğitimini ifade etmektedir. Ağırlık değerleri rastgele olarak atanmakta ve beklenen sonuçlar elde edilene kadar güncellenmeye devam etmektedir.

Sonuçlar, farklı sayıda temel bileşenler için verilmiş olup her kanal ve çapraz doğrulama tekniği için ayrı ayrı en iyi sonuç verenler kalın rakamlarla belirtilmiştir.

Tablo 2.7. Değişen temel bileşen sayısına göre Kanal 1'den elde edilen YSA sınıflandırma doğrulukları

Kanal 1	$T.B = 30$	$T.B = 40$	$T.B = 50$	$T.B = 60$	$T.B = 70$
3-Fold	64.2931	67.6819	70.6972	71.0243	66.7877
5-Fold	68.8496	70.2655	72.3894	75.2613	75.9292
7-Fold	69.5216	71.6578	71.6689	73.9771	73.0798

Tablo 2.8. Değişen temel bileşen sayısına göre Kanal 2'den elde edilen YSA sınıflandırma doğrulukları

Kanal 2	$T.B = 30$	$T.B = 40$	$T.B = 50$	$T.B = 60$	$T.B = 70$
3-Fold	58.0783	65.5441	61.2916	57.0164	59.1526
5-Fold	64.4248	68.1416	69.0265	70.6195	70.0085
7-Fold	61.1993	64.0212	66.8430	70.9423	68.4303

Tablo 2.9. Değişen temel bileşen sayısına göre Kanal 3'ten elde edilen YSA sınıflandırma doğrulukları

Kanal 3	$T.B = 30$	$T.B = 40$	$T.B = 50$	$T.B = 60$	$T.B = 70$
3-Fold	62.8879	63.7849	64.6733	65.2062	65.9154
5-Fold	55.8439	54.0661	56.3955	57.6469	59.9197
7-Fold	60.0557	60.3728	62.0012	60.7679	63.7883

Tablo 2.10. Değişen temel bileşen sayısına göre Kanal 4'ten elde edilen YSA sınıflandırma doğrulukları

Kanal 4	$T.B = 30$	$T.B = 40$	$T.B = 50$	$T.B = 60$	$T.B = 70$
3-Fold	55.7724	55.9497	59.1383	57.7237	56.1269
5-Fold	55.615	56.7901	64.0028	66.8473	66.6672
7-Fold	57.2923	64.0719	66.5498	65.2888	69.5613

Tablo 2.11. Değişen temel bileşen sayısına göre Kanal 5'ten elde edilen YSA sınıflandırma doğrulukları

Kanal 5	$T.B = 30$	$T.B = 40$	$T.B = 50$	$T.B = 60$	$T.B = 70$
3-Fold	50.9794	49.909	51.3359	57.0164	52.9345
5-Fold	48.3186	47.9646	50.9734	70.6195	53.6283
7-Fold	53.7919	53.0864	55.571	70.9423	55.7701

Tablo 2.12. Değişen temel bileşen sayısına göre Kanal 6'dan elde edilen YSA sınıflandırma doğrulukları

Kanal 6	$T.B = 30$	$T.B = 40$	$T.B = 50$	$T.B = 60$	$T.B = 70$
3-Fold	54.1776	54.5312	54.1842	71.0243	55.9534
5-Fold	53.0973	53.9823	53.9823	75.2613	55.3982
7-Fold	51.6755	54.1389	54.321	73.9771	53.6155

2.5.3. DVM ile Sınıflandırma Sonuçları

Literatürde yer alan birçok uygulamada verilerin doğrusal olarak ayrıştırılması mümkün olmamaktadır. Verilerin doğrusal ayrışmadığı bu gibi durumlarda destek vektör makineleri kernel hilesine başvurmaktadır. Çalışmada TBA uygulanması sonucunda elde edilen özellik vektörlerini (ilk 70 özellik vektörü) Radyal Tabanlı çekirdek fonksiyonu yardımıyla yüksek boyutta ayrıştırma gerçekleştirilmiştir. SVM yaklaşımının temeli kabul edilen çekirdek fonksiyonlar için parametre seçimi çok önemli bir ölçüttür.

Önerilen metodun sınıflandırma başarısı belirlenirken kullanılan çekirdek fonksiyonun alt ve üst sınır değerleri arasındaki tüm değerler denenmiş olup en ideal sonuçlar tablolarında her kanal için detaylı olarak verilmiştir. Yöntem için en uygun parametreyi tespit etmenin yanı sıra parametrelerin birbirleriyle uyumlu olması da başarıya pozitif katkı sağlamaktadır [40].

