

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



EEG SINYALLERİNİN SINIFLANDIRILMASINDA KUANTUM
TABANLI KARAR DESTEK SİSTEMİNİN
GERÇEKLEŞTİRİLMESİ

Gamzepelin AKSOY

Doktora Tezi

YAZILIM MÜHENDİSLİĞİ ANABİLİM DALI

TEMMUZ 2024

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Doktora Tezi

EEG SİNYALLERİNİN SINIFLANDIRILMASINDA KUANTUM TABANLI KARAR DESTEK SİSTEMİNİN GERÇEKLEŞTİRİLMESİ

Tez Yazarı

Gamzepelin AKSOY

Danışman

Prof. Dr. Murat KARABATAK

TEMMUZ 2024

ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Doktora Tezi

Başlığı:	EEG Sinyallerinin Sınıflandırılmasında Kuantum Tabanlı Karar Destek Sisteminin Gerçekleştirilmesi
Yazarı:	Gamzepelin AKSOY
İlk Teslim Tarihi:	24.06.2024
Savunma Tarihi:	24.07.2024

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Prof. Dr. Murat KARABATAK Fırat Üniversitesi, Teknoloji Fakültesi	İmza Onayladım
Başkan:	Prof. Dr. Erkan TANYILDIZI Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Doç Dr. Özal YILDIRIM Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Doç. Dr. Ali ARI İnönü Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Talha Burak ALAKUŞ Kırklareli Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “EEG Sinyallerinin Sınıflandırılmasında Kuantum Tabanlı Karar Destek Sisteminin Gerçekleştirilmesi” Başlıklı Doktora Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

24.07.2024

Gamzepelin AKSOY



ÖNSÖZ

Bilgisayar bilimlerinin hızla gelişen ve büyük ilgi gören bir dalı olan kuantum hesaplama, büyük veri problemlerine yenilikçi çözümler sunmak amacıyla geliştirilmiştir. Kuantum mekaniğinin eşsiz ilkeleri ile yapay zekânın sağladığı avantajların bir araya getirilmesi sonucunda kuantum programlama alanı ortaya çıkmıştır. Bu alandaki en önemli alt dallardan biri olan kuantum makine öğrenimi, klasik makine öğrenimi algoritmalarını kuantum mekaniğinin güçlü yapısıyla entegre etmeyi amaçlamaktadır. Bu tez çalışmasında, kuantum makine öğreniminin EEG sinyalleri üzerinde etkinliğini göstermek amacıyla kapsamlı analizler gerçekleştirilmiştir. Kuantum bilgisayara erişimin kısıtlı olması ve bu bilgisayarlarda kullanılabilen sınırlı kubit sayılarına rağmen, kuantum makine öğrenme yöntemlerinin EEG sinyallerinin analizinde klasik yöntemlerden daha yüksek başarımlar göstermiş olması, bu alanda gerçekleştirilecek yeni çalışmalar için umut vaat edicidir.

Doktora sürecinde bilgi ve tecrübeleriyle bana her zaman ışık tutan değerli danışmanım Prof. Dr. Murat KARABATAK'a teşekkür eder, saygılarımı sunarım. Tez izleme komitesi üyesi hocalarım Prof. Dr. Erkan TANYILDIZI ve Prof. Dr. Mehmet KARAKÖSE'ye, değerli katkıları ve önerileri için şükranlarımı sunarım. Bu tez çalışmasının her aşamasında bana rehberlik eden ve yol gösteren kıymetli hocam Doç. Dr. Özal YILDIRIM'a sonsuz teşekkür ederim.

Doktora sürecinde tüm zorlukların üstesinden birlikte geldiğimiz sevgili arkadaşlarım Dr. Öğr. Üyesi Zeynep ÖZPOLAT ve Öğr. Gör. Gökçe YILDIRIM'a içtenlikle teşekkür ederim. En sıkışık zamanımda bile bana vakit ayırıp destek olan Öğr. Gör. Büşra YALÇIN'a teşekkür ederim. Gece gündüz demeden tez süreçlerimizi birlikte yürüttüğümüz Arş. Gör. Mehmet ARZU'ya da teşekkür ederim.

Hayatımın her anında maddi ve manevi hiçbir desteğini esirgemeyen, zor anlarımda yanımda olan sevgili anne ve babama teşekkür ederim. Bu süreçte her zaman yanımda olan, bana inanan ve desteklerini hiçbir zaman esirgemeyen canım kardeşim Gonca Pervin AKSOY'a minnettarım.

Gamzepelin AKSOY
ELAZIĞ, 2024

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xi
EKLER LİSTESİ	xii
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ	1
1.1. Tezin Amacı, Katkısı	5
1.2. Tezin Organizasyonu	6
2. BİLGİSAYAR DESTEKLİ EEG ANALİZ SİSTEMLERİ	7
2.1. Elektroensefalografi ve Beyin Dalgaları.....	9
2.2. EEG Sinyallerinin Ölçülmesi	10
2.3. Beyin Bilgisayar Arayüzleri	12
2.3.1. EEG Tabanlı BBA Kontrol Sinyalleri.....	15
2.3.2. BBA Sistemlerinde Ön İşleme	17
2.3.3. BBA Sistemlerinde Özellik Çıkarımı	19
3. MAKİNE ÖĞRENMESİ.....	28
3.1. Makine Öğrenmesi Algoritmaları.....	29
3.1.1. Karar Ağaçları	29
3.1.2. Lojistik Regresyon	29
3.1.3. K-En Yakın Komşu Algoritması	30
3.1.4. Rastgele Orman	30
3.1.5. Naive Bayes	31
3.1.6. Destek Vektör Makinesi.....	31
3.2. Meta-Sezgisel Optimizasyon Algoritması	32
3.3. Makine Öğrenmesinde Kullanılan Performans Değerlendirme Metrikleri	33
4. KUANTUM MEKANİĞİ.....	36
4.1. Kuantum Mekanikinin Temel Deneyleri	37
4.1.1. Schrödinger'in Kedisi	37
4.1.2. Çift Yarıık Deneyi.....	38
4.2. Kuantum Mekanikisi ve Kuantum Hesaplamanın Temel Kavramları.....	39
4.2.1. Süperpozisyon ve Paralel Evrenler.....	39
4.2.2. Dolanıklık ve Kuantum İletişimi	40
4.2.3. Kuantum Işınlanma	41
4.2.4. Hilbert Uzayı.....	42
4.2.5. Kuantum Bit (Kübit)	43
4.2.6. Kuantum Mantık Kapıları	45
4.3. Kuantum Makine Öğrenmesi.....	46
4.3.1. Kuantum Özellik Haritaları	50
4.3.2. Kuantum Destek Vektör Makinesi	52

4.3.3. Değişken Kuantum Sınıflandırıcı.....	55
5. KUANTUM MAKİNE ÖĞRENMESİ UYGULAMALARI	57
5.1. EEG Sinyalleri Üzerinde QSVM ve Diğer Makine Öğrenimi Algoritmalarının Karşılaştırılması .	57
5.1.1. <i>EEG Göz Durumu</i> Veri Seti	59
5.1.2. Deneysel Çalışma.....	59
5.1.3. Sonuçlar ve Tartışma.....	63
5.2. Şizofreni Tespiti için Kuantum Makine Tabanlı Karar Destek Sistemi	64
5.2.1. Şizofreni Alanında Kullanılan Klasik Makine Öğrenimi Teknikleri.....	66
5.2.2. <i>EEG Şizofreni</i> Veri Seti.....	69
5.2.3. Deneysel Çalışma.....	69
5.2.4. Sonuçlar ve Tartışma.....	80
5.3. Yalan Tespit Sistemleri: Bir Kuantum Uygulaması	83
5.3.1. <i>LieWaves</i> Veri Seti	86
5.3.2. Deneysel Çalışma.....	87
5.3.3. Sonuçlar ve Tartışma.....	96
6. SONUÇLAR	98
ÖNERİLER	101
KAYNAKLAR.....	102
EKLER	116
ÖZGEÇMİŞ	

ÖZET

EEG Sinyallerinin Sınıflandırılmasında Kuantum Tabanlı Karar Destek Sisteminin Gerçekleştirilmesi

Gamzepelin AKSOY

Doktora Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Yazılım Mühendisliği Anabilim Dalı

Temmuz 2024, Sayfa: xiii + 115

Elektroensefalografi sinyalleri, sağlık sektöründen günlük yaşam aktivitelerinin analizine kadar geniş bir yelpazede uygulama alanı bulan, beyin aktivitelerini ölçen önemli biyomedikal veri kaynaklarıdır. Bu sinyaller, beyin dalgalarının elektriksel aktivitesini non-invaziv bir şekilde kaydederek, çeşitli nörolojik durumların ve bilişsel süreçlerin anlaşılmasına olanak tanır. EEG sinyallerinin ölçümü ve analizi, çeşitli makine öğrenmesi ve derin öğrenme teknikleri kullanılarak gerçekleştirilir. Bu tez çalışması, kuantum makine öğrenmesi tekniklerini kullanarak EEG sinyallerinin sınıflandırılmasındaki başarıyı analiz etmeyi hedeflemektedir. Kuantum makine öğrenmesi algoritmaları, kuantum hesaplama gücünü klasik makine öğrenmesi yöntemleriyle birleştirerek geliştirilen algoritmalarlardır. Tezin temel hipotezi, kuantum makine öğrenmesi algoritmalarının hız ve doğruluk açısından klasik algoritmaları geride bırakabileceği yönündedir.

Tez kapsamında, ilk olarak EEG göz durumu veri seti üzerinde kuantum destekli SVM ve klasik makine öğrenme algoritmaları kullanılarak yapılan analizler sunulmuş ve kuantum tabanlı sınıflandırma algoritmalarının etkinliği ortaya konulmuştur. Yapılan ikinci çalışmada, EEG şizofreni veri seti kullanılarak çeşitli özellik haritalarının QSVM algoritmasının sınıflandırma başarısı üzerine etkisi incelenmiştir. Bu çalışma Pauli X özellik haritası için tüm kübit sayılarında %100 başarıya ulaşmıştır. Tez kapsamında gerçekleştirilen son çalışmada ise LieWaves veri setinde farklı parametrik kuantum devrelerinin kullanıldığı VQC algoritmaları incelenmiştir. QSVM algoritmasının statevector ve Qasm simülatör ortamlarından performansı değerlendirilmiştir. Ayrıca QSVM ve VQC algoritmasında özellik haritaları ve VQC algoritmasında parametrik kuantum devreleri optimize edilmiştir. Elde edilen sonuçlar SVM algoritması ile karşılaştırılmış ve önerilen yöntemin klasik SVM algoritmasına göre daha yüksek performans gösterdiği görülmüştür.

Tez kapsamında yapılan çalışmalar, gelişmekte olan bir alan olmasına rağmen kuantum makine öğrenme algoritmalarının, klasik makine öğrenme yöntemlerine göre üstün performans gösterebileceğini ortaya koymaktadır. Kuantum simülatör ortamlarının kullanımı nedeniyle hız açısından, klasik makine öğrenme algoritmalarına göre çalışma süreleri daha fazladır. Kuantum bilgisayarların aktif olarak kullanılması ile hız problemlerinin de çözüme ulaşacağı öngörülmektedir.

Anahtar Kelimeler: EEG, Kuantum Makine Öğrenmesi, Makine Öğrenmesi, Özellik Haritaları

ABSTRACT

Implementation of Quantum-Based Decision Support System for Classification of EEG Signals

Gamzepelin AKSOY

Ph.D. Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Software Engineering

July 2024, Pages: xiii + 115

Electroencephalography (EEG) signals are significant biomedical data sources that measure brain activity, with applications ranging from healthcare to the analysis of daily life activities. These signals record the non-invasive electrical activity of brain waves, enabling the understanding of various neurological conditions and cognitive processes. The measurement and analysis of EEG signals involve the utilization of various machine learning and deep learning techniques. This thesis aims to analyze the efficacy of utilizing quantum machine learning techniques in the classification of EEG signals. Quantum machine learning algorithms combine the computational power of quantum computing with classical machine learning methods. The fundamental hypothesis of this thesis is that quantum machine learning algorithms can exceed classical algorithms in terms of speed and accuracy.

Within the scope of this thesis, initial analyses are presented, utilizing quantum-enhanced SVM and classical machine learning algorithms on an EEG eye state dataset, thereby demonstrating the effectiveness of quantum-based classification algorithms. In a second study, the influence of various feature maps on the classification success of the QSVM algorithm is examined using an EEG schizophrenia dataset. This study achieved 100% accuracy across all qubit numbers for the Pauli X feature map. The final study within the thesis investigates VQC algorithms using different parametric quantum circuits on the LieWaves dataset. The performance of the QSVM algorithm is evaluated across state vector and Qasm simulator environments. Additionally, feature maps in QSVM and parametric quantum circuits in VQC algorithms are optimized. The results obtained are compared with the SVM algorithm, demonstrating that the proposed method outperforms classical SVM algorithms.

Despite being an emerging field, the studies conducted within this thesis demonstrate that quantum machine learning algorithms have the potential to outperform classical machine learning methods. Currently, these algorithms require longer processing times compared to classical machine learning algorithms due to the utilization of quantum simulator environments. However, it is anticipated that these speed issues will be resolved with the active use of quantum computers.

Keywords: EEG, Quantum Machine Learning, Machine Learning, Feature Maps

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. EEG bantlarının frekans spektrumu.....	10
Şekil 2.2. EEG Sistemi.....	11
Şekil 2.3. EEG sisteminde kullanılan elektrotların konumu	12
Şekil 2.4. BBA sisteminin temel yapısı	13
Şekil 2.5. BBA kontrol sinyalleri	15
Şekil 2.6. PCA yönteminin temel aşamaları	20
Şekil 2.7. 4. seviye dalgacık dönüşümü	27
Şekil 3.1. Yapay zeka ve makine öğrenmesi kapsamı	28
Şekil 3.2. İki sınıflı veriler için (a) lineer SVM, (b) lineer olmayan SVM	32
Şekil 3.3. Karışıklık Matrisi	34
Şekil 4.1. Schrödinger'in kedisi düşünce deneyi	37
Şekil 4.2. Çift Yarıık Deneyi	38
Şekil 4.3. Kuantum dolanıklığı	41
Şekil 4.4. Bloch küresi üzerinde bir kübit'in durumu	44
Şekil 4.5. Klasik makine öğrenimi ve kuantum makine öğreniminin aşamaları	49
Şekil 4.6. ZZ özellik haritası devre çizimi	51
Şekil 4.7. Z özellik haritasının gösterimi	51
Şekil 5.1. EEG Göz Durumu veri setinde kullanılan kanallar	59
Şekil 5.2. QSVM metoduna ait blok diyagram	60
Şekil 5.3. ZZFeatureMap (2 tekrar)	60
Şekil 5.4. Farklı öznitelik sayılarına göre klasik makine öğrenme yöntemlerinin doğruluk oranları	61
Şekil 5.5. Farklı öznitelik sayılarına göre SVM ve QSVM algoritmasının doğruluk oranı grafikleri	62
Şekil 5.6. (a) EEG veri kümesindeki kanalların yer aldığı bölgeler, (b) Veri setindeki hasta bir bireyin kanallara göre EEG kayıtları.....	69
Şekil 5.7. Önerilen yöntemin şematik görünümü.....	70
Şekil 5.8. 4. seviye ayrık dalgacık dönüşümünün blok diyagramı	71
Şekil 5.9. Cz kanalındaki EEG sinyaline ayrık dalgacık dönüşümü uygulanarak elde edilen dalgalar ...	71
Şekil 5.10. PCA'nın veri kümesine uygulanmasını gösteren bir blok diyagram	72
Şekil 5.11. Klasik makine öğrenmesi algoritmalarının 4 kanal için performans grafiğı	73
Şekil 5.12. Çalışmada kullanılan kuantum özellik haritaları.....	76
Şekil 5.13. 4 kanal için Pauli X ve Pauli Z Özellik Haritalarını kullanan QSVM algoritmasının performans grafiğı.....	79

Şekil 5.14.	VQC modelinin şematik görünümü	87
Şekil 5.15.	Veri setinin hazırlanma süreci	88
Şekil 5.16.	Temel bileşen analizi uygulaması	88
Şekil 5.17.	ZZFeaturemap (1 tekrar).....	89
Şekil 5.18.	VQC algoritmasında kullanılan parametrik kuantum devreleri	89
Şekil 5.19.	PSO-QSVM ile gerçekleştirilen deneysel modleın şematik gösterimi	92
Şekil 5.20.	Önerilen modelin blok diyagramı	93