Çalışmada DVM sınıflandırma sonuçları 3-,5- ve 7-Fold çapraz doğrulama yöntemiyle değerlendirilmiş, her fold değeri için C düzenleme parametresi değiştirilerek sonuçlar gözlemlenmiş ve elde edilen en iyi sonuçlar tablolarda kalın rakamlarla verilmiştir. Değişen C değerleri için aşağıdaki tablolarda verilen ve sınınan alt-üst değer aralıkları dışındaki değerler, önerilen yöntemin doğruluk performansını olumlu yönde etkilemediğinden tablolara eklenmemiştir.

Tablo 2.13. Değişen c parametre değerlerine göre Kanal 1'den elde edilen DVM sınıflandırma doğrulukları

Kanal 1	2^{-15}	2^{-10}	2^{-5}	2^5	2^{10}	2^{15}
3-Fold	84.7096	84.7096	68.4356	76.8786	76.8786	76.8786
5-Fold	93.9832	93.9832	76.64	78.60	78.60	78.60
7-Fold	94.47	89.3011	71.1155	63.3003	63.3003	63.3003

Tablo 2.14. Değişen c parametre değerlerine göre Kanal 2'den elde edilen DVM sınıflandırma doğrulukları

Kanal 2	2^{-15}	2^{-10}	2^{-5}	2^5	2^{10}	2^{15}
3-Fold	76.737	77.0926	67.2745	55.7733	55.7733	55.7733
5-Fold	93.9823	93.9823	55.5752	49.3794	49.3806	49.3806
7-Fold	92.2398	73.3686	52.0282	48.6771	48.6771	48.6771

Tablo 2.15. Değişen c parametre değerlerine göre Kanal 3'ten elde edilen DVM sınıflandırma doğrulukları

Kanal 3	2^{-15}	2^{-10}	2^{-5}	2^5	2^{10}	2^{15}
3-Fold	65.9408	65.9408	60.7961	60.0915	60.0915	60.0915
5-Fold	78.1805	78.1820	67.1924	50.1676	50.1676	50.1676
7-Fold	90.9655	90.9633	60.1853	54.8807	54.8807	54.8807

Tablo 2.16. Değişen c parametre değerlerine göre Kanal 4'ten elde edilen DVM sınıflandırma doğrulukları

Kanal 4	2^{-15}	2^{-10}	2^{-5}	2^5	2^{10}	2^{15}
3-Fold	62.692	63.0475	58.0896	58.2546	58.2546	58.2546
5-Fold	90.2495	90.0724	73.0468	66.8742	66.8722	66.8722
7-Fold	89.9161	89.9161	68.1613	65.8245	65.8245	65.8245

Tablo 2.17. Değişen c parametre değerlerine göre Kanal 5'ten elde edilen DVM sınıflandırma doğrulukları

Kanal 5	2^{-15}	2^{-10}	2^{-5}	2^5	2^{10}	2^{15}
3-Fold	42.3988	52.5771	51.1501	46.3553	46.3553	46.3553
5-Fold	54.1593	53.8053	51.3227	55.2213	55.2213	55.2213
7-Fold	65.1543	65.5115	53.6331	53.6331	53.6331	53.6331

Tablo 2.18. Değişen c parametre değerlerine göre Kanal 6'dan elde edilen DVM sınıflandırma doğrulukları

Kanal 6	2^{-15}	2^{-10}	2^{-5}	2^5	2^{10}	2^{15}
3-Fold	58.7979	58.6197	54.5322	52.213	52.213	52.213
5-Fold	60	59.8230	53.8053	52.2124	52.2124	52.2124
7-Fold	60.1411	59.9647	56.3615	52.5573	52.5573	52.5573

2.6. Deneysel Sonuçlar ve Karşılaştırmalar

EEG sinyalleri beynin işlevsel fonksiyonları hakkında bilgi veren sinyaller olmaları sebebiyle birçok hastalık tespitinde bu sinyallerden faydalanılmaktadır [45]. Bu tez çalışmasında, EEG verilerine uygulanıp gürültünün kaldırılmasını sağlayan aynı zamanda ham sinyalin kullanılmasına engel olan ön işlemlerin ortadan kaldırılmasını sağlamak amacıyla yeni bir dönüşüm yöntemi önerilmiştir.

Dönüşüm sayesinde ham sinyaller basit görüntülere dönüştürülmüş ve tüm işlemler de görüntüler üzerinde gerçekleştirilmiştir. İlk aşamada EEG verisi sınıflandırılmak üzere 6 kanala ayrılmıştır. İkinci aşama olarak, daha önce tarafımda yayınlanmış olan "Gender Recognition from Face Images" [62] isimli bildiriye TBA yöntemi karmaşık görüntüler üzerinde etkili bir özellik çıkarıcı olarak tespit edildiğinden, mevcut çalışmada da elde edilen Açık-Genlik görüntülerinden özellik çıkarıcı olarak kullanılmıştır. Yapılan çalışmada TBA yöntemiyle görüntülerin boyutlarının indirgenmiş olarak kullanılması sağlanmış ve yayınlanan çalışmada karmaşık görüntülerde iyi sonuç alınmış olması gözlemlendiğinden çalışmadaki görüntüler üzerinde de kullanılması tercih edilmiştir.