TABLÖLAR LİSTESİ

	Sayfa
Tablo 2.1. Beyin dalgaları siyal frekans aralıkları ve açıklamaları	9
Tablo 2.2. Özellik çıkarımı aşamasında kullanılan istatistiksel yöntemler	22
Tablo 4.1. Kuantum mantık kapıları	45
Tablo 5.1. Öznitelik sayısına göre makine öğrenme algoritmalarının performans karşılaştırması	61
Tablo 5.2. 5 kubit için QSVM'in performans metrikleri	62
Tablo 5.3. Klasik sınıflandırıcılar için Cz ve T3 kanalından elde edilen doğruluk oranları.....	74
Tablo 5.4. Cz ve T3 kanallarından 5 kubit için elde edilen sınıflandırma performansları	74
Tablo 5.5. Cz kanalı EEG sinyallerine farklı özellik haritaları uygulandığında elde edilen QSVM doğruluk oranları	77
Tablo 5.6. Cz kanalından 5 kubit için elde edilen sınıflandırma performans metriklerinin sonuçları.....	78
Tablo 5.7. T3 kanalı EEG sinyallerine farklı özellik haritaları uygulandığında elde edilen QSVM doğruluk oranları	78
Tablo 5.8. T3 kanalından 5 kubit için elde edilen sınıflandırma performans metriklerinin sonuçları.....	79
Tablo 5.9. <i>EEG şizofreni</i> veri setiyle ilgili bazı çalışmalardan performans karşılaştırmaları	81
Tablo 5.10. <i>LieWaves</i> veri seti hakkında genel bilgiler	86
Tablo 5.11. RealAmplitude ve EfficientSU2 kuantum devre yapılarının sınıflandırma performansı	90
Tablo 5.12. PSO algoritması için kullanılan temel parametreler	91
Tablo 5.13. <i>LieWaves</i> veri setine QSVM algoritması uygulanması sonucu elde edilen doğruluk oranları	92
Tablo 5.14. SVM ve PSO-QSVM algoritmalarının parametreleri ve ortalama doğruluk oranları	94
Tablo 5.15. PSO-VQC algoritmasının parametreleri ve ortalama doğruluk oranları	95

EKLER LİSTESİ

	Sayfa
Ek- 1: PSO-QSVM Algoritmasında Kullanılan Özellik Haritaları (Rastgele Bölümleme)	116
Ek- 2: PSO-QSVM Algoritmasında Kullanılan Özellik Haritaları (K Katlı Çapraz Doğrulama)	121
Ek- 3: VQC Algoritmasında Kullanılan Özellik Haritaları (K Katlı Çapraz Doğrulama)	125
Ek- 4: VQC Algoritmasında Kullanılan Parametrik Kuantum Devreleri (K Katlı Çapraz Doğrulama)	126



SİMGELER VE KISALTMALAR

Kısaltmalar

ACC	: Doğruluk (Accuracy)
ALS	: Amyotrofik Lateral Skleroz
ANN	: Yapay Sinir Ağları (Artificial Neural Network)
AR	: Otoregresif Bileşenler (AutoRegressive Components)
BBA	: Beyin Bilgisayar Arayüzü (Brain-Computer Interface)
BoL	: Bag-of-Lies
C: Central	
CNN	: Evrişimli Sinir Ağları (Convolutional Neural Networks)
COBYLA	: Doğrusal Yaklaşımlar ile Kısıtlı Optimizasyon (Constrained Optimization BY Linear Approximations)
CPU	: Merkezi İşlem Birimi (Central Processing Unit)
CSP	: Ortak uzaysal desenler (Common Spatial Pattern)
DT	: Karar Ağaçları (Decision Trees)
DTF	: Doğrudan Transfer Fonksiyonu (Directed Transfer Function)
DWT	: Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)
EBT	: Ensemble Bagged Tree
ECG	: Elektrokardiyografi
EEG	: Elektroensefalografi (Electroencephalogram)
ERP	: Olayla İlgili Potansiyeller (Event Related Potentials)
F	: Frontal
FFT	: Hızlı Fourier Dönüşümü (Fast Fourier Transform)
FN	: Yanlış-Negatif (False-Negative)
FP	: Yanlış-Pozitif (False-Positive)
Fp	: Frontal Kutup
GPU	: Grafik İşlemci Birimi (Graphics Processing Unit)
HOS	: Yüksek dereceli spektral (Higher-Order Spectral)
IBRO	: Uluslararası Beyin Araştırma Örgütü
ICA	: Bağımsız Bileşen Analizi (Independent Component Analysis)
IFR	: Artımlı Özellik Yeniden Sıralama (Incremental Feature Reordering)
KNN	: k-En Yakın Komşu (k-nearest neighbors)
LDA	: Lineer Diskriminant Analizi (Linear Discriminant Analysis)
LR	: Lojistik Regresyon (Logistic Regression)
LSTM	: Uzun-Kısa Süreli Bellek (Long Short-Term Memory)
MHRC	: Ruh Sağlığı Araştırma Merkezi
MIF	: Çok Değişkenli Yinelemeli Filtreleme
MRI	: Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging)
MU3D	: Miami University Deception Detection
NB	: Naive Bayes
NISQ	: Gürültülü Orta Ölçekli Kuantum (Noisy Intermediate-Scale Quantum)
O	: Occipital
P	: Parietal
PCA	: Temel Bileşen Analizi (Principal Component Analysis)

PSO	: Parçacık Sürü Optimizasyonu (Particle Swarm Optimization)
QC ANN	: Kuantum Hesaplamalı Yapay Sinir Ağları (Quantum Computing Artificial Neural Networks)
Q-KNN	: Kuantum K- En Yakın Komşu (Quantum K-Nearest Neighbour)
qKSVM	: Kuantum-çekirdek Destek Vektör Makinesi (Quantum Kernel Support Vector Machine)
QML	: Kuantum Tabanlı Makine Öğrenmesi (Quantum Machine Learning)
QNN	: Kuantum Sinir Ağları (Quantum Neural Network)
QPCA	: Kuantum Temel Bileşen Analizi (Quantum Principal Component Analysis)
QRF	: Kuantum Rastgele Orman (Quantum Random Forrest)
QSVM	: Kuantum Destek Vektör Makinesi (Quantum Support Vector Machine)
QVC	: Kuantum Değişken Devreler (Quantum Variational Circuits)
RL	: Real-Life
RF	: Rastgele Orman (Random Forest)
RQNN	: Tekrarlayan Kuantum Yapay Sinir Ağı (Recurrent Quantum Neural Network)
SCP	: Yavaş Kortikal Potansiyeller (Slow Cortical Potentials)
SPWVD	: Smoothed Pseudo-Wigner-Ville Distribution
SSEP	: Kararlı Durum Uyarılmış Potansiyeller (Steady-State Evoked Potentials)
SVM	: Destek Vektör Makinesi (Support Vector Machine)
SzHNN	: Şizofreni Hibrit Sinir Ağı
TN	: Doğru-Negatif (True Negative)
TP	: Doğru-Pozitif (True Positive)
VEP	: Görsel Uyarılmış Potansiyeller (Visual Evoked Potentials)
VQC	: Değişken Kuantum Sınıflandırıcı (Variational Quantum Classifier)
WT	: Dalgacık Dönüşümü (Wavelet Transform)

1. GİRİŞ

Bilgisayar bilimleri, birçok disiplinle etkileşim içinde olan geniş bir alandır ve bu disiplinlerin başında sağlık bilimleri gelmektedir. Bilgisayar bilimleri ve sağlık bilimleri arasındaki bu güçlü ilişki, büyük ölçüde sürekli ve güncel veri akışının varlığına dayanmaktadır. Tıp dünyasında, her alt dalda toplanan veriler, bilgisayar destekli sistemlerle analiz edilmekte ve bu sayede daha hassas ve etkili sağlık çözümleri geliştirilmektedir. Özellikle yapay zekâ alanında, beyin araştırmaları ve beyinden elde edilen çeşitli biyolojik veriler, bu gelişimin temel taşlarını oluşturmaktadır. Bu işbirliği, sağlık hizmetlerinin iyileştirilmesine ve hastalıkların daha erken teşhis edilmesine olanak tanıyarak, bilgisayar bilimlerinin potansiyelini, sağlık sektöründe daha da arttırmaktadır.

Bilgisayar bilimleri ve nöroloji alanlarının kesişim noktasında, Elektroensefalografi (EEG) gibi teknolojilerin beyin aktivitelerini detaylı bir şekilde incelemesi ve bu verilerin bilgisayar destekli sistemlerle analiz edilerek, beyin fonksiyonları hakkında derinlemesine anlayış sağlanması oldukça önemlidir. Beyindeki dalgalanmalardan elde edilen sinyalleri içeren EEG verileri, beyin aktivitelerinin incelenmesinde kullanılan temel kaynaklardandır. EEG, beyin aktivitelerini incelemek, ölçmek ve kaydetmek için aktif olarak kullanılan bir yöntem olup, çeşitli nörolojik durumların anlaşılmasını sağlayan etkili yöntemler arasında yer almaktadır. Epilepsi [1], Parkinson [2], Alzheimer [3], majör depresyon [4], uyku bozuklukları [5] gibi birçok nörolojik ve fizyolojik hastalığın yanı sıra sürücü yorgunluğunun belirlenmesi [6], duygu analizi [7], bağımlılığa yatkınlığın belirlenmesi [8], yalan tespit sistemi [9] gibi farklı alanlarda da EEG sinyalleri kullanılarak kapsamlı çalışmalar yapılmaktadır. Bu çalışmalarda elde edilen verilerden beyin bilgisayar arayüzleri oluşturmak için sinyal işleme ve yapay zekâ algoritmaları kullanılmaktadır. Yapılan bu analizler, beyin fonksiyonları hakkında detaylı bilgiler sunmaktadır. Dolayısıyla, EEG sinyallerinin analizi ve yorumlanması, bilgisayar bilimleri ve veri bilimi için kritik bir araştırma alanı haline gelmiştir.

EEG sinyallerinin işlenmesi ve analiz edilmesinde en çok tercih edilen yöntemlerden biri makine öğrenmesi teknikleridir. Bilgisayar sistemlerinin verilerden öğrenme ve karar verme süreçlerini otomatik hale getirmeyi amaçlayan makine öğrenmesi, EEG sinyallerinden anlamlı bilgiler çıkarılması bağlamında önemli katkılar sunmaktadır. Ancak, veri boyutlarının artması ve hesaplama gücündeki yükseliş beklentisi, bazı durumlarda makine öğrenmesi algoritmalarının yetersiz kalmasına neden olmaktadır. Bu sebeple geliştirilen derin öğrenme yöntemleri, nörolojik incelemelerin gerçekleştirilebilmesi sürecinde EEG sinyallerinin işlenmesi ve yorumlanması için önemli bir araç olarak öne çıkmaktadır.

İnsan beyninin çalışma mekanizmasından esinlenerek oluşturulan çok katmanlı sinir ağları, derin öğrenme modellerine kaynaklık etmiştir. Derin öğrenme, yapay sinir ağları gibi karmaşık algoritmalar sayesinde büyük ve karmaşık veri setlerinde yüksek performanslı sonuçlar elde etmeyi

amaçlayan makine öğrenmesi tabanlı yapıdır. Derin öğrenme modelleri, giriş verisini başlangıç noktası seçerek sırayla çeşitli katmanlarda bilgiyi işler ve nihai çıktıyı üretir. Bu kademeli süreç, insan beynindeki nöronların öğrenme prensibine benzer bir öğrenme oluşmasını sağlar. Derin öğrenme algoritmaları sayesinde EEG verilerinden özellik çıkarımı ve karmaşık desenlerin tanımlanması kolaylıkla yapılabilmektedir. 1940’larda ortaya atılan derin öğrenme fikirleri bazı dönemlerde duraksamalar yaşasa da günümüzde etkinliğini sürdürmektedir. Ancak, ilerleyen teknoloji ile birlikte büyüyen veri yığınları, hesaplama gücünün çok üst seviyelerde olmasını gerektirmiştir. Bu ihtiyacı gidermek için süper bilgisayarlar kullanılmaya başlansa da hem büyük veri hem de karmaşık hesaplamalar bir araya geldiği için klasik bilgisayarlar yetersiz kalmaya başlamıştır.

20. yüzyılın başlarında kuantum mekaniğinin ilginç ilkelerinin kabul edilmesi ile bilim dünyasında büyük bir devrim yaşanmıştır. Kuantum mekaniği, atom altı parçacıkların davranışlarını açıklayan ve klasik fiziğe aykırı kurallarla işleyen bir bilim dalı olarak, hesaplamada bilim insanlarına farklı bir bakış açısı ve çalışma alanı sunmaktadır. Kuantum bilgisayarlar, kuantum mekaniğinin süperpozisyon ve dolanıklık gibi prensiplerini kullanarak klasik bilgisayarlardan çok daha hızlı bir şekilde problemleri çözüme ulaştırmayı hedeflemektedir. 1980’lerin başında Richard Feynman ve David Deutsch gibi öncü bilim insanları, kuantum bilgisayarların teorik temellerini atmışlardır [10]. Kuantum mekaniği kavramında yaşanan gelişmeler ve kuantum bilgisayarların ortaya çıkışı ile birlikte kuantum hesaplama kavramının ortaya çıkmıştır. Bu yeni hesaplama paradigması, makine öğrenimi modellerinin de kuantum hesaplama kavramı çerçevesinde değişikliğe uğramasına sebep olmuştur. Kuantum bilgisayarların sağladığı yüksek hesaplama gücü ve veri işleme kapasitesi, kuantum makine öğrenme modellerinin geliştirilmesine zemin hazırlamıştır. Bu modeller, klasik makine öğrenmesi algoritmalarına kıyasla daha yüksek verimlilik ve doğruluk sunarak, büyük veri setlerinin analizinde ve karmaşık desenlerin tanımlanmasında kayda değer nitelikte çözümler sunmayı hedeflemektedir.

Kuantum mekaniği kavramı uzun yıllar önce ortaya atılmasına rağmen teknolojik gelişmelerle birlikte son yıllarda birçok uygulama alanı bulmuştur. Bu alanlar içerisinde sağlık bilimleri ön plana çıkmaktadır. Tez çalışmasının bu kısmında literatürde yer alan kuantum makine öğrenmesi (Quantum Machine Learning, QML) algoritmalarına ve uygulamalı çalışmalara yer verilmiştir.

Sharma, K-en yakın komşu sınıflandırıcısının sınıflandırma yöntemine benzeyen bir değişken kuantum devresi olan Kuantum K-en yakın komşu (Quantum K-Nearest Neighbour, Q-KNN) algoritmasını tanıtmışlardır. Yapmış olduğu algoritmada uzaklık ölçümü için Hamming yöntemini kullanmıştır ve 10 boyutlu göğüs kanseri veri setinde gerçekleştirdiği deneylerin klasik K- en yakın komşu (KNN)’dan daha iyi sonuçlar gösterdiğini belirtmiştir [11]. Chalumuria vd., süper bilgisayarların bile büyük veri ile dolup taşıdığı bir aşamaya ulaşılması beklendiğinden, Yapay Sinir Ağları (Artificial Neural Networks-ANN) eğitiminin, büyük verinin boyutu nedeniyle zorlu bir

görev haline geleceğinden bahsetmiştir. Ayrıca, modelleri öğrenmek ve bu tür verileri analiz etmek için ağda çok sayıda parametre kullanılmasının ve optimize edilmesinin gerekliliğinin zorunlu olduğunu belirtmişlerdir. Kuantum bilgisayarın kubitleri kullanarak verileri farklı şekilde temsil edebildiğinden, kuantum hesaplamanın bu soruna çözüm sağlayan bir alan olarak ortaya çıktığını ifade etmişlerdir. Kuantum bilgisayarlardaki kubitlerin, klasik bir bilgisayarın bulması zor olan verilerdeki gizli kalıpları tespit etmek için kullanılması gerektiğini öne sürmüşlerdir. Bu nedenle, kuantum bilgisayarların ANN alanında büyük bir uygulama alanı olduğunu belirleyen araştırmacılar bu çalışmada, öncelikle kubitleri yapay nöronlar olarak kullanan yapay bir sinir ağını eğitmeye odaklanmışlardır. Kuantum simülatorü kullandıkları çalışmada, Kuantum Hesaplamalı Yapay Sinir Ağı (Quantum Computing Neural Network, QC ANN) için kuantum hesaplama yaklaşımlarının, klasik ANN ile karşılaştırıldığında daha iyi performans gösterdiğini belirtmişlerdir. Yapay nöronlar olarak kubitlere sahip model, ikili bir sınıflandırma görevi için daha az parametre kullanarak verilerin özelliklerini öğrenebilmiştir [12]. Havlicek vd., Destek Vektör Makinelerinin (Support Vector Machine, SVM) sınıflandırma problemleri için en iyi bilinen yöntem olduğunu ancak, öznelilik uzayı genişlemesi durumunda ve çekirdek fonksiyonlarının hesaplanması aşamasında sınırlamaları olduğunu belirtmiştir. Kuantum algoritmaları tarafından etkinleştirilen hesaplama hızlandırmalarındaki temel bir unsur, kontrol edilebilir karışıklık ve girişim yoluyla üstel olarak büyük bir kuantum durum uzayının kullanılmasıdır. Burada bir süper iletken işlemci üzerinde iki kuantum algoritması önermiştir ve deneysel olarak uygulamıştır. Her iki yöntemde de önemli bir bileşenin, kuantum durum uzayının özellik uzayı olarak kullanılması olduğunu vurgulamıştır [13]. Lloyd vd., makine öğrenimi görevlerinin sıklıkla yüksek boyutlu uzaylarda çok sayıda vektörün işlenmesi ve sınıflandırılması problemlerini içerdiğini ve bu tür problemleri çözmek için klasik algoritmaların polinomsal zaman alacağına değinmiştir. Kuantum bilgisayarların, büyük tensör çarpım uzaylarında yüksek boyutlu vektörleri manipüle etmede iyi olduğunu belirterek küme ataması ve küme bulma için denetimli ve denetimsiz kuantum makine öğrenimi algoritmalarından bahsetmiştir. Kuantum makine öğreniminin, hem vektör sayısı hem de boyutları açısından logaritmik zaman alacağını; bunun, klasik algoritmalara göre üstel bir hızlanma sağlayacağını göstermiştir [14]. Kerenidis vd., yaptıkları çalışmada kuantum makine öğreniminin, tam ölçekli bir kuantum bilgisayarın en umut verici uygulama alanlarından olduğunu belirtmiştir. Klasik algoritmaların üzerinde potansiyel olarak önemli hızlanmalar sunabilen birçok kuantum makine öğrenme algoritmasından biri olan denetimsiz makine öğrenimi için q-ortalama algoritmasını tanıtmıştır. K ortalama algoritmasına benzer yakınsama ve kesinlik değerlerine sahip olduğunu ancak klasik k-ortalama algoritmasına göre çalışma süresinin, büyük veri kümeleri için önemli ölçüde daha düşük olduğunu ifade etmiştir [15]. Li vd. EEG sinyalinde hem özellik çıkarımı hem de sınıflandırmayı uygulamak için hiyerarşik kuantum mekaniği tabanlı bir çerçeve üzerinde çalışma gerçekleştirmiştir. Öncelikle, klasik EEG sinyal veri setini, veri noktasının işareti

korunurken kuantum durumuna dönüştürmüştür. Özellik çıkarımı için dalgacık paket enerji entropisi yöntemini uygulamıştır. Daha sonra sınıflandırma işlemi için ise yaygın olarak tercih edilen Kuantum Destek Vektör Makineleri (Quantum Support Vector Machine, QSVM) kullanmıştır. Yapılan çalışma neticesinde kuantum tabanlı sınıflandırma sonuçlarının klasik sınıflandırmaya oranla karmaşıklık açısından üstel bir hızlanma sağladığı belirtmiştir [16]. Biance vd., klasik makine öğrenme algoritmalarının verimliliğini artırmak için kuantum makine öğrenme algoritmaları üzerinde çalışmıştır. Bu amaç doğrultusunda, kuantum hesaplama yöntemlerini klasik sinir ağı teknikleriyle birleştirerek, sınıflandırma problemlerinin çözümünde performans artışı sağlamayı amaçlamıştır. Ağın parametrelerini optimize etmek için yeni bir hibrit varyasyonel kuantum sınıflandırıcı önermiştir. Bu yöntemin klasik bir sinir ağından daha iyi bir öğrenme sonucuna sahip olduğunu tespit etmiştir [17].

Yu, SARS-CoV-2 hastalıklarının analizi için Pennylane programında varyasyonel kuantum sınıflandırıcı kullanmıştır. Kullanılan yöntemin hastalığın erken teşhisinde faydalı olabileceği vurgulanmıştır [18]. Başka bir çalışmada, 3 farklı klinik veri seti (kalp yetmezliği, Wisconsin göğüs kanseri, pediatrik kemik iliği nakli) üzerinde kuantum uzaklık sınıflandırıcısı ve Kuantum-Çekirdek Destek Vektör Makinesi (qKSVM) yöntemleri kullanılmıştır. Bu çalışmada IBMQ Melbourne'de 16 kubitlik yapıda qKSVM yönteminin daha yüksek performans gösterdiği bulunmuştur [19]. Kumar vd., kuantum en yakın komşu, kuantum karar ağacı, kuantum Gaussian Naive Bayes ve Kuantum Rastgele Orman (Quantum Random Forest, QRF) algoritmalarını içeren çalışmalarında, kuantum tabanlı yöntemlerin geleneksel yöntemlere göre daha üstün performans gösterdiğini belirtmiştir. En yüksek performans ise QRF algoritmasında %89 doğruluk oranıyla sağlanmıştır [20]. Kadınlarda diyabet hastalığını araştıran bir çalışmada hem derin öğrenme hem de kuantum makine öğrenme algoritmaları uygulanmıştır. Önerilen kuantum makine öğrenme yaklaşımıyla %86 doğruluk oranı elde edilmiştir [21]. Shahwar vd., Alzheimer hastalığının tespitinde kullanılan hibrit bir klasik-kuantum makine öğrenimi modelini sunan bir çalışma yürütmüştür. Bu çalışmada verilerin karmaşıklığı ve boyutu hibrit klasik-kuantum transfer öğrenimi ile ele alınmıştır. Klasik sinir ağları tarafından çıkarılan özellikler, kuantum işlemcisiyle entegre edilmiştir. ResNet34 ile görüntülerden özellikler çıkarılmış ve Kuantum Değişken Devreler (Quantum Variational Circuits, QVC) ile özellik vektörleri oluşturulmuştur. Model, farklı kuantum simülatörleri ile doğrulama yapılarak %97.2 sınıflandırma doğruluğu elde etmiştir [22]. Cattan vd, araştırmasında, 26 katılımcının EEG verileri kullanılmış ve QSVM ve SVM algoritmaları bu veri setine uygulanmıştır. Çalışma kuantum bilgisayar ve QasmSimulator ortamlarıyla gerçekleştirilmiştir. Çalışmada simülasyon ortamındaki analizlerin kuantum bilgisayarlarda gerçekleştirilen analizlere göre daha uzun sürede tamamlandığı belirtilmiştir. QSVM ile elde edilen sonuçların SVM algoritmasının sonuçlarına göre daha düşük bir doğruluk oranına sahip olduğunu gösterilmiştir [23]. Kalp hastalıklarının teşhisi için yapılan bir çalışmada elektrokardiyografi (ECG)

veri setini kullanarak SVM ve QSVM algoritmalarının performanslarını karşılaştırmıştır. Öncelikle veri setini farklı boyutlara ayırarak PCA uygulamıştır. Araştırmacılar SVM algoritmasının QSVM algoritmasından daha iyi performans gösterdiğini ve geliştirmekte olan bir teknoloji için elde edilen sonuçların oldukça iyi olduğunu belirtmiştir [24].

Amyotrofik Lateral Skleroz (ALS) hastaları için beyin bilgisayar arayüzü geliştirmek amacıyla yapılan bir çalışmada, EEG verileri kaydedilmiş ve hastaların kelimeleri ayırt etme yeteneği incelenmiştir. Çalışmada, QSVM algoritması kullanılarak elde edilen sonuçların, bilinen diğer yöntemlere göre daha yüksek doğruluk sağladığı vurgulanmıştır [25]. Andreev ve Cattan, EEG verilerini sınıflandırmak için QSVM ile Lineer Diskriminant Analizi (LDA)'nın performansını karşılaştırmıştır. EEG analizi için verileri hazırlamada Riemann Geometrisini kullanmış ve kuantum sınıflandırıcıda elde ettikleri sonuçların LDA ile yapılan analizlere göre daha düşük doğruluğa sahip olduğunu belirtmiştir. İyi ayırt edilebilir verilerin sınıflandırılmasında klasik hesaplamanın kuantum hesaplama üstünlüğü olmadığını belirtmiştir [26]. Padma ve Sahoo, insan ruh sağlığı üzerinde stresin etkilerini incelemek amacıyla SWELL KW veri kümesine Q-KNN, QSVM ve Değişken Kuantum Sınıflandırıcısı (Variational Quantum Circuit, VQC) yöntemlerini uygulamıştır. 25 katılımcıdan elde edilen verilere Temel Bileşen Analizi (Principal Component Analysis, PCA) ve Kuantum Temel Bileşen Analizi (QPCA) uygulayarak boyut indirgeme işlemi gerçekleştirmiştir. Araştırmanın sonucunda, en yüksek doğruluk değerinin QSVM algoritmasından elde edildiğini belirtmiştir [27].

Farklı algoritmalar ve yöntemler kullanılarak yapılan bu çalışmalar kuantum makine öğrenmesinin sağlık sektöründe gelişimini ortaya koymaktadır. Bu alanda ki yenilikçi araştırmalar ve yapılacak olan geliştirmeler ile kuantum makine öğrenmesinin sağlık alanında teşhis ve tedavi yöntemlerine daha fazla katkı sağlayabileceği öngörülmektedir.

Bu tez çalışmasında EEG sinyallerinden oluşan üç farklı veri seti üzerinde QML algoritmalarının etkinliği araştırılmıştır. Bu tez çalışmasının temel motivasyonlarından ilki EEG sinyalleri ile belirlenebilen farklı nörolojik durumların tespitinde kuantum makine öğrenme algoritmalarının, klasik makine öğrenme algoritmalarına kıyasla daha başarılı sonuçlar vereceğidir. Bu anlamda hem kuantum hem de klasik makine öğrenmesi yöntemleri kullanılarak kıyaslama gerçekleştirilmiştir. Bunu yanı sıra özellik haritalarının kuantum makine öğrenme algoritmalarının performansı üzerindeki etkisi araştırılarak başarımın artırılması hedeflenmiştir. Son çalışmada ise kullanılan özellik haritalarının otomatik tespitinin sağlanması amacıyla parçacık sürü optimizasyon yöntemi kullanılmıştır.

1.1. Tezin Amacı, Katkısı

Kuantum teknolojileri, benzersiz hesaplama gücü ve hız avantajlarıyla dikkat çekmektedir. Bu teknolojiler, büyük veri setlerini ve karmaşık algoritmaları geleneksel yöntemlere göre çok daha

hızlı ve verimli bir şekilde işleme yeteneğine sahiptir [28]. Bu özellikleriyle, kuantum teknolojileri oldukça cazip hale gelmiştir. Ancak, kuantum bilgisayarların henüz gelişme aşamasında olması nedeniyle çeşitli sınırlılıkları da mevcuttur. Gerçek kuantum bilgisayarlara erişimde yaşanan zorluklar ve simülatör ortamlarının kısıtlı sayıda kübit kullanımına izin vermesi gibi durumlar, kuantum hesaplama alanındaki ilerlemelerin hızını etkileyebilmekte ve teknolojinin geniş çapta benimsenmesi sürecini geciktirebilmektedir.

Bu tez çalışmasının amacı, kuantum makine öğrenmesi yöntemlerini kullanarak EEG sinyallerinin sınıflandırılmasındaki başarıyı arttırmaktır. Kuantum tabanlı sistemlerde algoritmaların kullanılabilmesi için veri setinin boyutlarının boyut indirgeme yöntemlerinden PCA algoritması kullanılarak hazırlanması, oluşturulan modellerin farklı simülatör ortamlarında analizlerinin gerçekleştirilmesi ve EEG sinyallerinin sınıflandırılmasında, klasik makine öğrenme algoritmalarının ve kuantum makine öğrenme algoritmalarının performanslarının değerlendirilmesi tezin alt amaçları arasında yer almaktadır. Farklı kuantum özellik haritalarının kullanımının, VQC ve QSVM algoritmaları üzerindeki başarımının araştırılması hedeflenmektedir.

Bu tez çalışmasının katkıları:

- EEG veri setlerinde yer alan kanalların her biri deneysel çalışmalarda ayrı ayrı değerlendirilerek, probleme uygun kanal seçiminin sağlanması,
- EEG sinyallerinin farklı kullanım alanlarına yönelik kuantum sınıflandırma modellerinin oluşturulması,
- Kuantum tabanlı sistemlerle makine öğrenmesi yöntemlerinin birleştirilerek performansının değerlendirilmesi.

1.2. Tezin Organizasyonu

Tezin genel organizasyonu şu şekildedir: İkinci bölümde Elektroensefalografi, tarihsel gelişim süreci ve bu alandaki teknik bilgiler detaylı bir şekilde ele alınmıştır. Üçüncü bölümde makine öğrenme konseptleri ve çeşitli makine öğrenme modelleri incelenmiştir. Dördüncü bölümde kuantum mekaniği ve kuantum hesaplama ile ilgili temel kavramlar açıklanmıştır. Kuantum makine öğrenimi, QSVM ve VQC algoritmaları incelenmiştir. Beşinci bölümde yapılan deneysel çalışmalar ayrı başlıklar altında incelenmiş ve değerlendirilmiştir. Altıncı bölümde genel bir değerlendirme yapılarak çalışmaların sonuçları özetlenmiştir.

2. BİLGİSAYAR DESTEKLİ EEG ANALİZ SİSTEMLERİ

İnsan beyni, sinir sistemi içindeki temel işlevsel hücreler olan nöronlardan oluşmaktadır. Bu sinir hücreleri, beyin, omurilik ve sinirlerde yer almaktadır. Beyinde, birbirini etkileyebilen 100 milyardan fazla nöron bulunmaktadır. Nöronlar arasındaki etkileşimler, sinyal adı verilen iletilerle gerçekleşir ve bu sinyaller, sinir sistemi fonksiyonlarının temelini oluşturur. Nöronlar arasındaki bu iletişimle birlikte elektriksel aktiviteler meydana gelir ve bu aktiviteler insan EEG'sini oluşturur [29]. EEG, beyin korteksinde bulunan kortikal nöronların senkronize sinaptik aktivitelerinden kaynaklanmaktadır. İnvaziv olmayan bir tekniktir ve sinirsel aktivitede meydana gelen değişikliklerin milisaniyeler içinde tespit edilmesini sağlamaktadır. Elektroensefalografi alanındaki keşiflerin kökeni 18. yüzyıla kadar uzanmaktadır. Bu keşifler, beyin aktivitesinin elektriksel özelliklerini anlamamıza ve EEG'nin gelişimine yol açmıştır.

Elektroensefalografi alanındaki keşiflerin öncülerinden biri Galvani'dir; 1791'de yayınladığı çalışmada elektriksel uyarılar kullanılarak hayvanlarda kas hareketi sağlanabileceğini belirtmiştir [30]. Bu çalışma, nöronlar arası elektrik iletiminin keşfini gösteren önemli bir adımdır. Daha sonra, Caton'un 1875'te Britanya Tıp Birliği'ne sunduğu raporda, hayvan beyinlerinden elektriksel aktivitenin kaydedilebileceğini göstermiştir. Bu dönemde yapılan araştırmalar, EEG'nin erken evrelerine ışık tutmuş ve sinir sistemi üzerindeki elektriksel etkileşimlerin incelenmesine yol açmıştır. Hayvanlar üzerinde yaptığı araştırmalarda, uykunun ve göze ışık tutulması gibi duyuşal uyarıların beyin sinyallerinin değişimini tetiklediğini keşfetmiştir [31]. Beck, 1890'da yayınladığı çalışmada, elektrotları doğrudan beyin yüzeyine yerleştirerek duyuşal uyarılara karşı elde edilen beyin dalgalarını incelemiştir. Elektriksel beyin aktivitesinde kendiliğinden oluşan dalgalanmaların duyuşal uyarı sonrasında durduğunu vurgulamıştır [32].