TBA yöntemi için etkili bir faktör olan özellik vektörü sayısının en uygun olanını tespit etmek amacıyla kullanılan tüm sınıflandırma yöntemleri farklı temel bileşen sayılarıyla denenmiş ve elde edilen sonuçlar açıklamalarıyla birlikte detaylı olarak yukarıdaki tablolarda verilmiştir. Bu işlemin yapılmasındaki amaç, bazı durumlarda

gereğinden fazla özellik vektörü kullanılmasının sınıflandırma başarısını olumsuz etkilediğinin gözlemlenmiş olmasıdır. Verilen tablolarda belirtildiği sayıda temel bileşenler kullanıldığında doğruluk değeri yeterince yüksek olduğundan geri kalanını kullanmaya gerek olmadığı tespit edilmiştir.

TBA yönteminin uygulanmasının ardından Açık-Genlik grafiklerine ait özellikleri sınıflandırmak amacıyla literatürdeki birçok çalışmada da kullanılmış olan DVM, YSA ve k -EYK makine öğrenmesi algoritmaları tercih edilmiştir.

Çalışmada elde edilen sonuçlardan EEG sinyallerinin 2-B görüntülere dönüştürülüp sınıflandırılmasının ümit vadeden bir yöntem olduğu görülmüştür. Bu fikir çalışmada kullanılan veri seti üzerinde literatürdeki çalışmaların elde ettiği başarı oranlarının verildiği Tablo 2.19’da açıkça görülmektedir.

Yönteme ait akış genel olarak aşağıdaki gibidir.

- Değişim noktaları arasındaki uzaklık ve açıları hesapla
- Her değişim noktasının sağ ve sol tarafındaki uzaklıklardan daha büyük değere sahip olanı tespit et
- Küçük değere sahip olanı büyük değere sahip olana böl
- Elde edilen açı ve uzaklık değerlerini Açık-Genlik grafiğini oluştur.

En uygun özellik çıkarma yöntemiyle sınıflandırıcı çifti eşleşmesi de bu kısımda altı çizilmesi gereken bir noktayı ifade etmektedir. Diğer bir önemli nokta ise kullanılan algoritmalarda en uygun parametrenin seçilmesidir. İfade edilen tüm bu şartlar sağlandığında sınıflandırıcı başarısı gözle görülebilen ölçüde artmaktadır.

Tablo 2.19. Önerilen yöntemin Dataset I(a)’yı kullanan diğer çalışmalarla karşılaştırılması

	Kanal Sayısı	Sınıflandırıcı	Ortalama Doğruluk
Mensh ve arkadaşları [13]	4	Lineer	88.70
Sun ve Zhang [11]	6	Bayes	90.44
Ting ve arkadaşları [10]	6	Sinir Ağları	90.80
Wang ve arkadaşları [12]	4	Lineer	88.70
Kayıkçıoğlu ve Aydemir [14]	1	k -EYK	92.15
Önerilen Yöntem	1	k -EYK	70.89
Önerilen Yöntem	1	Sinir Ağları	75.92
Önerilen Yöntem	1	Destek Vektör Makineleri	94,47

Çalışmada kullanılan veri seti 6 ayrı kanaldan alınmış olan EEG sinyallerini barındırmaktadır. Her kanaldan alınan sinyallerin Açık-Genlik grafikleri oluşturulmuş ve 3-,5- ve 7- Fold çapraz doğrulama teknikleri kullanılarak sonuçlara ait doğruluklar elde edilmiştir. Doğruluk değerlerinin hesaplanması doğru sınıflandırılan veri sayısının sınıflandırmada kullanılan toplam veri sayısına oranından elde edilen yüzde değerleriyle gerçekleştirilmiştir.



3. SONUÇLAR VE TARTIŞMA

EEG işaretleri, insan beynine ait çok miktarda bilgi içeren karmaşık yapıdaki işaretlerdir. Bu işaretlerin incelenmesi ve değerlendirilmesi için kesin ölçütler olmaması nedeniyle bazen analizler yetersiz kalmaktadırlar.

EEG sinyalleri birçok hastalık tespitinde etkin olarak kullanılmaktadır. Bu nedenle kafa yüzeyinden elektrotlar yardımıyla kaydedilen sinyaller, kayıt sonrasında işlenmekte ve hastalık veya belirtileri tespit edilmeye çalışılmaktadır. Bu amaca yönelik sistemlerin geliştirilmesinde, kayıt işlemi esnasında EEG sinyallerine sıklıkla gürültü karışabilmektedir. Kan basıncı, kan akış hızı, deri direnci ve yüz ifadeleri gibi faktörler EEG işaretlerinin kaydını etkilemektedir. Geliştirilecek sistemin başarısına ve doğruluğuna negatif yönde etki eden bu tarz gürültülerin kaldırılması amacıyla literatürde önışlem aşaması olarak birçok yöntem önerilmiştir.

Bu tez çalışmasında bu amaç doğrultusunda, EEG sinyallerinin sınıflandırılması için yeni bir yöntem önerilmiş ve literatürde sinyallere uygulanan önışlem aşaması ortadan kaldırılmaya çalışılmıştır. Bu işlem ise EEG sinyal verilerinin açı-genlik bilgilerinden oluşan 2-B sonlu grafik görüntüsüne dönüştürülmesi ile gerçekleştirilmiştir.

Önerilen yöntem imleç hareketinin hayali sırasında kaydedilmiş EEG sinyalleri üzerinden sınıflandırma işleminin doğruluğu k -fold çapraz doğrulama yöntemiyle test edilmiş ve veri setinden eğitim için kullanılan veriler rastgele seçilmiştir.

Özellik çıkarma ve boyut azaltma işleminde kullanılan TBA yöntemi için matristeki tüm bileşenlerin kullanılmasına gerek olmadığı ve yeterli sayıda bileşen ile yüksek doğruluk sağlanabileceği görülmüştür. Özellik çıkarımı esnasında elde edilen veri setlerinde gereksiz olan temel bileşenlerin sınıflandırma performansını azaltacağı ve bu ilgisiz verilerin sistem çalışmasına negatif yönde katkı sağlayacağı gözlemlenmiştir.

Sınıflandırma aşamasında k -EYK, YSA ve DVM olmak üzere üç farklı yöntem kullanılmıştır. k -EYK ile sınıflandırma farklı k değerleri ile gerçekleştirilmiştir ve en uygun k değeri de bruteforce arama yöntemiyle tespit edilmiştir. YSA'nın çok katmanlı olarak kullanılması doğrudan sınıflandırma başarısını etkilemektedir. Bu nedenle

görüntüleri sınıflandırmak amacıyla öğrenme kuralı olarak çok katmanlı ve geri yayımlı Perceptron kullanılmasına karar verilmiştir. DVM yönteminde ise kullanılan kernel fonksiyonun yanı sıra bu fonksiyonun en doğru parametre ile kullanılmasının sınıflandırma başarısını ne kadar etkilediği tablolarda da verildiği gibi açıkça görülmüştür.

Tablo 3.20. Çalışmada kullanılan tüm sınıflandırma ve öznitelik çıkarma yöntemlerinin sınıflandırma doğrulukları

	1.Kanal	2.Kanal	3.Kanal	4.Kanal	5.Kanal	6.Kanal
TBA+ DVM	94.47	93.9823	90.9655	90.2495	65.5115	60.1411
TBA+ YSA	75.9292	71.9423	65.9154	69.5613	70.9423	75.2613
TBA+ <i>k</i> -EYK	70.8929	66.4903	61.5695	64.1893	60.7932	57.0370

Kullanılan tüm yöntemler ve bu yöntemlerin her birinden elde edilen en başarılı doğruluk değerleri Tablo 2.20' de özetlenmiştir.

Önerilen yöntemlerin başarısının doğruluğu eğitim ve test işlemlerinin güvenilir ve geçerli veri setleri üzerinden denenmesi ile elde edilebilmektedir. Çalışmada bu amaçla önerilen tüm yöntemler BCI Competition III'de yayınlanmış olan ve BBA çalışmalarında sinyal işleme ve sınıflandırma amacıyla sıklıkla kullanılan Dataset I(a) üzerinde sınanmıştır. En başarılı sonuçlar ise önerilen dönüşüm yöntemi üzerine uygulanan TBA-DVM ikilisi ile elde edildiği açıkça görülmüştür. Literatürde aynı veri seti üzerinde uygulanan ve Tablo 2.19' da listelenen yöntemlerin daha önceki çalışmalardan elde edilen başarı oranları 88.70 ile 92.15 aralığındadır. Elde edilen sonuçlar incelendiğinde bu çalışmada önerilen dönüşüm yöntemi ve özellik çıkarma-sınıflandırma yöntem ikililerinin kabul edilebilir düzeyde başarılı olduğu sonucuna varılmıştır.

Çalışmada önerilen yöntem farklı amaca yönelik EEG verilerine kolayca uygulanabilecek; hasta ve sağlıklı bireylerden alınan veya farklı sınıflara ait herhangi bir veri setinin sınıflandırılmasında rahatlıkla kullanılacaktır. Çalışmada elde edilen sonuçlar bilimsel ve klinik çalışmalarda kullanılıp sınıflandırma işleminde kolaylık sağlayacağı gözlemlenmiştir.