Forbes ve Thatcher 1920 yılında sinir impulslarını güçlendirmek için elektronik kondansatör bağlı cihazlar kullanarak yeni bir elektronik çağ başlatmıştır. Forbes vd. başka bir araştırmalarında kombine elektro-kimyasal sinaptik iletim teorisini oluşturmuştur [33]. Hans Berger, 1924'te insan beyin dalgalarını kaydetmeyi başarmıştır ve ilk defa 'Elektroensefalogram' ifadesini kullanmıştır. Beyin sinyallerinin incelenmesi alanında yaptığı çalışmalarda α ve β dalgaları gibi dalga modellerinin karakterizasyonunu tanımlamıştır. EEG'nin zihinsel aktivite ve hasar durumlarında normal ve anormal durumlarını belirlemiştir [34]. Berger beyin yüzeyine elektrotları yerleştirerek İntrakraniyal elektroensefalografi tekniğini kullanmıştır. Grass, 1935 yılında 3 kanallı EEG cihazını ilk kez kurmuştur [35]. Adrian ve Matthews, beyin korteksindeki potansiyel dalgaların yorumlanması konusunda çalışmalar gerçekleştirmiştir [36]. Davis ve Jasper, 1934'te katot ışıklı osiloskoplar yardımıyla insan beyin aktivitesini kaydetmiştir. Böylece klinik uygulamalarda kullanılacak olan ekipmanların geliştirilmesinde öncü olmuştur. Grey Walter, tümörlerin EEG tarafından tespit edilebileceğine yönelik çalışmalar gerçekleştirmiştir. Tümör bulunan kişilerin

EEG kayıtlarında yavaş aktivite varlığına yönelik bilgiler sunulmuştur. Walter, Dovey ile gerçekleştirmiş olduğu çalışmalarda, tümörlerin tanımlanmasında EEG'deki teta dalgasının rolünü incelemiştir. Walter aynı zamanda epilepsi hastalığı üzerine yaptığı araştırmalar ile beyin sinyallerinin bu hastalıkla değişimini gözlemlemiştir [37]. Jasper ve Carmichael, 1935 yılında alfa dalgaları üzerine çalışmalar gerçekleştirmiştir. Beyin hasarı durumunun delta dalgaları ile ilişkili olduğunu ve elektroensefalogramların psikoloji ile klinik nöroloji alanlarında önemli olduğunu belirtmiştir. Aynı zamanda epilepsi üzerine yapılan cerrahi müdahale sırasında EEG sinyallerinden elde edilen beyin korteks haritasından faydalanmıştır. Rockefeller Vakfı tarafından 1939 yılında açılan ilk EEG laboratuvarında klinik elektroensefalografi çalışmaları yürütülmeye başlanmıştır. 1947'de kurulan Amerikan Elektroensefalografi Derneği, EEG'nin standardizasyonu ve klinik kullanımı üzerine çalışmalar başlatmıştır. 1961 yılında UNESCO'ya bağlı olarak kurulan Uluslararası Beyin Araştırma Örgütü (IBRO), beyin aktiviteleri üzerine yapılan araştırmaların kapsamını genişletmiştir. Ayrıca, 1958 yılında Jasper tarafından EEG elektrot yerleşiminde kullanılan standartlar tanımlanmıştır [38]. Jasper, aynı yıl EEG kayıtlarını standartlaştırmak amacıyla uluslararası 10-20 elektrot yerleştirme sistemini geliştirmiştir [39]. Lynch ve Paskewitz, alfa ritimlerinin öğrenilmiş kontrolünde, bu ritimlerin yoğunluğunu etkileyen faktörlerin yapısal, fizyolojik ve bilişsel-dikkat faktörleri olduğunu raporlamıştır. Bu bulgular, otonom sinir sistemi aktivitesinin öğrenilebilir kontrolünün mümkün olduğunu vurgulamaktadır [40]. Vogel, 1970 yılında EEG'nin genetik temellerini incelemiştir. Bu çalışma, alfa ve beta dalgalarının yaş ve cinsiyete göre farklılıklarını ortaya koymuştur [41]. Hjort, EEG'nin genel özelliklerini tanımlamak amacıyla zaman alanı ile frekans alanı arasında bir bağlantı kurmuştur. Bu sayede, zamana dayalı hesaplamalarla temel sinyal özelliklerinin çevrimiçi olarak ölçülmesine olanak sağlamıştır [42]. Petersen ve Olofsson, klinik teşhis çalışmalarında çocuklarda farklı hastalık durumlarıyla bağlantılı olarak EEG'nin değerlendirilmesinde referans değerleri olarak kullanılabilecek Bu bağlamda, yaşa ve cinsiyete göre EEG'nin gelişimini tanımlamıştır [43]. Lehmann, 1971 yılında protez kol cihazının kontrolünü sağlamak amacıyla EEG motor sinyal takibi gerçekleştirmiştir [44]. Sterman ve Friar, 1972 yılında yaptıkları araştırmada, günümüzde neurofeedback olarak bilinen ve kişilerin beyin sinyallerini ölçerek kendi beyin aktivitelerini düzenlemelerine olanak tanıyan sistemin temelini atmıştır [45]. Grossberg tarafından alfa dalgalarının kontrolü üzerine yapılan çalışmalar, beyin ve zihnin nasıl çalıştığını anlamak ve bu süreçlerin bilinçli olarak kontrol edilebileceğini göstermek açısından önemli bir temel oluşturmuştur [46]. 1980'li yıllarda EEG analizleri için bilgisayar sistemleri etkin bir şekilde kullanılmaya başlanmış ve manuel Fourier analizinin yerini Hızlı Fourier Dönüşümü (FFT) temelli spektral analiz yöntemi almıştır [47]. Teknolojik gelişmeler, analog EEG cihazlarının yerini dijital EEG cihazlarına bırakmasını sağlamıştır. Bu sayede daha fazla veri toplama kapasitesine sahip, verilerin depolanması, işlenmesi ve paylaşılması daha kolay olan cihazlar geliştirilmiştir. Gotman, 16 kanaldan alınan EEG verilerini kullanarak

epilepsi nöbetlerinin otomatik tanımlanmasını sağlayan bilgisayar tabanlı bir sistem geliştirmiştir [48]. Farwell ve Donchin, P300 bileşenlerini kullanarak bilgisayar aracılığıyla iletişim kurulabilen bir sistem geliştirip test etmişlerdir [49]. Klasik EEG cihazlarındaki kanal sayısının yetersiz kalmasıyla yüksek yoğunluklu EEG'ler geliştirilmiştir. Bu cihazlarda 64 ile 256 arasında değişen sayıda elektrot yer almıştır. Bu gelişme sayesinde beyin aktivitesinin daha ayrıntılı haritaları çıkarılabilmiş ve klinik çalışmalarda daha iyi sonuçlar elde edilmiştir [50].

Tüm bu gelişmelerin ışığında, EEG alanındaki araştırmalar 18. yüzyılda başlamış ve günümüze kadar devam etmiştir. Özellikle Beyin Bilgisayar Arayüzleri (BBA) üzerine yapılan çalışmalar, makine öğrenimi ve yapay zeka gibi gelişen teknolojilerle birleştirilerek önemli bir çeşitlilik kazanmıştır. Bu entegrasyon, gelecekte EEG'nin beyin aktivitesini anlama, analiz etme ve hatta belirli durumlarda kontrol etme yeteneğini daha da geliştirmeyi hedeflemektedir.


2.1. Elektroensefalografi ve Beyin Dalgaları

EEG sinyallerinin analizi sırasında, sinyallerin frekans bileşenleri incelenir. Bu frekans bileşenleri, beynin elektriksel aktivitesinin belirli ritmik haritalarını veya 'nöral salınımlarını' temsil eder. Nöral salınımlar, beynin farklı durumları ve işlevleri ile ilişkilendirilebilen belirli frekans bantlarında ortaya çıkar. EEG'nin spektral içeriği, bu frekans bileşenlerinin ve salınım türlerinin analiz edilmesi anlamına gelir. Karmaşık beyin yapısını daha anlaşılır hale getirmek için, sinyal frekansları farklı frekans aralıklarına ayrılır. Senkronize olan sinyaller, beyin durumlarını yansıtan farklı frekans bantları aracılığıyla gösterilir. Tablo 2.1'de beyin dalgalarının sinyal frekans aralıkları ve bu aralıkların açıklamaları sunulmuştur.

Tablo 2.1. Beyin dalgaları sinyal frekans aralıkları ve açıklamaları [51].

Bant Adı	Frekans Aralığı	Açıklama
Delta (δ)	0.2-4 Hz	Özellikle derin uyku evrelerinde görülen en yavaş beyin aktivitesidir. Uyanık olan yetişkinler için anormal bir durumun varlığına işaret eder.
Teta (θ)	4-8 Hz	Gevşeme ve meditasyon ile ilgili olan bilinçaltı aktiviteleri gösterir. Büyüme, serotonin ve öğrenmeyi arttıran kortikal hormonun salgılanmasını sağlar.
Alfa (α)	8-12 Hz	Genellikle gözlerin kapalı olduğu uyanık ama rahatlamış durumlarda tüm yaş gruplarında görülür. Başın arka bölümü ve ön bölgelerden kaydedilen düşük sinyal gücüne sahip, yavaş dalga aktivitesidir.
Beta (β)	13-30 Hz	Konuşma, problem çözme, yargılama ve karar verme gibi bilinçli durumlarda ortaya çıkan davranış ve eylemler ile ilgili olan dalgalardır.
Gamma (γ)	30-100 Hz	Duyular ve belleğin bir araya geldiği uyanıklık ve duyuşal girdilerin birleşimi sonucu oluşan dalgalardır.

EEG işaretleri, zaman ve frekans eksenlerinde incelenir ve genellikle beyin aktivitesiyle ilişkilidir. Bu nedenle zaman içinde genlik, faz ve frekans açısından değişiklik gösterebilmektedir. Beyin aktivitelerinin düzeyleri yükseldikçe EEG dalga frekansları artmakta ve genlikleri azalmaktadır. Egemen olan frekansların yaşa göre yükseldiği yeni doğanlarda frekansın 3-4 Hz iken, yetişkinlerde egemen frekansların 8-12 Hz arasında olduğu bilinmektedir. Şekil 2.1’de EEG bantlarının frekans spektrum grafiği verilmiştir.




Şekil 2.1. EEG bantlarının frekans spektrumu

2.2. EEG Sinyallerinin Ölçülmesi

Elektroensefalografi, kafa derisine yerleştirilen elektrotlar aracılığıyla beyindeki çeşitli dalgaları temsil eden sinyallerin ölçülmesi ve kaydedilmesini sağlayan bir tekniktir. Bu teknik, beyin aktivitelerinin haritalanmasını mümkün kılarak insan vücudunun davranışlarını kontrol etmeyi sağlayan süreçlerin anlaşılmasına katkıda bulunur. EEG cihazları, nöronlar arasında meydana gelen iyonik akımların yarattığı elektriksel akımı ölçmektedir.


Kafa derisine yerleştirilen elektrotlar, bir yükseltici aracılığıyla mikrovolt seviyesinde kayıt yapmaktadır. Kayıt süresi yapılan çalışmalara göre değişiklik gösterse de genellikle 20-40 dakika arasında sürmektedir. Kayıtların alınmasında Uluslararası 10-20 sistemi kullanılmaktadır. Bu yöntem, beyin dalgalarından elde edilen sinyallerin standart bir şekilde kaydedilmesini sağlayarak, gerçekleştirilen deneysel süreçlerin zaman içinde karşılaştırılabilir olmasını mümkün kılar. Şekil 2.2’de EEG sisteminin gösterimine yer verilmiştir.



Şekil 2.2. EEG Sistemi

10-20 sistemi, elektrotların konumları ile beyin korteksi bölgeleri arasındaki ilişkiyi göstermektedir. Burun ile alnın birleştiği çukur noktadan (nasion) kafatasının arka alt kısmındaki çıkıntılı noktaya (inion) bir çizgi çekilir. Elektrotların kafa derisine yerleştirilmesi için kullanılan belirli noktalar vardır. Bunlar, beyin bölgelerine göre adlandırılmıştır ve Frontal Kutup (Fp), Frontal (F), Central (C), Parietal (P) ve Occipital (O) şeklinde ifade edilmektedir [52].

Fp, burun ile alnın birleştiği çukur noktadan %10 mesafe yukarısında yer alır. O ise kafatasının arka alt kısmındaki çıkıntılı noktadan %10 yukarıda bulunur. Diğer üç nokta ise Fp ile O noktaları arasında, eşit mesafe aralıklarıyla tanımlanır ve bu mesafeler, başlangıçta belirlenen aralığın %20'si olacak şekilde düzenlenir. Bu sistemde, tek sayılar sol yarımküreyi, çift sayılar ise sağ yarımküreyi temsil etmek için kullanılmaktadır [52]. Şekil 2.3'de 10-20 sistemine göre yerleştirilmiş elektrotların konumları gösterilmiştir.



2.3. Beyin Bilgisayar Arayüzleri


Beyin Bilgisayar Arayüzleri, beyin aktivitesinden elde edilen kontrol sinyallerini kullanarak insanların bilgisayarlar veya harici cihazlarla doğrudan ve gerçek zamanlı iletişim kurmasını sağlayan bir teknolojidir. Bu sistemler genellikle EEG gibi beyin aktivitesi ölçümleri kullanmaktadır. BBA, özellikle fiziksel engelli bireyler için büyük bir potansiyele sahiptir, çünkü kas hareketlerine ihtiyaç duymadan zihinsel işlevleri kontrol etmelerine olanak tanır. Ayrıca, bu sistemler zamanla sağlıklı bireylerin çeşitli yeteneklerini geliştirmek amacıyla da kullanılmıştır.

BBA'nın uygulandığı temel yöntemlerden biri, rehabilitasyon gerektirmeyen harici cihazları kontrol etmek için beyin aktivitesinin incelenmesidir. Diğer bir yöntem ise nörorehabilitasyon sürecinde kullanılan BBA sistemleridir; bu sistemlerde geri bildirim döngüsü, nöral plastisiteyi yeniden kazanmak veya beyin aktivitelerini düzenlemek için önemli bir rol oynamaktadır [53].

Tıbbi alanlarda yapılan arařtırmalar, BBA'nın hem teřhis ve tedavi sũreçlerine odaklandığını hem de hastalık veya kaza sonucu merkezi sinir sisteminde oluřan hasarlar nedeniyle meydana gelen işlevsel kayıpların giderilmesini amaçladığını göstermektedir. Amyotrofik Lateral Skleroz (ALS), beyin sapı felci, serebral palsi ve omurilik yaralanması gibi durumlarda BBA'lar önemli bir rol oynamaktadır. Bu hastalıklara sahip bireyler için iletişim ve kontrol seçenekleri sunarak yaşam kalitesini artırabilmektedir. Bu doğrultuda, arařtırmacılar beyin aktivitesini kullanarak robotik sistemlerin düşünme ve hayal etme yoluyla kontrol edilmesine olanak tanıyan çalışmalar

yapmaktadır. Ayrıca, beyindeki vücut kontrol mekanizmasının hasar almasından kaynaklanan sorunları olan hastalar için düşünce mekanizması ile kontrol edilebilen el protezleri üzerinde de çalışmalar yürütülmüştür [44]. Benzer şekilde, robotik bir kolun zihinsel komutlarla hareket ettirilmesini sağlayan yenilikçi sistemler de geliştirilmiştir [54]. Yürüme engeli olan bireyler için, düşünce gücüyle kontrol edilebilen ve otomatik navigasyona dayalı tekerlekli sandalye sistemleri tasarlanmıştır [55]. Felç geçiren hastaların, bilgisayarlar aracılığıyla insanlarla iletişim kurmalarını sağlamak amacıyla, düşünceleriyle hareket ettirebildikleri iki boyutlu imleç hareketine dayalı yöntemler oluşturulmuştur [56, 57].

BBA'lar klinik uygulamalarda tanı sürecinde de etkin bir şekilde kullanılmaktadır. Örneğin, göğüs kanseri ve EEG sinyalleri üzerine yapılan bir çalışmada, kanser teşhisinin erken aşamaları için otomatik bir sistem önerilmiştir [58]. Parkinson hastalığının ileri aşamalarında, beyindeki anormal aktiviteyi değerlendirmek ve terapötik tedavi amacıyla düşük voltajlı elektriksel uyarıların ne zaman verilmesi gerektiğini belirlemek için bir BBA yöntemi tasarlanmıştır [59]. Şizofreni hastalığında görülen halüsinasyonların tedavisinde sanal/artırılmış gerçeklik ve BBA'ların kullanımının etkisi incelenmiştir. Bu yöntemler, geleneksel tedavilere alternatif olarak sunulmaktadır [60]. BBA'nın bir diğer uygulama alanı rehabilitasyon süreçleridir. Bu süreçlerde, hastalardan belirli görevleri yerine getirmeleri istenmektedir. Bu sırada alınan EEG kayıtları, hastalara geri bildirim olarak sunulmakta ve böylece duyu-motor döngüsünün düzenlenmesine yardımcı olmaktadır [61]. BBA sisteminin genel yapısı Şekil 2.4'te gösterilmiştir.



Şekil 2.4. BBA sisteminin temel yapısı

Son yıllarda önemli bir araştırma alanı haline gelen Neurofeedback, beyin bilgisayar arayüzü uygulaması olarak kabul edilmektedir. Neurofeedback eğitimlerinde, bireylerin beyin dalgaları ölçülerek geri bildirim olarak sunulur ve hastalar kendi beyin dalgalarını kontrol etmeyi öğrenirler. Bu yöntem, otistik spektrum bozukluğu yaşayan bireylerde gözlemlenen anormal EEG nöbet aktiviteleri ve yüksek delta/teta aktivitesini hedef alarak, odaklanmayı artırmayı, nöropsikolojik işlevselliği iyileştirmeyi ve sosyal iletişimde gelişme sağlamayı amaçlamaktadır [62]. Dikkat eksikliği ve hiperaktivite bozukluğu olan bireylerde 3 ay boyunca gerçekleştirilen eğitimler sonucunda nörolojik geri bildirimin olumlu olduğu raporlanmıştır [63]. Dikkat eksikliği ve hiperaktivite bozukluğu olan bireylerde, 3 ay boyunca uygulanan eğitimler sonucunda nörolojik geri bildirimin olumlu olduğu raporlanmıştır [64]. Aynı zamanda yapılan araştırmalar uzun süreli uyuşturucu kullanımının EEG sinyallerinde bozulmaya sebep olduğunu ve 12 saatlik bir eğitim süreciyle bu bağımlılığın azaltılabileceğini göstermiştir [65].

Duygu analizi, EEG gibi tekniklerle incelenen önemli bir araştırma alanıdır. Bu analiz, duyguların beyindeki fizyolojik temsillerini anlamayı sağlayarak, insan davranışları ve zihinsel sağlık üzerinde derinlemesine bir anlayış sunabilmektedir. Örneğin, insan kişiliği ile EEG analizi arasındaki ilişkiyi inceleyen araştırmacılar, gerçek hayattaki duygusal deneyimleri karakterize ederek kişiliğin belirlenebileceğini belirtmiştir. [66]. Başka bir incelemede, doğanın insan psikolojisi üzerindeki etkisini araştırmak amacıyla taşınabilir EEG cihazı takan katılımcılar, farklı üç bölgede yürütülmüştür. Bu süreçte, katılımcıların düşük hayal kırıklığı ve yüksek meditasyon gibi duygular hissettikleri sonucuna ulaşılmıştır [67]. İnsanlara çeşitli akustik müzikler dinletilerek yapılan bir araştırmada, müzik dinlemenin insanlarda yarattığı duygular analiz edilmiştir [68].

BBA'nın tıbbi alanlar dışında farklı uygulama alanları da göze çarpmaktadır. Oyunlar ve sanal simülasyon ortamlarında, kullanıcının çeşitli fiziksel aktiviteleri gerçekleştirdiğini hayal etmesi istenerek çalışmalar yapılmıştır. Bu amaçla, el ve ayak hareketlerini temsil eden alanlara elektrotlar yerleştirilmiş ve katılımcılardan sadece ayaklarını hareket ettirdiklerini hayal etmeleri istenmiştir. Bu sayede, sanal bir ortamda kas hareketi olmadan hareket etmeleri sağlanmıştır [69]. Farklı bir çalışmada BBA kullanılarak bir beyin bilgisayar arayüzü ve sanal gerçeklik teknoloji birleştirilmiştir. Sadece motor görüntüleri kullanılarak sanal bir şehirde yürümenin fizibilitesi incelenmiştir [70]. Geleneksel endüstriyel nesnelerin interneti sürecine EEG'nin entegre edilmesi, insan ve makine varlıklarının etkileşime girmesini sağlamaktadır. Endüstriyel robotların beyin sinyalleri ile kontrol edilmesi, insan sezgisinin teknolojiye uygulanmasına olanak tanımaktadır [71].

BBA, kullanıcıların fiziksel olarak etkileşime girmeden çevrelerini kontrol etmelerine olanak tanıyarak daha bağımsız bir yaşam sürmelerine katkıda bulunmaktadır. Engelli bireyler için önemli bir iletişim ve kontrol aracı olarak yaşam kalitesini artırıcı bir etki yaratmaktadır. Ayrıca, beyin aktivitesinin daha iyi anlaşılmasını sağlayarak nörolojik hastalıkların teşhis ve tedavisinde


potansiyel bir araç olarak kullanılmaktadır. Bunun yanı sıra, BBA sistemleri beyin aktivitesini kullanarak karmaşık görevleri gerçekleştirebilen robotlar gibi otonom sistemlerin geliştirilmesine de imkan sağlamaktadır.

Beyin aktiviteleri ile insan vücudu arasındaki ilişkilerin biyomedikal sistemlere uyarlanması oldukça karmaşık bir süreçtir. Bu karmaşıklık, oluşturulan sistemlerin beklenen performansı sergileyememesine sebebiyet verebilmektedir. Oluşturulan bu sistemlerin kullanımları genellikle kullanıcı eğitimi gerektirdiği için zaman alıcı ve maliyetlidir. Hazırlanan modellerde kullanılan EEG sinyallerinde bireysel farklılıklar oluşmaktadır. Aynı zamanda yeni gelişen teknolojilere uyarlanabilir olması da önem arz etmektedir.

BBA'nın temeli, beyin aktivitesinin kontrol sinyallerine dönüştürülmesine dayanmaktadır. Bu nedenle, beyin bilgisayar arayüzlerinin etkinliği ve güvenilirliği açısından, beyin kontrol sinyallerinin doğru bir şekilde anlaşılması ve yorumlanması kritik öneme sahiptir.

2.3.1. EEG Tabanlı BBA Kontrol Sinyalleri

BBA çalışmalarında yaygın olarak kullanılan EEG sinyalleri doğrudan beyinden gelen sinyal amplifikasyonuna dayanmaktadır. Bu sinyallerin daha belirgin bir şekilde görülmesine ve analiz edilmesine olanak sağlamaktadır. Kontrol sinyalleri üç grup altında toplanmaktadır: görsel uyarılmış potansiyeller, hibrit sinyaller ve kendiliğinden oluşan sinyaller. Şekil 2.5'te, BBA'larda kullanılan kontrol sinyallerinin şematik gösterimi yer almaktadır.



Şekil 2.5. BBA kontrol sinyalleri [72].

Görsel Uyarılmış Potansiyeller

Görsel uyarılmış potansiyeller (Visual Evoked Potentials-VEP), gözlerin bir ışık veya desen gibi görsel bir uyarıcıya maruz kalması sonucu beyinde oluşan görsel bilgi işleme mekanizmalarını ifade etmektedir. Bu aktiviteler genellikle EEG kullanılarak ölçülmektedir. Işık, desen, renk olarak

verilen bu uyarılar gözler tarafından algılanarak, beyindeki görsel korteks tarafından işlenmektedir. Merkezi görsel alanın uyarılması, dışsal alanların uyarılmasından daha büyük VEP'lere sebep olmaktadır. Görsel uyarılmış potansiyeller tabanlı BBA'lar, deneğin görsel olarak odaklandığı hedef nesnenin EEG analizi yoluyla tanımlanmasını sağlamaktadır. Her hedef, beyinde özel bir yanıt oluşturur ve bu yanıt, hedefin algılanmasını sağlayan özel bir görsel uyarı dizisiyle ilişkilendirilir. Bu süreç, beyin tarafından üretilen elektriksel aktivitelerde farklılıklara yol açar [73].

- **P300 uyarılmış potansiyeller**, Olayla İlgili Potansiyellerin (Event Related Potentials-ERP) bir bileşenidir. ERP belirli bir olay veya uyarana yanıt olarak beyinde üretilen elektriksel aktivitelerdir. P300, beklenmedik veya önemli bir uyarının başlangıcından yaklaşık 300 ms sonra pik noktasına ulaşmaktadır. P300 bileşenleri; dikkat, uyarı işleme hızı, hata farkındalığı ve hafıza performansı ile ilişkili bilgi işlemeyi yansıtmaktadır. Yapılan çeşitli araştırmalar daha kısa P300 gecikmesi ve daha büyük P300 genliğinin, belirtilen bilişsel işlevlerde daha iyi performansla bağlantılı olduğunu ortaya koymaktadır [74].
- **Kararlı durum uyarılmış potansiyeller** (Steady-State Evoked Potentials-SSEP), düzenli olarak değişen uyarılara yanıt olarak ortaya çıkan ve beyin aktivitesinin frekans uzayında kolay analiz edilebilmesini sağlayan periyodik kafa derisi potansiyelleridir. Bu potansiyeller, genellikle hızlı bir şekilde sunulan ve beyinden neredeyse sinüzoidal bir yanıt elde edilen uyarı dizilerine yanıt olarak ortaya çıkmaktadır. Ancak, her bir yanıt dizisi tek bir uyarana verilen yanıtı temsil ettiği için bu yanıtların yorumlanması bazen zor olabilir. Kısa kayıt süreleri, frekans alanında istatistiksel değerlendirmenin kolay olması nedeniyle elektrofizyolojik incelemelerde sıklıkla kullanılmaktadır. SSEP'lerin analizi, hem zaman alanında tepe yüksekliğinin ölçülmesi hem de frekans alanı spektrumunun değerlendirilmesi yoluyla gerçekleştirilir [75].

Kendiliğinde Oluşan Sinyaller

Herhangi bir dış uyarı etkisi olmadan kendiliğinden meydana gelen sinyaller olarak tanımlanmaktadır. Motor ve duyu-motor ritimleri, yavaş kortikal potansiyeller ve motor olmayan bilişsel görevler bu sinyal grubunda yer almaktadır.

Motor, duyu-motor sinyallerin kontrolü çeşitli bilişsel süreçlerin uyumlu bir şekilde organize edilmesini gerektirmektedir. Beyin, her an çeşitli duyuusal bilgi kaynaklarını birleştirir, yaklaşan hareketleri seçer ve planlar, motor komutların sonuçlarını içsel olarak tahmin eder ve vücut ile çevredeki değişikliklere uyum sağlar. Duyu-motor kontrolünde, motor becerilerin zamanla kazanılabilir, uyarlanabilir ve iyileştirilebilir olması önemli bir özelliktir. Bu karmaşık ve birbiriyle

bağlantılı süreçler, duyu-motor kontrolünün altında yatan nöral mekanizmaların daha derinlemesine anlaşılmasını zorlaştırmaktadır [76].

Yavaş kortikal potansiyeller (Slow Cortical Potentials-SCP), kortikal elektriksel aktivitelerdeki milisaniyelik kaymaları ifade eder. Bu sinyaller, dışarıdan tetiklenebileceği gibi kendiliğinden de oluşabilir ve bilgi işleme üzerinde düzenleyici bir rol oynar. Pozitif SCP'ler, zayıflamış irkilme refleksi gibi nöral yapılardaki kortikal uyarılmanın azaldığını gösterirken, negatif SCP'ler uyarılabilirliğin artması ya da beyin aktivitesinin yoğunlaştığı durumlarla ilişkilidir. SCP'ler, motor veya bilişsel görevlerin planlanması ve hazırlanması sırasında gözlemlenebilir [77].

Motor dışı bilişsel görevlerde, kişiden genellikle fiziksel bir eylem gerçekleştirmesi değil, sadece bilişsel işlevlerini kullanması istenir. Bu görevler genellikle düşünme, dikkat veya hafıza gibi bilişsel süreçleri içermektedir. Bu tür görevler sırasında, kişinin beyin sinyalleri, belirli bir bilişsel sürecin gerçekleştirildiği anlarda ortaya çıkan beyin aktivitesini yansıtır.

Hibrit Sinyaller

Hibrit sinyaller, beyin tarafından üretilen farklı sinyal türlerinin bir kombinasyonunun kontrol amacıyla kullanılmasını ifade eder. Bu sistemde, beyinden elde edilen girdi sinyali tek bir türden değil, birden fazla türden oluşmaktadır. Bu yaklaşım, daha güvenilir bir kontrol sistemine olanak tanır ve her bir sinyal türünün dezavantajlarından kaçınılmasını sağlamaktadır [72].

BBA sistemleri genellikle dört ana aşamadan oluşur. İlk aşama, beyin sinyallerinin elde edilmesidir. İkinci aşama, kaydedilen sinyallerin işlenmesidir; bu aşamada, sinyaller gürültüden arındırılır ve önemli özellikler çıkarılır. Üçüncü aşama, elde edilen bu özelliklerin bir modele verilerek sınıflandırılmasıdır. Sınıflandırma aşamasından sonra, uygulamaya geri bildirim gönderilir ve cihazların kontrolü sağlanır.

2.3.2. BBA Sistemlerinde Ön İşleme

BBA'larda kullanılan kontrol sinyallerinin doğasını anlamak oldukça önemlidir. Bu sistemlerde, kayıt esnasında çevresel faktörler, kullanılan elektrot veya yükselticiler, elektrotların yerleşim düzeni, kas ve göz hareketleri gibi unsurlar gürültü oluşumuna neden olabilir. Bu gürültüler, sinyalin doğru bir şekilde analiz edilmesini zorlaştırır. EEG sinyalleri, gürültü ve bozulmalara karşı oldukça hassas olduğundan, bu sinyalleri işlerken dikkatli olunması gerekmektedir. Gürültüyü azaltmak ve sinyal kalitesini artırmak için çeşitli filtreleme ve sinyal işleme teknikleri kullanılmaktadır.

Bağımsız Bileşen Analizi

Bağımsız Bileşen Analizi (Independent Component Analysis-ICA), özellikle biyomedikal alanda kullanılan kör kaynak ayırma yöntemlerinden biridir. Biyomedikal sinyaller genellikle birden fazla

kaynaktan gelen sinyallerin bir kombinasyonunu içerir. ICA, bu karmaşık sinyal kombinasyonundan olabildiğince bağımsız olan orijinal EEG kaynak sinyallerini elde etme prensibine dayanır [78]. ICA, çok kanallı EEG verilerini mekânsal olarak sabit ve zamansal olarak bağımsız bileşenlere ayırmayı sağlamaktadır.

Yumuşatma Filtreleri

Yumuşatma filtreleri, analiz edilen sinyallerdeki gürültüyü azaltmak veya sinyalin belirli özelliklerini vurgulamak için kullanılır. Yumuşatma işlemi, sinyalin veri noktalarını değiştirerek gürültüyü azaltır ve aynı zamanda komşu noktalardan daha düşük olan noktaları artırarak daha düzgün bir sinyal elde edilmesini sağlar. Sıklıkla kullanılan çeşitleri şu şekildedir;

- **Savitzky-Golay filtresi**, bir en küçük kareler yumuşatma filtresidir. Bu yöntemde, her bir veri noktası, polinom uyumundan elde edilen yeni bir değer ile değiştirilir. Elde edilen bu yeni değer, temel doğrusal en küçük kareler uyumu kullanılarak belirlenir. Böylece, veri setindeki her bir değer daha doğru ve daha düzgün bir şekilde temsil edilir.
- **Medyan filtresi**, işlenen verilerin artan sıraya göre dizildiği ve bu diziden medyanın hesaplandığı doğrusal olmayan bir filtredir. Medyan filtresi, sinyalin düzgünleştirilmesi veya gürültünün azaltılması amacıyla kullanıldığında, ortalamadan çok farklı olan aşırı değerlerin etkisini azaltır. Bu sayede, daha istikrarlı ve güvenilir bir çıktı elde edilir [79].

Ortak Ortalama Referansı

Ortak ortalama referanslama yönteminde, her elektrot bölgesindeki kayıtların ortalaması alınarak bu ortalamalar referans olarak kullanılır. Temel amaç, belirli bir bölgedeki EEG sinyalinin gerçek beyin aktivitesini yansıtmamasını sağlamak için elektrotlardan gelen gürültüyü azaltmaktır. Bu yöntemle, sadece tüm elektrotlarda ortak olan sinyal ve gürültü korunurken, herhangi bir elektrotta izole edilen sinyaller görünmez hale gelir. Bu sayede, mikro elektrot dizilerinin konumundaki ilişkili gürültü doğru bir şekilde temsil edilir ve ilişkisiz gürültü kaynaklarının katkısı en aza indirilir [80].

Uyarlanabilir Filtreler

Uyarlanabilir filtreler, sinyalin belirli özelliklerini vurgulamak veya gürültüyü azaltmak amacıyla ayarlanabilen sistemlerdir. Sabit bir sistemin performansının yeterli olmayacağı, değişen şartlar altında kullanılmak üzere tasarlanmışlardır ve genellikle gerçek zamanlı uygulamalarda tercih edilirler. Bu filtreler, ortamdan gelen bilgilere veya işlenen sinyaldeki değişimlere göre kendilerini ayarlayabilir. Ortamdan gelen bilgi, gerçek zamanlı olarak algılanabilir veya giriş sinyalinin istatistiksel özelliklerine ilişkin önceden sağlanmış bir bilgi şeklinde olabilir [81].