4. ÖNERİLER

Tez çalışmasında, önerilen dönüşüm yöntemi kullanılarak farklı kategorilere ait EEG sinyallerinin etkili bir şekilde ayırt edilebileceği ve sınıflandırılabilceği elde edilen ümit verici sonuçlardan açıkça görülmektedir. Bunun yanında sonraki çalışmalarda daha başarılı sonuçların elde edilebilmesi için önerilebilecek bazı işlemler aşağıdaki gibi listelenebilmektedir.

- EEG sinyali alınırken kullanılan elektrot sayısı artırılabilir ve amaca yönelik belirli bölgeler üzerinden kayıt alınmasına yoğunlaşılabilir.
- Başka ve daha çok örneğe sahip olan veri setleri üzerinde önerilen dönüşüm yöntemi sınanabilir ve farklı türdeki EEG verilerinin sınıflandırılmasında kullanılabilir.
- Sinyaller daha sık örneklenebilirse, sinyal üzerinde daha fazla değişim noktası bulunabileceğinden oluşan Açık-Genlik grafiği daha net bir şekilde elde edilebilir ve böylece sınıflandırma yöntemlerinden daha etkin sonuçlar elde edilebilir.
- Farklı özellik çıkarma yöntemi kullanıldıktan sonra ona en uygun başka sınıflandırma yöntemleriyle de doğruluklar test edilebilir. Başarısı bilinen farklı özellik çıkarma ve sınıflandırma yöntemleri kullanılarak önerilen dönüşüm yöntemi üzerinde daha yüksek doğrulukta sonuçlar elde edilebilir.

5. KAYNAKLAR

1. Sabeti, M., Katebi, S. and Boostani, R., Entropy and complexity measures for EEG signal classification of schizophrenic and control participants, Artificial Intelligence in Medicine, 47, 3 (2009) 263-274.
2. Fraiwan, L., Lweesy, K., Khasawneh, N., Wenz, H., & Dickhaus, H., Automated sleep stage identification system based on time–frequency analysis of a single EEG channel and random forest classifier, Computer methods and programs in biomedicine, 108, 1 (2012) 10-19.
3. Übeyli, E. D., Analysis of EEG signals by combining eigenvector methods and multiclass support vector machines, Computers in Biology and Medicine, 38, 1 (2008), 14-22.
4. Parvinnia, E., Sabeti, M., Jahromi, M. Z., and Boostani, R. , Classification of EEG Signals using adaptive weighted distance nearest neighbor algorithm, Journal of King Saud University-Computer and Information Sciences, 26, 1(2004) 1-6.
5. Bogacz, R., Markowska-Kaczmar, U., & Kozik, A., Blinking artefact recognition in EEG signal using artificial neural network, In Proc. of 4 th Conference on Neural Networks and Their Applications, Zakopane (Poland), November, 1999.
6. Aydemir, Ö., İmlecin iki boyutlu hareketinin hayali sırasında kaydedilmiş EEG işaretlerinin karar ağaç yapısı esaslı sınıflandırılması, Doktora Tezi, KTU, Fen Bilimleri Enstitüsü, Trabzon, 2013.
7. Aydemir, O., and Kayikcioglu, T., Decision tree structure based classification of EEG signals recorded during two dimensional cursor movement imagery, Journal of neuroscience methods, 229, 68-75, 2014.
8. Pfurtscheller, G., Neuper, C., Flotzinger, D., & Pregenzer, M., EEG-based discrimination between imagination of right and left hand movement, Electroencephalography and clinical Neurophysiology, 103, 6 (1997) 642-651.
9. Aydemir, O., and Kayikcioglu, T., Comparing common machine learning classifiers in low-dimensional feature vectors for brain computer interface applications, International Journal of Innovative Computing, Information and Control, 9, 3 (2013) 1145-1157.
10. K Ting, W., Guo-zheng, Y., Bang-hua, Y., and Hong, S., EEG feature extraction based on wavelet packet decomposition for brain computer interface, Measurement, 41, 6 (2008) 618-625.