Ampirik Mod Ayırması

Ampirik mod ayırma, temel fonksiyonların sinyalden türetilmesinin sağlandığı adaptif bir yaklaşımdır. Sinyaldeki daha yüksek frekanslı ölçeklerden daha düşük frekanslı ölçeklere kadar değişen enerjiyi sıralı olarak çıkaran bir temele dayanır. Ampirik mod ayırma işlemi sonucunda elde edilen zaman serisi bileşenleri, sinyalin farklı zaman ölçeklerindeki değişen bileşenlerini temsil eder ve sinyalin yapısının daha iyi anlaşılmasına katkı sağlar. Bu yöntem, sinyallerin değişken doğasına uyum sağlayabildiği için oluşan gürültünün giderilmesine de olanak tanır [82].

Kanonik Korelasyon Analizi

Kanonik korelasyon analizi, iki farklı çok boyutlu değişken arasındaki doğrusal ilişkiyi ölçmek için kullanılan bir istatistiksel tekniktir. Kör kaynak ayırması tekniklerinden biri olan bu yöntem, iki değişken arasındaki en yüksek korelasyonu bulur ve bu korelasyona karşılık gelen temel vektörleri tespit eder. EEG sinyalleri ile kas hareketleri arasında belirgin bir ilişki olduğu mantığına dayanan bu yöntem, EEG sinyallerinde kas hareketlerinden kaynaklanan artefaktların düzeltilmesini sağlayabilir [83].

Kuantum Yapay Sinir Ağı Tabanlı Filtre

Tekrarlayan sinir ağları ve kuantum kavramlarının birleştirilmesiyle oluşturulan hibrit bir yöntem olan tekrarlayan kuantum yapay sinir ağı (Recurrent Quantum Neural Network-RQNN), EEG sinyallerindeki gürültülerin giderilmesi ve sinyal kalitesinin artırılması için kullanılır. Bu yöntemin temeli Schrödinger dalga denkleminde dayanmaktadır. RQNN filtresi, nöbet tahmini gibi tıbbi uygulamalar için uygun olmamakla birlikte, BBA oyun uygulamalarında kullanılan EEG sinyallerinin ön işlenmesi için uygundur [84].

EEG sinyallerindeki gürültülerden arındırılması aşaması olan ön işleme aşaması sinyallerin kalitesini artırarak analiz için hazır hale gelmesini sağlamaktadır. Ancak EEG sinyallerinden anlamlı bilgiler elde edilebilmesi için bu aşama tek başına yeterli değildir. Bu aşamadan sonra, sinyallere özellik çıkarımı yöntemleri uygulanmaktadır.


2.3.3. BBA Sistemlerinde Özellik Çıkarımı

EEG sinyallerinin belirli özelliklerinin tanımlanması ve bu özelliklerden daha anlamlı modellerin oluşturulmasına yönelik işlemler, özellik çıkarımı olarak adlandırılır. BBA sistemlerinin etkinliğini artıran bu adım, sinyal işleme sürecinde önemli bir rol oynar. Özellik çıkarımı, EEG sinyallerindeki karmaşık bilgilerin basitleştirilmesini ve sınıflandırma algoritmaları tarafından daha iyi analiz edilmesini sağlar. EEG tabanlı özellik çıkarımı genellikle zaman alanı, frekans alanı ve zaman-frekans alanı özelliklerine odaklanır.

Zaman Alanı Özellik Çıkarımı

EEG sinyalleri durağan olmayan sinyaller olma dezavantajına sahip olmasına rağmen, zaman alanı özelliklerinin incelenmesi ve çıkarılması nispeten kolaydır. Zaman alanındaki özelliklerin elde edilebilmesi için sinyalin genlik değerlerine, dalga şekillerine ve zamanla değişimine odaklanılır. Zaman alanında özellik çıkarımı için olayla ilgili potansiyeller, Bağımsız Bileşen Analizi (ICA), Temel Bileşen Analizi (PCA), Hjorth özellikleri, Higuchi fraktalı, yüksek dereceli geçişler ve çeşitli istatistiksel teknikler kullanılmaktadır [85].

- **Olayla ilgili potansiyeller**, beynin belirli bir uyarana veya uyaranlara verdiği tepkidir. Sinyallerde küçük voltaj tepkileri olarak ortaya çıkmaktadır. Bu sinyaller, belirli uyaranlar sonucu üretilen çoklu EEG sinyallerinin tamamından tek bir bileşen elde edilerek analiz edilir. Özellik çıkarımında, ERP'nin genliği, tepki süresi ve ortalaması gibi sonuçlar elde edilir, böylece uyaranlara karşı verilen tepkinin etkisi ve hızı belirlenir. ERP'lerde farklı zaman dilimlerinde farklı bileşenler (P100, N100, P200, N200, P300) gözlemlenmektedir. Bu bileşenlerin her biri, farklı bilişsel süreçleri ve duyuşal işlemleri ifade eder [86].
- **Temel Bileşen Analizi** (Principal Component Analysis, PCA), veri boyutunu azaltırken çoklu değişkenler arasındaki ilişkileri tanımlamak için kullanılan bir tekniktir. Bu yöntem, veri seti içindeki istatistiksel bilgiyi koruyarak analizdeki yorumlanabilirliği artırmayı ve bilgi kaybını minimuma indirmeyi hedefler. PCA'nın temel amacı, veri setindeki varyansı maksimum düzeyde tutan yeni ve ilişkisiz değişkenler oluşturmaktır. Bu yeni değişkenler, bir özdeğer/özvektör probleminin çözülmesiyle elde edilir ve 'temel bileşenler' olarak adlandırılır. PCA, temel bileşenlerin oluşturulmasında veri setinin yapısal özelliklerine dayandığı için dağılım varsayımlarına ihtiyaç duymaz ve veri setinin özelliklerine uyum sağlayabilir [87]. Şekil 2.6'da temel bileşen analizinde izlenen aşamalar gösterilmektedir.



Şekil 2.6. PCA yönteminin temel aşamaları

n boyutlu bir veri kümesinden ($x^1, x^2, x^3, \dots, x^m$) k boyutunda bir veri seti ($k \ll n$) elde edilmek istendiğinde PCA’da gerçekleştirilmesi gereken aşamalar şu şekilde sıralanabilir; PCA yönteminin ilk aşamasında veriler standardizasyon işlemine tabi tutularak her değişkenin veri seti içinde katkısının eşit düzeyde olması sağlanmaktadır. Standartlaştırma işleminde kullanılan Denklem 2.1’de verilmiştir.

$$x_j^i = \frac{x_j^i - \bar{x}_j}{\sigma_j} \quad \forall j \quad (2.1)$$

Standartlaştırılmış veri setinden, değişkenler arasındaki ilişkiyi gösteren kovaryans vektörü hesaplanmaktadır. Kovaryans vektörünün elde edilmesinde kullanılan Denklem 2.2’de verilmiştir.

$$\Sigma = \frac{1}{m} \sum_i^m (x_i)(x_i)^T, \quad \Sigma \in R^{n \times n} \quad (2.2)$$

Kovaryans matrisindeki özvektör ve özdeğerlerin hesaplanmasıyla temel bileşenler elde edilmektedir. Elde edilen temel bileşenler verinin yönünü temsil etmektedir. Bu bileşenler verilerin daha kolay değerlendirilebilmesinin için yeni eksenler oluşturmaktadır. Denklem 2.3’te yer alan genel formüller kullanılarak özdeğer ve özvektörler belirlenmektedir.

$$u^T \Sigma u = \lambda \mu \quad (2.3)$$

$$U = \begin{bmatrix} | & | & \dots & | \\ u_1 & u_2 & \dots & u_n \\ | & | & \dots & | \end{bmatrix}, \quad u_i \in R^n$$

PCA’nın son adımı, orijinal veri setini yeni bir boyuta yansıtmaktır. Bu seçilen temel bileşenlerle yapılmaktadır. Kovaryans matrisinin en büyük k özvektörü seçildikten sonra, bu özvektörler kullanılarak orijinal veri seti yeni boyuta yansıtılır. Bu işlem, seçilen özvektörlerin veri setinin her bir örneğini yeni boyuta nasıl yansıtacağını belirler. Denklem 2.4, bu yeni temsili nasıl hesaplanacağını göstermektedir [88].

$$x_i^{yeni} = \begin{bmatrix} u_1^T x^i \\ u_2^T x^i \\ \dots \\ u_k^T x^i \end{bmatrix} \in R^k \quad (2.4)$$

Bu adımlar takip edilerek, n boyutlu veri setinin boyutu k boyuta indirgenmektedir. Böylece veriyi daha anlamlı bir şekilde temsil eden yeni bir veri seti oluşturulmuştur. Sonuçta veri analizi ve modelleme süreçlerinde daha başarılı çıktılar elde edilebilir.

- **Higuchi fraktalı**, zaman serilerinin fraktal boyutunu değerlendirmek için kullanılan bir yöntemdir. Bu yöntemin, zaman serisinin belirli bir zaman aralığı boyunca fraktal özelliklerini hesaplamak için kullanılan matematiksel bir çerçevesi vardır. Higuchi fraktalı, zaman serisinin zamansal ölçeğe özgü özelliklerini hesaba katmadan bu fraktal boyutu

hesaplar. Ayrıca, fraktal boyut, zamansal ölçeğin artan maksimum değeriyle ilişkili bir yapıyı ortaya koymaktadır [89].

- **Hjorth parametresi**, sinyalin zaman alanındaki istatistiksel özelliklerinin çıkarılmasını sağlayan etkinlik, hareketlilik ve karmaşıklık olmak üzere üç parametresi olan niceliksel terimlerdir. Bu parametreler zaman bağlı olmasının yanı sıra güç spektrumu özellikleri kullanılarak da elde edilmektedir. Etkinlik parametresi, zaman bölgesinde sinyalin varyans değerini belirler ve sinyalin toplam enerjisini ölçer. Etkinlik parametresinin matematiksel olarak belirlenmesinde $x(t)$ sinyali için kullanılan formül Denklem 2.5'te yer almaktadır.

$$E = \text{Varyans}(x(t)) \quad (2.5)$$

Hareketlilik, sinyalin değişim hızını ölçmektedir. Denklem 2.6'da frekans bölgesindeki sinyalin enerjisi temsil eden bu parametrenin formülü bulunmaktadır.

$$H = \sqrt{\frac{\text{Varyans}\left(\frac{dx(t)}{dt}\right)}{E}} \quad (2.6)$$

Karmaşıklık parametresi, sinyalin dalgalanma modelinin karmaşıklık derecesini ifade etmektedir. Bu parametrenin 1 değerine yaklaşması sinyalin saf sinüs dalgasına benzediğini göstermektedir. Hareketlilik parametresinin hesaplanması sonucu elde edilmektedir. Bu parametrenin matematiksel formülü Denklem 2.7'de yer almaktadır.

$$K = \sqrt{\frac{H\left(\frac{dx(t)}{dt}\right)}{H(x(t))}} \quad (2.7)$$

Hjorth parametreleri düşük hesaplama maliyetine sahip olması sebebi ile özellik çıkarımı için sıklıkla tercih edilmektedir. Ancak sinyal parametrelerinin hesaplanmasında bazı istatistiksel yanılgılara yol açabilmektedir. Bu parametrelerde frekans alanında güç spektrumu hesaplanmasına rağmen frekans alanıyla ilgili ayrıntılı bilgi sağlamamaktadır.

- **İstatistiksel özellik çıkarımı**, zaman alanında çeşitli istatistiksel teknikler kullanılarak gerçekleştirilir. Kullanılan tekniklerin formülasyonu Tablo 2.2'de yer almaktadır [72].

Tablo 2.2. Özellik çıkarımı aşamasında kullanılan istatistiksel yöntemler

İstatistiksel Yöntemler	Formüller
Minimum değer	$\min = \min(X[n])$
Maksimum değer	$\max = \max(X[n])$
Sinyal aralığı	$SA = \max(x[n]) - \min(x[n])$

İstatistiksel Yöntemler	Formüller
Dalga biçimi uzunluğu	$DBU = \sum_{n=1}^N X[n] - X[n-1] $
Ortalama genlik değişim değeri	$OGDG = \frac{1}{N} \sum_{n=1}^N X[n] - X[n-1] $
Standart sapmadaki mutlak fark	$SSMF = \sqrt{\frac{1}{N} \sum_{n=1}^N (x[n] - x[n-1])^2}$
Ortalama mutlak değer	$OMD = \frac{1}{N} \sum_{n=1}^N x_n $
Standart sapma	$SS = \sqrt{\frac{1}{N} \sum_{n=1}^N (x(n) - \mu_n)^2}$
Varyans	$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2$
Kök ortalama kare	$KOK = \left(\frac{1}{N} \sum_{i=1}^N \sqrt{ x_i } \right)^2$
Skewness değeri	$SD = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{\sigma} \right)^3$
Kurtosis değeri	$KD = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{\sigma} \right)^4$
Güç	$P = \frac{1}{N} \sum_{n=1}^N x_n ^2$

Zaman alanında uygulanan bu yöntemler, sinyallerinin özelliklerini anlamak ve analizlerin etkinliğini arttırmak açısından büyük önem taşır. Bu analizler sayesinde sinyallerin dalgalanma seviyeleri, karmaşıklıkları ve istatistiksel verileri elde edilebilir. Ancak sinyaller hakkındaki bilgilere erişim için sadece zaman alanında yapılan analizler yeterli değildir. Bu sebeple farklı frekans alanı yöntemleri de zaman alanından elde edilen bilgileri tamamlayıcı olarak kullanılmaktadır.

Frekans Alanı Özellik Çıkarımı

Sinyallerin zaman alanında olduğu gibi, frekans alanında da özellik çıkarımı büyük önem taşır. Sinyallerin frekans bileşenlerini elde etmek, sinyalin farklı frekans bantlarından analiz edilmesini kolaylaştırır. Bir sinyalin frekans alanı bileşenleri, sinyalin farklı frekanslardaki yapılarını ifade eder ve sinyalin frekans alanında nasıl dağıldığını gösterir. Frekans alanı bileşenleri, sinyalin analizi ve işleme süreçlerinde kritik bir rol oynar. Bu amaçla kullanılan çeşitli yöntemler ve bu yöntemlerin varyasyonları mevcuttur.

- **Hızlı Fourier Dönüşümü** (Fast Fourier Transform, FFT), sinyalleri zaman alanından frekans alanına dönüştürmek için kullanılan bir yöntemdir. Bu yöntemde, sinyallerin farklı frekans bileşenlerine ayrılması sağlanır ve sinyalin frekans bileşenlerini gösteren güç spektral yoğunluğu hesaplanır. Bu hesaplamayı gerçekleştirmek için öncelikle otokorelasyonun tahmin edilmesi gerekmektedir [90]. Zaman alanında sinyalin tüm özellikleri bir arada gözlemlenebilirken, frekans alanında bu özellikler bağımsız frekans bileşenlerine ayrılarak analiz edilebilir. Bu işlem sırasında kullanılan formül Denklem 2.8’de verilmiştir.

$$X_k = \sum_{n=0}^{N-1} x_n * e^{-i2\pi kn/N} \quad (2.8)$$

N zaman örneği sayısını, n incelenen örneği, X_n sinyalin n zamanındaki genliğini k ise frekansı ifade etmektedir.

$$X_n = \frac{1}{N} \sum_{k=0}^{N-1} X_k * e^{-i2\pi kn/N} \quad (2.9)$$

Zaman alanındaki verilerin frekans alanına dönüştürülmesiyle, bu yöntemin zaman alanı verilerine uygulanabilirliği sınırlı hale gelmiştir [91]. Ayrıca FFT, büyük gürültü duyarlılığına sahiptir.

- **Ortak Uzaysal Desenler** (Common Spatial Pattern, CSP), EEG verilerinin uzamsal ayrıntısını artırmak için yaygın olarak kullanılan bir yöntemdir İlk olarak anormal EEG aktivitesini tanımlamak için CSP algoritması tanıtılmıştır. Daha sonra, BBA alanında hareketle ilgili kalıpları ve farklı zihinsel aktiviteleri ayırt etmek için etkili bir yöntem olduğu gösterilmiştir. CSP, EEG verilerinin sinyal-gürültü oranını azaltmaktadır. Optimal uzaysal filtreleme için ham EEG sinyallerini bir koşulun varyansını maksimize ederken diğer koşulun varyansını en aza indirerek ayırmaktadır [92]. CSP’nin temel amacı, bu çok boyutlu veri matrisini daha az boyuta sahip bir alt uzaya dönüştürmektir. Bu alt uzay, belirli beyin aktivitelerini temsil edecek şekilde şekillendirilir. CSP, bu dönüşüm için doğrusal bir ilişki kullanır ve her bir EEG kanalının ağırlıklarını içeren bir matris aracılığıyla belirli beyin aktivitelerinin optimal şekilde temsil edilebileceği yeni bir uzay oluşturur [93]. CSP gürültüye son derece hassastır ve aşırı uyum olasılığı yüksektir.
- **Yüksek Dereceli Spektral** (Higher-Order Spectral, HOS), normal dağılıma uymayan süreçleri analiz etme yeteneğine sahiptir ve gürültülere karşı dayanıklıdır. Bu analiz yöntemi, sinyalin güç spektrumunda kaybolan faz bilgisini içerir ve düşük sinyal-gürültü oranına sahip zayıf sinyallerde daha iyi sonuçlar vermektedir. Sinyalin yüksek dereceli momentlerine odaklanan bu yöntem sinyaldeki gürültüyü filtreleyerek, önemli bilgilere

erişimi sağlamaktadır. Gauss gürültüsü gibi normal dağılıma uyan gürültülerin üçüncü ve daha yüksek dereceli momentlerindeki (çarpıklık ve basıklık) değerler sıfır olduğundan, bu tür gürültüleri filtreler ve sinyalin önemli olabilecek non-lineer özelliklerini belirler.

Frekans alanı özellik çıkarımı, sinyalin frekans bileşenlerini analiz ederek sinyalin karakteristik özelliklerinin belirlemeye yardımcı olur. Bu sayede, sinyalin analiz edilme sürecinde daha detaylı bilgi elde edilmesini sağlar. Zaman-frekans alanı analizi ise sinyalin hem zaman hem de frekans boyutlarında nasıl değiştiğini inceleyerek, sinyalin dinamik özelliklerini daha kapsamlı bir şekilde ortaya koyar.

Zaman-Frekans Alanı Özellik Çıkarımı

Zaman-frekans alanı özellik çıkarımı, bir sinyalin hem zaman hem de frekans alanlarındaki özelliklerini analiz ederek bilgi çıkarmayı amaçlayan bir tekniktir. Bu teknik, sinyalin zaman içindeki değişimini ve frekans bileşenlerini birlikte analiz ederek, sinyalin içerdiği bilgilerin daha kapsamlı bir şekilde incelenmesini sağlar. Zaman serileri veya sürekli sinyaller üzerinde etkili olan bu yöntem, sinyalin belirli bir zaman diliminde hangi frekans bileşenlerine sahip olduğunu göstermektedir.

- **Otoregresif Bileşenler** (AutoRegressive Components, AR), Otoregresif (AR) yöntemler, EEG verilerini modellemek için yaygın olarak kullanılan yöntemlerdir. Bu yöntemler, her kanaldaki sinyali önceki zaman noktalarındaki sinyalin doğrusal bir kombinasyonu olarak temsil ederek sinyalin zamana bağlı değişimini açıklamayı amaçlamaktadır. Aynı zamanda çok değişkenli AR modelleri kullanılarak kanallar arasındaki ilişkilerde ölçülmektedir. Bu modeller sıradan, kısmi veya yönlendirilmiş tutarlılık ve doğrudan transfer fonksiyonu gibi nicelikleri hesaplamak için kullanılabilecek yararlı bilgiler sağlamaktadır. AR modelleri, EEG sinyallerini daha az yer kaplayarak ve daha az miktarda bilgiyle etkili bir şekilde temsil eder, bu da hesaplama açısından verimli bir temsil oluşturur. Ayrıca, AR modeli parametreleri, bireysel farklılıklardan kaynaklanan verilerdeki ölçeklendirme değişikliklerinden etkilenmez [94].
- **Dalgacık Dönüşümü** (Wavelet Transform, WT), zamanla değişen biyomedikal sinyaller gibi çok sayıda veri noktasını içeren sinyallerin analizi için kullanılır. Durağan olmayan EEG sinyalleri gibi sinyallerde, ham verilerden özellik çıkarımı için en uygun yöntemlerden biri, dalgacık dönüşümü gibi spektral tahmin teknikleridir. WT yönteminde, orijinal EEG sinyali, dalgacıklar olarak adlandırılan basit ve güvenilir yapı bloklarıyla temsil edilmektedir [90]. Bu yöntemin temel fikri, sinyali bir dizi dalgacık katsayısına ayıştırmaktır. Dalgacık analizi, sinyali daha az sayıda parametreyle temsil ederek sıkıştırır ve bu sayede sinyali daha küçük parçalara ayırmamıza olanak tanır. Her bir parçayı temsil etmek için uygun bir dalgacık fonksiyonu seçilerek, sinyalin daha iyi anlaşılması ve

işlenmesi sağlanır. Dalgacık dönüşümü, bir sinyali farklı frekans bantları ve çözünürlüklerde analiz etmek için kullanılan bir yöntemdir. İlk adımda, sinyal yaklaşık ve detay katsayılarına ayrıştırılır. Yaklaşık katsayıları, sinyalin daha düşük frekanslı bileşenlerini, detay katsayıları ise daha yüksek frekanslı bileşenlerini temsil eder. Daha sonra, yaklaşık katsayıları aynı dalgacık dönüşümü adımı kullanılarak daha da ayrıştırılabilir. Bu süreç, zaman alanındaki sinyalin ardışık yüksek geçiş ve alçak geçiş filtrelemeleriyle elde edilir ve sinyalin farklı frekans bileşenlerine ayrılmasını sağlar. Alçak geçiş ve yüksek geçiş filtrelerinin denklemleri Denklem 2.10 ve 2.11’de yer almaktadır.

$$YGF(S) = D_{1j} = \sum_t S(t)k(2j - t) \quad (2.10)$$


$$DGF(S) = A_{1j} = \sum_t S(t)h(2j - t) \quad (2.11)$$

D_1 detay katsayısını ifade ederken, A_1 ise yaklaşık katsayısını ifade etmektedir. İlk katsayılar oluşturulduktan sonra A_1 katsayısı tekrar filtreleme işlemine tabi tutularak hedeflenen işaret elde edilene kadar ayrıştırılma işlemi devam ettirmektedir. Oluşturulan i . seviyedeki yaklaşık ve detay dalgacıklarının enerjisi Denklem 2.12 ve denklem 2.13’deki matematiksel formül ile hesaplanmaktadır.

$$ED_i = \sum_{j=1}^N |D_{ij}|^2 \quad i = 1, 2, \dots, l \quad (2.12)$$

$$EA_i = \sum_{j=1}^N |A_{ij}|^2 \quad i = 1, 2, \dots, l \quad (2.13)$$

Formülde l değeri ayrıştırılacak olan seviyeyi ifade ederken, N değeri her seviyedeki toplam detay ve yaklaşık katsayılarını belirtir [95]. 4. Seviye dalgacık dönüşümünün şematik görünümü Şekil 2.7’de verilmiştir.




Şekil 2.7. Dördüncü seviye dalgacık dönüşümü

Elektroensefalografi (EEG) sinyalleri, beyin aktivitesini ölçmek için kullanılan değerli verilerdir. Bu sinyaller, beyin-bilgisayar arayüzü (BBA) sistemlerinde beyin kontrol sinyalleri olarak işlev görür. BBA sistemlerinde, EEG sinyalleri önce ön işleme adımlarından geçirilir, ardından özellik çıkarımı yapılır. Bu süreç, sinyallerin daha anlamlı ve kullanışlı hale getirilmesini sağlar. Sonrasında, makine öğrenimi algoritmalarıyla sınıflandırılan bu sinyaller, çeşitli uygulamalarda kullanılmak üzere hazır hale gelir.

3. MAKİNE ÖĞRENMESİ

Makine öğrenimi, son yıllarda hem akademik hem de endüstriyel alanda büyük ilgi gören ve hızla gelişen bir alan olmuştur. Temel olarak, makine öğrenimi algoritmaları, verilerden öğrenerek ve bu öğrenmeyi kullanarak yeni veriler üzerinde tahminler yapabilen modeller oluşturmayı amaçlar. Bu algoritmaların uygulanma alanları, görüntü tanıma, doğal dil işleme, biyomedikal veri analizi ve finansal tahminler gibi geniş bir yelpazeye yayılmaktadır. Makine öğrenimi, istatistiksel yöntemlerle derin öğrenme tekniklerini birleştirerek daha karmaşık ve büyük veri setleri üzerinde etkili sonuçlar elde edebilmektedir [96]. Şekil 3.1’de yapay zeka ve makine öğrenmesi kapsamını belirten bir şematik görünüme yer verilmiştir.



Şekil 3.1. Yapay zeka ve makine öğrenmesi kapsamı

Makine öğrenmesinin en önemli bileşenlerinden biri, gözetimli ve gözetimsiz öğrenme yöntemleridir. Gözetimli öğrenme, etiketli veri kullanarak öğrenme sürecini ifade ederken, gözetimsiz öğrenme ise etiketlenmemiş verilerle çalışarak veri içindeki yapıları keşfetmeyi amaçlar. Gözetimsiz öğrenme yöntemleri ise, büyük veri setlerinde gizli kalıpları ve ilişkileri bulmak için kullanılır; bu da özellikle veri madenciliği ve büyük veri analitiği gibi alanlarda büyük fayda sağlar [97].

Makine öğrenimi uygulamalarının performansı, büyük ölçüde kaliteli ve yeterli veri miktarına bağlıdır. Verinin miktarı ve kalitesi, algoritmaların doğruluğunu ve genel başarısını doğrudan etkiler. Bu nedenle, veri toplama, ön işleme ve özellik mühendisliği gibi adımlar makine öğrenimi süreçlerinin kritik parçalarıdır. Ayrıca, makine öğrenimi modellerinin genelleştirme yeteneği de büyük önem taşır; bu, modellerin yeni ve görülmemiş veriler üzerinde doğru tahminler yapabilme yeteneğidir [98]. Bu süreçlerin doğru yönetilmesi, makine öğrenimi algoritmalarının etkinliğini ve güvenilirliğini artırarak daha doğru ve güvenilir sonuçlar elde edilmesini sağlar.

3.1. Makine Öğrenmesi Algoritmaları

Makine öğrenmesi yöntemleri, verilerin matematiksel bir temsil kullanılarak modellenmesini sağlar ve tıp alanında teşhis sistemlerinde önemli bir rol oynamaktadır. Bu sistemler, var olan vakalardan elde edilen veri koleksiyonlarıyla eğitilmektedir. Eğitilen sistemler, veriler arasındaki ilişkilere dayalı olarak gelecek vakaları analiz ederek tahminler yapabilmektedir. Makine öğrenmesi algoritmaları, sağlık alanında teşhis süreçlerini desteklemek için yaygın olarak kullanılmaktadır. Bu algoritmalar; tıbbi görüntüleme, hastalık teşhisi ve tedavi planlaması gibi çeşitli uygulamalarda başarıyla kullanılmaktadır. Makine öğrenmesi algoritmalarının doğruluğu, veri kalitesine, doğru algoritmanın seçimine ve modelin uygun şekilde eğitilmesine bağlıdır. Bu teknikler, büyük veri setlerindeki karmaşık ilişkileri öğrenerek teşhis doğruluğunu artırabilmektedir.

3.1.1. Karar Ağaçları

Ağaç tabanlı öğrenme modeli olarak da bilinen karar ağaçları (Decision Trees, DT) sınıflandırma ve regresyon problemlerinin çözümünde kullanılan gözetimli öğrenme modellerindendir. Bu teknik, çok sayıda veri içeren bir veri kümesini yüksek bilgi kazancı sağlayacak şekilde tekrar tekrar daha küçük kümeler bölmek için kullanılmaktadır. Her bölünme aşamasında entropi değerinin düşmesi gerekmektedir [99]. Veri kümesinde yer alan her bir öznitelik, ağaç benzeri yapıda bir düğüme karşılık gelirken, farklı sınıf etiketleri yapraklar ile temsil edilir. Düğümler ile yapraklar arasındaki yollar, karar kurallarını gösterir. Dallanma işlemi sırasında entropi, kazanç oranı ve Gini indeksi gibi yöntemler kullanılır. Karar ağacının karmaşıklığını azaltmak için belirli durdurma kriterleri uygulanır ve daha az bilgiye sahip olan düğümler budanarak ağaç sadeleştirilir. Karar ağacı sistemleri, veriler arasındaki karmaşık ilişkilerin daha kolay anlaşılmasını ve yorumlanmasını sağlar. Eksik verileri işlemenin daha kolay olması ve diğer avantajları ile tıp alanında kullanımı oldukça yaygınlaşmıştır. Ancak bu sistemlerde küçük boyuttaki veri setleri kullanıldığı durumlarda eğitim verilerine aşırı uyumlama oluşabileceği için modellerin yorumlanması zordur [100].

3.1.2. Lojistik Regresyon

Lojistik regresyon (LR), değişken etkilerinin incelenmesi, değişkenler arasındaki ilişkilerin gözlemlenmesi ve sonuçların analiz edilebilmesi nedeniyle tıbbi araştırma alanlarında tercih edilen yöntemler arasındadır. Bu yöntem, lineer regresyonun lojit ölçeğindeki bileşenleri ile sonucu belirleme ihtimali en yüksek olan değişkenlerin birleşimini yinelemeli olarak tanımlar. Yöntemdeki önemli kriterler, bağımsız değişkenlerin ve uygun bir modelin belirlenmesidir. Lojistik regresyon analizinde farklı değişken tipleri kullanılırken, bağımsız değişkenlerin belirlenmesinde geçmiş

deneyisel ve klinik arařtırmalar ile istatistiksel analiz yöntemleri dikkate alınır. Aşırı uyumlama riskinden kaçınmak için örneklem boyutunun dikkatli bir şekilde belirlenmesi gereklidir. Model oluşturma aşamasında ise doğrudan, hiyerarşik ve istatistiksel yaklaşımlar yaygın olarak kullanılır. Bağımsız değişkenlerle birlikte regresyon modelinin eş zamanlı belirlenmesinin ardından elde edilen sonuçlar, modelin uyumu ve bireysel değişkenler açısından yorumlanır [70].

3.1.3. K-En Yakın Komşu Algoritması

K-En Yakın Komşu algoritması (KNN), yeni veriler ile mevcut veriler arasındaki benzerliğe dayanan, herhangi bir model oluşturulması gerekmeyen öğrenme tabanlı bir yöntemdir. Bu yöntemde, verilerin sınıflandırılması için uzaklık vektörleri (Minkowski, Öklit, Manhattan, Chebychev, Cosine ve Jaccard) ve en yakın komşuların sayısı olan k komşuluk değerinin belirlenmesi önemlidir. k değeri belirlendikten sonra, veriler arasındaki uzaklık değerleri hesaplanır ve sınıflandırılacak noktaya en yakın olan k tane değer sınıfı belirlenir. En çok tekrarlanan sınıf, gözlem değerinin sınıfı olarak kabul edilir [101].

KNN, gerçekleştiriminin kolay ve gürültülü eğitim verilerine karşı dirençli olması nedeniyle sınıflandırma problemlerinde tercih edilmektedir. Ancak performansın k komşu sayısı, uzaklık ölçütü gibi parametrelere bağlı olması nedeniyle, en iyi sonuçların elde edilmesinde kullanılacak olan uzaklık tipi ve nitelik belirsizdir.

3.1.4. Rastgele Orman

Rastgele orman (RF) algoritması, denetimli sınıflandırma ve regresyon problemlerindeki verimliliği ve yorumlanabilirliği nedeniyle sıklıkla tercih edilen bir yöntemdir. RF algoritması, farklı karar ağacı modellerini bir araya getirerek kullanır ve özellikle değişken sayısının yüksek olduğu problemlerde yüksek performans sergiler. Her bir ağaç, rastgele seçilen özellikler arasından en iyisini seçerek oluşturulur, bu da her ağacın birbirinden bağımsız olarak eğitildiği ve tahmin yaptığı anlamına gelir. Sonuç olarak, her ağacın tahmini alınarak bir oylama yapılır ve bu oylama sonucu, rastgele ormanın final tahmini olarak kullanılır. Bu özellikler, RF algoritmasının doğruluğunu artırır. Ağaçlar, yer değiştirmeli olarak orijinal veri setinden türetilen verilerle oluşturulur ve ağaçlarda budama işlemi yapılmaz. Ayrıca, hızlı bir algoritma olması ve aşırı uyumlamaya karşı dayanıklı olması nedeniyle sınıflandırma işlemlerinde yaygın olarak kullanılır [102]. Her ağacın bağımsız olarak eğitilmesi, algoritmanın paralelleştirilebilir olmasını sağlar ve bu da işlem hızını artırır ve büyük veri setlerinde daha verimli bir şekilde kullanılmasına olanak tanır.