11. Sun, S., and Zhang, C., Assessing features for electroencephalographic signal categorization, In Proceedings. (ICASSP'05), IEEE International Conference on Acoustics, Speech and Signal Processing, 5, v-417, IEEE, 2005.
12. Wang, B., Jun, L., Bai, J., Peng, L., Li, G., and Li, Y., EEG recognition based on multiple types of information by using wavelet packet transform and neural networks, In 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference, January,2006, 5377-5380.
13. Mensh, B. D., Werfel, J., and Seung, H. S., BCI competition 2003-data set Ia: combining gamma-band power with slow cortical potentials to improve single-trial classification of electroencephalographic signals, IEEE Transactions on Biomedical Engineering, 51, 6 (2004) 1052-1056.
14. Kayıkcioglu, T., and Aydemir, O., A polynomial fitting and k-NN based approach for improving classification of motor imagery BCI data, Pattern Recognition Letters, 31, 11 (2010) 1207-1215.
15. Sanei, S., and Chambers, J. A., EEG signal processing, John Wiley and Sons, 2013.
16. Teplan, M., Fundamentals of EEG measurement. Measurement science review, 2, 2 (2002), 1-11.
17. Aydemir, Ö. , & Kayıkçıoğlu, T., EEG Tabanlı Beyin Bilgisayar Arayüzleri, Akademik Bilişim'09-XI. Akademik Bilişim Konferansı Bildirileri, Şubat, 2009, 7-13.
18. Kalaivani, M., Kalaivani, V., and Devi, V. A., Analysis of EEG Signal for the Detection of Brain Abnormalities, In IJCA Proceedings on International Conference on Simulations in Computing Nexus, 2, 1-6, Foundation of Computer Science (FCS), 2014.
19. Varol, O., Raw EEG data classification and applications using SVM, Doctoral dissertation, Istanbul Technical University. Electrical-electronics Engineering Faculty, 2010.
20. <http://www.eeguzerine.com/?s=Icerik&No=1331884783>. 25 Ekim 2016.
21. Trans Cranial Technologies, 10/20 System Positioning Manual, Trans Cranial Technologies ltd, 2012.
22. B. Blankertz, K.R. Mueller, G. Curio, T.M. Vaughan, G. Schalk, J.R. Wolpaw, A. Schloegl, C. Neuper, G. Pfurtscheller, T. Hinterberger, M. Schroeder, and N. Birbaumer, The BCI Competition 2003: progress and perspectives in detection and discrimination of EEG single trials, IEEE Trans Biomed Eng, 51, 1044-1051, Jun 2004.
23. Yazıcı, M., and Ulutaş, M., Classification of EEG signals using time domain features, 23rd Signal Processing and Communications Applications Conference, SIU, 2358-2361, IEEE, 2015.

24. Dursun, M., EEG Sinyallerinde Uyku İğciklerinin Zaman ve Frekans Domeni Özellikleri Kullanılarak Analizi, Doctoral dissertation, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya, 2009.
25. Collura, T. F., History and evolution of electroencephalographic instruments and techniques, *Journal of clinical neurophysiology*, 10, 4 (1993) 476-504.
26. Haspolat, İ., Investigation of Electroencephalograph signals based on hand movements, MSc Thesis, Fatih University, Institute of Biomedical Engineering, İstanbul, 2016.
27. Duman, F., Destek vektör makineleri yardımıyla invaziv eeg verilerinden epileptik nöbet tahmini, Yüksek Lisans Tezi, Mustafa Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Hatay, 2013.
28. O Smith, L. I., A tutorial on principal components analysis. Cornell University, USA, 51, 52, 2002.
29. Cunningham, P., and Delany, S. J., K-Nearest neighbour classifiers, *Multiple Classifier Systems*, 1-17, 2007.
30. Acar, E., Classification of motor imagery tasks in eeg signal and its application to a brain-computer interface for controlling assistive environmental devices, Master Thesis, Middle East Technical University, Institute of Science and Technology, Ankara, 2011.
31. Berwick, R., An Idiot's guide to Support vector machines (SVMs). Retrieved on October, 21, 2011.
32. Burbidge, R., and Buxton, B., An introduction to support vector machines for data mining. Keynote papers, young OR12, 3-15, 2001.
33. Fletcher, T., Support vector machines explained. Online]. <http://sutikno.blog.undip.ac.id/files/2011/11/SVM-Explained.Pdf>, 06.06.2013.
34. Hofmann, M., Support Vector Machines—Kernels and the Kernel Trick. Notes, 26, 2006.
35. Ortaç Kabaoğlu, R., Destek vektör makineleri tabanlı hata bulma, tanıma ve hata toleranslı kontrol yöntemleri, Doktora Tezi, İTÜ, Fen Bilimleri Enstitüsü, İstanbul, 2010.
36. <https://quizlet.com/2488126/brain-lobes-and-functions-flash-cards/>. 1 Kasım 2016.
37. Moore, A. W., Support vector machines, Tutorial. School of Computer Science of the Carnegie Mellon University, Available at <http://www.cs.cmu.edu/~awm/tutorials>, 16/08/2009.

38. Subasi, A., and Gursoy, M. I., EEG signal classification using PCA, ICA, LDA and support vector machines, Expert Systems with Applications, 37, 12 (2010) 8659-8666.
39. Yılmaz, Ç.M., Görünüm Temelli Yöntemlerle Gerçek Zamanlı Göz Bakış Yönü Kestirimi ve İnsan Bilgisayar Etkileşimi, Yüksek Lisans Tezi, KTU, Fen Bilimleri Enstitüsü, Trabzon, 2014.
40. Ayhan, S. ve Erdoğan, Ş., DVM ile Sınıflandırma Problemlerinin Çözümü, Eskişehir Osmangazi Üniversitesi İİBF Dergisi, 9, 1 (2014) 175-198.
41. Bose, R., Khasnobish, A., Bhaduri, S., and Tibarewala, D. N., Performance analysis of left and right lower limb movement classification from EEG, In Signal Processing and Integrated Networks (SPIN), 2016 3rd International Conference on, 174-179, IEEE, 2016.
42. Abhishek, K., Kumar, A., Ranjan, R., and Kumar, S., A rainfall prediction model using artificial neural network, In Control and System Graduate Research Colloquium (ICSGRC), IEEE, 82-87, IEEE, 2012.
43. Bo, Z., The prediction of warp breakage rate of weaving by considering sized yarn quality using artificial neural network theory, In Computer Design and Applications (ICCD), 2010 International Conference on, 2, V2-526, IEEE, 2010.
44. Reddy, D. K., Manglick, A., Upadhyay, R., and Padhy, P. K., Feature extraction and classification of Electroencephalogram signals for vigilance level detection, In Control, Automation, Robotics and Embedded Systems (CARE), 2013 International Conference on, 1-4, IEEE, 2013.
45. Sezer, E., Epilepsi teşhisi için EEG sinyal analizi, Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya, 2008.
46. <http://serendip.brynmawr.edu/bb/kinser/Structure1.html>. 5 Kasım 2016.
47. http://www.dartmouth.edu/~rswenson/NeuroSci/chapter_11.html. 5 Kasım 2016.
48. Kavzoğlu, T., ve Çölkesen, İ., Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi, Harita Dergisi, 144,7 (2010) 73-82.
49. <http://www.herturbilgi.com/2013/01/en-yakin-komsu-bulma-algoritmasi-knn/>. 6 Kasım 2016.

50. <http://faculty.ksu.edu.sa/MFALREZ/Ebooks%20Library/EEG/EEG%20electrodes.pdf>. 7 Kasım 2016.
51. <http://www.healthline.com/health/eeg#Uses2>. 8 Kasım 2016.
52. <http://www.akgunolmez.com.tr/ic.php?aid=56>. 8 Kasım 2016.
53. <http://cu.dergipark.gov.tr/download/article-file/25356>. 8 Kasım 2016.
54. <https://mindsongproject.co.uk/facts/a-brief-history-of-eeg/>. 8 Kasım 2016.
55. Tat, M., Zihin dili programlaması (NLP) nın kişisel gelişim ve kişilerarası iletişim üzerindeki etkileri, Doctoral Dissertation, Ege Üniversitesi, Sosyal Bilimler Enstitüsü, İzmir, 2007.
56. Yağanoğlu, M., Bozkurt, F., Günay, F. B., EEG tabanlı beyin-bilgisayar arayüzü sistemlerinde öznitelik çıkarma yöntemleri, SDÜ, Mühendislik Bilimleri ve Tasarım Dergisi, 2(3), 313-318, 2014.
57. Durmuş, E., Sadreddini, Z., & Özmen, N. G. Beyin Bilgisayar Arayüzü Sistemleri için Uygun Öznitelik ve Sınıflandırıcı Seçimi.
58. http://www.rehabilitasyon.com/action/makale/1/Beyin_Bilgisayar_Arayuzleri-2299. 10 Kasım 2016.
59. <https://fazlamesai.net/posts/beyin-bilgisayar-arayuzleri-ustune>. 10 Kasım 2016.
60. Glannon, W., Ethical issues with brain-computer interfaces, *Frontiers in systems neuroscience*, 8, 136, 2014.
61. <http://brainmadesimple.com/left-and-right-hemispheres.html>. 12 Kasım 2016.
62. Hatipoglu, B., Gender recognition from face images using PCA and LBP. In 2015 9th International Conference on Electrical and Electronics Engineering (ELECO), pp. 1258-1262, IEEE, 2015.
63. Gumus, E., Kilic, N., Sertbas, A., & Ucan, O. N., Evaluation of face recognition techniques using PCA, wavelets and SVM, *Expert Systems with Applications*, 37(9), 6404-6408, 2010.
64. Cantoni, A., & Butler, P., Eigenvalues and eigenvectors of symmetric centrosymmetric matrices. *Linear Algebra and its Applications*, 13(3), 275-288, 1976.
65. Rajapakse, J. C., & Cichocki, A., Independent component analysis and beyond in brain imaging: EEG, MEG, fMRI, and PET, In *Neural Information Processing, ICONIP'02. Proceedings of the 9th International Conference on*, Vol. 1, pp. 404-412, IEEE, 2002.

66. Ersöz, A., & Özşen, S., Uyku Eeg Sinyalinin Yapay Sinir Ağ Modeli İle Sınıflandırılması.
67. Arslan, D., Elektroensefalografik fokal epileptik deşarjlar ve jeneralizasyon belirteçleri, Uzmanlık Tezi, İnönü Üniversitesi, Nöroloji Anabilim Dalı, Malatya, 2009.
68. Ma, Z., Millar, R., Hiromoto, R., & Krings, A., Logics in animal cognition: Are they important to Brain Computer Interfaces (BCI) and aerospace missions?, In Aerospace Conference, IEEE, pp. 1-8, IEEE, 2010.
69. Klem, G. H., Lüders, H. O., Jasper, H. H., & Elger, C., The ten-twenty electrode system of the International Federation, *Electroencephalogram Clinical Neurophysiology*, 52(3), 1999.
70. Gershenson, C., Artificial neural networks for beginners, arXiv preprint cs/0308031, 2003.
71. Ataseven, B., Yapay sinir ağları ile öngörü modellemesi, İstanbul Kültür Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İstanbul, 2013.
72. <http://www.yildiz.edu.tr/~gulez/3k1n.pdf>. 15 Kasım 2016
73. Yavuz, S., & Deveci, M., İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi, *Erciyes Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, (40), 167-187,2012.
74. <https://ekblc.files.wordpress.com/2014/02/ysa.pdf>. 20 Kasım 2016.
75. Zurada, J. M., Introduction to artificial neural systems, (Vol. 8), St. Paul: West, 1992.
76. <http://w3.gazi.edu.tr/~akcayol/files/ZOL6ANN.pdf>. 20 Kasım 2016
77. http://bm.bilecik.edu.tr/Dosya/Icerik/107/DosyaEki/nsg_ders_notu.pdf. 20 Kasım 2016.
78. Rumelhart, D. E., & Zipser, D., Feature discovery by competitive learning, *Cognitive science*, 9(1), 75-112.ISO 690, 1985.
79. Karakaya, B., Yapay Sinir Ağlarının İncelenmesi ve Sırt Ağrısı Olan Bireyler Üzerinde Bir Uygulaması, Yüksek Lisans Tezi, Sağlık Bilimleri Enstitüsü, Ankara, 2007.
80. Özdemir, H., Yapay sinir ağları ve dokuma teknolojisinde kullanımı, *Tekstil Teknolojileri Elektronik Dergisi*, 7(1), 51-68, 2013.
81. Çayıroğlu, İ., İleri algoritma analizi, Yapay Sinir Ağları, Karabük Üniversitesi, Mühendislik Fakültesi, Karabük.

82. Alpan, G., Görsel okuryazarlık ve öğretim teknolojisi, Yüzüncü Yıl Üniversitesi Eğitim Fakültesi Dergisi, 5(2), 2008.
83. Keleş, E., ve Çepni, S., Beyin ve öğrenme, Türk Fen Eğitimi Dergisi, 3,2 (2006) 66-82.
84. <http://biyolojiciler.blogcu.com/insan-beyninin-bolumleri/3093722>. 25 Kasım 2016.
85. Coşkun, M., ve İstanbullu, A. EEG İşaretlerinin FFT ve Dalgacık Dönüşümü ile Analizi, 2012.
86. <http://eee.ktu.edu.tr/labs/med.end/EEG.pdf>. 25 Kasım 2016.
87. Avşar, E., Tek-Sınıf Destek Vektör Makineleri Kullanılarak Epileptik Eeg İşaretlerinin Sınıflandırılması, Doctoral dissertation, Fen Bilimleri Enstitüsü, 2009.
88. Palabaş, T., Ayrık Dalgacık Dönüşümü Bileşenlerine Ait İstatistiksel Veriler ile Epileptik EEG İşaretlerinin Sınıflandırılması, AJIT-e: Online Academic Journal of Information Technology, 5,15, 2014.
89. Bulut, F. ve Amasyalı, M. F. En Yakın k Komşuluk Algoritmasında Örneklerle Bağlı Dinamik k Seçimi.
90. Dule, E., Araç Renk Tanıma Sistemi, Doctoral dissertation, İstanbul Teknik Üniversitesi, Bilişim Enstitüsü, İstanbul, 2016.
91. <http://slideplayer.biz.tr/slide/2390585/>. 25 Kasım 2016.
92. Taşova, O., Yapay Sinir Ağları ile Yüz Tanıma, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir, 2011.
93. Sancakdar, T., Yapay Sinir Ağı Destekli Kalman Filtresi Yardımı ile Hedef İzleme, Doctoral Dissertation, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2002.

ÖZGEÇMİŞ

1991 yılında Trabzon'da doğdu. İlköğrenimini Yıldızlı İlköğretim Okulu'nda, orta öğrenimini Yüzüncü Yıl İlköğretim Okulu'nda, lise öğrenimini Yunus Emre Yabancı Dil Ağırlıklı Süper Lisesi'nde tamamladı. 2009 yılında Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü'nde lisans programına başladı ve 2013 yılında bu bölümden mezun oldu. 2014 yılında Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans öğrenimine başladı. 2014 bahar döneminden itibaren Bilgisayar Mühendisliği bölümünde araştırma görevlisi olarak çalışmaktadır.