3.1.5. Naive Bayes

Naive Bayes (NB) algoritması, temeli Bayes teoremine dayanan olasılık tabanlı bir yaklaşımdır. NB verilerin öğrenilmesi mantığına dayanmaktadır. Modelin öğrenilmesi sürecinde eğitim verilerinin her bir çıktısının ne sıklıkta tekrarlandığına bakılarak öncelikli olasılık değerleri hesaplanmaktadır. Bağımsız değişkenlerin bağımlı değişkenlere bölünmesinin kombinasyonları hesaplanarak olayın oluşma sıklığı belirlenmektedir. NB sınıflandırıcı, hem kategorik hem de sayısal özniteliklere sahip verilerin sınıflandırılmasında kullanılabilir. Ayrıca sınıf etiketi denilen bir öznitelik de bulunmaktadır. Bu sayede, yeni eklenen ve sınıf etiketi olmayan kayıtların sınıf etiketlerinin tahmin edilmesi için bir model oluşturulmaktadır. Yeni bir verinin hangi sınıfa ait olduğunun belirlenmesinde bağımsız değişkenlerin bağımlı değişkenlerle olan ilişkilerinden yararlanılmaktadır [103].

NB sınıflandırıcısının avantajları arasında kısa çalışma süresi, verileri işleme kapasitesi ve veri akışını etkin bir şekilde yönetebilme yeteneği bulunmaktadır. Naive Bayes sınıflandırıcısı, sınıflandırma problemlerinde yaygın olarak kullanılan basit ve etkili bir yöntemdir. Eğitim verilerindeki eksik değerleri işleyebilme kabiliyeti ve hızlı çalışma özelliği, büyük veri setlerinde de tercih edilmesini sağlamaktadır. NB'nin her bir özniteliğin sınıf etiketi üzerindeki etkisini bağımsız olarak ele alması ve öznitelikler arasındaki ilişkiyi göz ardı etmesi, veri setindeki öznitelik sayısının artmasına rağmen modelin karmaşıklığının artmamasını sağlamaktadır. Modelin dezavantajlarından biri de, tüm özellikleri eşit derecede önemli kabul etmesi ve ilgisiz özelliklere duyarsız olmasıdır. Çünkü yapılan tahminlerin yetersiz kalmasına sebep olmaktadır. Naive Bayes sınıflandırıcısı, sınıflandırma problemlerinde yaygın olarak kullanılan basit ve etkili bir yöntemdir.


3.1.6. Destek Vektör Makinesi

Destek vektör makineleri ilk olarak Vapnik tarafından önerilen bir yöntem olup, örüntü tanıma ve sınıflandırma problemlerinin çözümüne yönelik olarak tasarlanmıştır. Hem doğrusal olmayan hem de çok sınıflı verilerin sınıflandırılma amacıyla kullanılan istatistiksel öğrenme teorisine dayalı bir yöntemdir. SVM'nin sınıflandırma işleminin temelinde, birbirinden farklı iki sınıfa ait verilerin belirlenen bir sınır yani hiper-düzlem ile ayrılması yer almaktadır [104].

Eğitim veri setindeki veriler üzerinde eğitim gerçekleştirildikten sonra elde edilen karar fonksiyonu, test veri setindeki veriler üzerinde uygulanarak en iyi ayrım yapan düzlem belirlenmektedir. SVM ile eğitim veri setinde bulunan en uç noktadaki veriler seçilerek en uygun düzlem belirlenir. Seçilen bu verilere destek vektörü denilmektedir. Destek vektörlerin uygun olarak belirlenmesi, sınıflandırma performansını olumlu yönde etkileyen önemli parametrelerdendir. En uygun hiperdüzlemin seçilmesi, sınıflandırma ve ayrım başarımını destekler ve daha etkili sonuçlar ortaya çıkmasını sağlar. SVM'de, sınıfları birbirinden mümkün

olduğunca uzak tutarak ayıran bir hiperdüzlem bulunmaktadır. Bu hiperdüzlem, her iki sınıfın veri noktaları arasındaki en kısa çizgiye dik olacak şekilde yönlendirilmektedir [105].

SVM, doğrusal ve doğrusal olmayan şekillerde ikiye ayrılmaktadır. Lineer olarak ayrılma durumunda iki sınıf doğrusal bir düzlem ile ayrılır ve bu düzlem iki sınıfa da eş uzaklıktadır. Lineer olarak ayrılamayan durumlarda ise, sınıfları ayırmak için çekirdek fonksiyonları kullanılmaktadır. Bu algorithma kullanılan çekirdek fonksiyonları arasında doğrusal, polinomial, sigmoid ve radyal tabanlı fonksiyonlar bulunur. Şekil 3.2’de iki sınıflı veriler için lineer ve lineer olmayan destek vektör makinesinin şekilsel gösterimine yer verilmiştir.



Şekil 3.2. İki sınıflı veriler için (a) lineer SVM, (b) lineer olmayan SVM

SVM yüksek boyutlu veri setlerinde iyi performans gösterirken, büyük veri setlerinde hesaplama maliyetinin artışına neden olmaktadır. Bu durum, özellikle çok sayıda örnek ve öznelilik içeren veri setlerinde önemli hale gelmektedir. SVM aşırı uydurmaya karşı dirençlidir ve genellemeyi artırarak modelin daha iyi performans göstermesine yardımcı olabilmektedir. Ayrıca SVM doğrusal olmayan veri setlerinde de kullanılabilir. Veriler arasındaki ilişkinin doğrusal olmadığı durumda bile SVM algoritması etkili bir şekilde çalışmaktadır.

3.2. Meta-Sezgisel Optimizasyon Algoritması

Metasezgisel algoritmalar, geleneksel yöntemlerle çözülemeyen karmaşık problemlere yönelik optimizasyon teknikleridir. Bu algoritmalar, genetik, sürü davranışı ve evrim gibi doğal süreçlerden ilham alır ve bir problemin küresel optimumunu bulmak için geniş bir arama alanını keşfeder. Mühendislik, finans ve bilgisayar bilimi gibi çeşitli alanlarda karmaşık sorunları çözmek için

yaygın olarak kullanılmıştır. Meta-sezgisel algoritmaların evrimi, doğal sistemlerden esinlenen optimizasyon yöntemlerinin geliştirilmesiyle geniş bir zaman dilimini kapsamaktadır. Bu algoritmalar, karmaşık optimizasyon problemlerini çözmek için değerli araçlar haline gelmiş ve yeni teknolojilerin ve uygulamaların geliştirilmesinde önemli bir rol oynamaya devam etmektedir [106].

Meta-sezgisel optimizasyon algoritmaları içerisinde literatürde en fazla kullanılan parçacık sürü optimizasyon algoritması bu çalışmada ele alınmıştır. Parçacık sürü optimizasyonu, kuş sürülerinin doğal ve öngörülemez koreografik davranışlarını modellemektedir [107]. Yöntem, Kenedy ve Eberhart tarafından 1995 yılında geliştirilmiş ve pek çok alanda başarıyla uygulanmıştır [108].

Parçacık sürü optimizasyonun temel prensibi sürüdeki her bir parçacığın konum ve hızının sürüdeki en iyi konum ve hıza sahip bireye ulaştırılmasıdır [109]. Başlangıçta tüm parçacıklara rastgele konum ve hız bilgisi verilir ve bu bilgi doğrultusunda uygunluk fonksiyonu hesaplanır. Uygunluk fonksiyonu tüm durumlar içindeki en optimum durumu ifade eder. Daha sonra her parçacık hem kendi en iyi durumunu hem de sürüdeki en iyi durumu göz önünde bulundurarak hız ve konum güncellemesi yapar. Bu durum en uygun konum ve hızın bulunmasına kadar devam eder. Parçacıkların pozisyon ve hızları hesaplanırken Denklem 3.1 ve Denklem 3.2'deki formüller kullanılmaktadır.

$$V_{id} = W * V_{id} + c_1 * rand_1 * (P_i - X_{id}) + c_2 * rand_2 * (P_{gd} - X_{id}) \quad (3.1)$$

$$X_{id} = X_{id} + V_{id} \quad (3.2)$$

Burada V_{id} ve X_{id} değerleri sırasıyla parçacığın hız ve konumunu ifade etmektedir. W ağırlık ataleti, c_1 ve c_2 ise ölçeklendirme faktörleridir [110].

3.3. Makine Öğrenmesinde Kullanılan Performans Değerlendirme Metrikleri

Makine öğrenimi algoritmalarıyla yapılan çalışmaların başarısını değerlendirmek, bu algoritmaların etkinliğini anlamak ve iyileştirmek için önemli bir adımdır. Ancak başarılı bir değerlendirme için doğru metriklerin kullanılması oldukça önemlidir. Makine öğrenimi algoritmalarının performansını değerlendirmek için bir dizi metrik ve yöntem bulunmaktadır. Bu metrikler, modelin doğruluğunu, doğruluk oranını, duyarlılığını, özgüllüğünü belirlemek için kullanılmaktadır. Karışıklık matrisi bu metriklerin bulunabilmesi için kullanılan ve gerçek sınıf ile modelin tahmin ettiği sınıflar arasındaki ilişkiyi görsel olarak temsil eden bir araçtır.

Karışıklık matrisinde 4 ana sınıf bulunmaktadır. Burada modelin doğru bir şekilde sınıflandırdığı pozitiflerin sayısı (True Positive-TP), negatif bir örneği pozitif olarak sınıflandırdığı örnek sayısı (False Positive-FP), doğru bir şekilde sınıflandırdığı negatiflerin sayısı (True Negative- TN) ve

pozitif bir örneği negatif olarak sınıflandırdığı örnek sayısı (False Negative-FN)'dir. Şekil 3.3'te 2 sınıf etiketi olan veriler için hazırlanmış karışıklık matrisinin görseline yer verilmiştir.

		Gerçek Sınıf	
		1	2
Tahmin Sınıfı	1	TP	FP
	2	FN	TN

Şekil 3.3. Karışıklık Matrisi

Bu dört kategori, modelin performansını değerlendirmede metriklerin hesaplanması için kullanılmaktadır.

Doğruluk (Accuracy, ACC): Modelin ne kadar iyi performans gösterdiğini ölçmek için kullanılan bir metriktir. Modelin doğru sınıflandırdığı örneklerin toplam örnek sayısına oranını ifade etmektedir.

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.3)$$

Doğruluk, modelin farklı sınıflarda ne kadar iyi performans gösterdiğini tam olarak yansıtmaz. Hassasiyet ve özgüllük gibi diğer ölçütler de performans değerlendirmesinde dikkate alınmaktadır.

Hassasiyet (Sensitivity, Recall): Bir sınıflandırma modelinin gerçek pozitif durumların ne kadarını doğru bir şekilde tahmin ettiğini ölçmektedir. Yani bu metrik gerçek pozitif vakaların tamamını kapsamaktadır. Eğer bir modelin hassasiyeti yüksekse, bu model gerçek pozitif durumları kaçırmadan doğru bir şekilde tespit etme eğilimindedir. Denklem 3.4'te gösterilen formül kullanılarak hesaplanmaktadır [111].

$$TPR = \frac{TP}{TP + FN} \quad (3.4)$$

Özgüllük (Specificity): Negatif örneklerin ne kadarının doğru bir şekilde negatif olarak sınıflandırıldığını gösteren bir performans ölçütüdür. Özgüllük, duyarlılık ile birlikte kullanıldığında, modelin hem pozitif hem de negatif sınıfları ne kadar iyi tanımladığını tam olarak anlamak için güçlü bir değerlendirme aracı olarak kullanılmaktadır.

$$TNR = \frac{TN}{TN + FP} \quad (3.5)$$

Kesinlik (Precision, Confidence): Modelin tahmin ettiği pozitif durumların gerçekten ne kadarının doğru olduğunu göstermektedir. Denklem 3.6’da görüldüğü gibi bu model tahmin edilen pozitiflerin doğruluğunu ölçer ve gerçek pozitiflerin oranıyla karşılaştırarak modelin doğruluğunu değerlendirir [111].

$$PPV = \frac{TP}{TP + FP} \quad (3.6)$$

F1-Değeri: Hassasiyet ve duyarlılığın harmonik ortalamasıdır. F1 değeri, modelin pozitif sınıf performansını değerlendirirken denge sağlar. Özellikle dengesiz veri setlerinde hassasiyet ve duyarlılığı birleştirerek daha dengeli bir performans ölçümü sağlamaktadır.

$$F1 = \frac{2TP}{2TP + FP + FN} \quad (3.7)$$

Makine öğreniminde model performansını değerlendirmek için çeşitli ölçütler kullanılmaktadır. Doğruluk, modelin genel olarak ne kadar doğru tahmin yaptığını gösterirken; hassasiyet, duyarlılık ve F1 skoru gibi ölçütler, modelin pozitif sınıfları ne kadar iyi tanımladığını detaylandırır. Özgüllük ise negatif sınıfların doğru tanımlanma oranını belirler. Bu performans ölçütleri, modelin güçlü ve zayıf yönlerini belirlemek ve daha dengeli, güvenilir ve uygulamaya uygun modeller geliştirmek için birlikte kullanılmaktadır.

4. KUANTUM MEKANIĞI

Kuantum hesaplama kavramının ortaya çıkışı kuantum fiziğinin başlangıcına dayanan uzun bir süreci ifade etmektedir. Bu görüş öne sürüldüğü dönemde büyük tartışmalara sebep olmuş ve çeşitli kimya, fizik ve matematik alanındaki bilim adamlarının dikkatini çekmiştir. Kuantum mekaniğinde gerçekleşen gelişmeler günümüzde kuantum hesaplamanın, yapay zekâ ve makine öğrenme teknolojilerinde uyarlanabilmesine öncü olmuştur. Yapılan çalışmalar incelenerek, tarihsel süreç içinde ön plana çıkan çalışmalara ve bu alanda yaşanan gelişmelere yer verilmiştir.

Klasik fizik ile açıklanamayan siyah cisim radyasyonu ve fotoelektrik etki gibi kavramların ortaya çıkması ile birlikte yeni fiziksel paradigma arayışı başlamıştır. 19. yüzyılın sonlarında yaşanan Max Plank'ın kara cisim radyasyonunu tanıtması, kuantum teknolojisinin başlangıcı olarak kabul edilmektedir. Albert Einstein'ın 1905 yılında fotoelektrik etki kavramını keşfetmesi, ışık deneylerinin yapılmasına olanak tanımış oldu. Böylece ışının sadece dalga değil aynı zamanda parçacık gibi davrandığı fikrini ortaya çıkardı [112]. 1925 yılında Schrödinger kuantum mekaniğinde dalga denklemini önermiştir. Lewis 1926'daki çalışmasında, foton kavramı ve ışınım enerjisinin belirli bir yoldan geçerken ayrı birimler halinde hareket edebileceği fikri ortaya çıktı. Heisenberg 1927 yılında yayınladığı çalışmasında kuantum mekaniğinin klasik mekanik ve kinematik kavramlar kullanılarak açıklanamayacağını belirtmiştir. Heisenberg'in belirsizlik ilkesi olarak bilinen bu araştırma, kuantum mekaniğinin klasik fizikten ayıran farkları ortaya koymaktadır [113]. Einstein'ın 1935 yılında ortaya attığı ERP paradoksu ile kuantum mekaniğinde, bir fiziksel olayın başka bir fiziksel olayı nasıl etkileyebileceği gösterilmiştir. Bir sistem ile etkileşime giren diğer bir sistem üzerinde ölçümler yapılarak tahminde bulunulacaksa, iki sistemden birinde yanlış sonucuna ulaşırsa diğer sistemin tahmininin de yanlış olacağı belirtilmiştir [114]. Bu paradoks, günümüzde kuantumun yapıtaşlarından olan kuantum dolanıklığının temelini oluşturmaktadır. David Bohm 1952'de kuantum teorisinin kendi içerisinde tutarlı olduğunu ancak deneysel olarak test edilemeyecek varsayımlar içerdiğini belirtmiştir. Konumu ve momentumu belli olan bir parçacığın dalga fonksiyonu tarafından yönlendirilmesinin olasılıksal bir davranışını belirleyeceği açıklanarak, kuantum teorisinin 'gizli' değişkenler açısından yorumlanması gerektiği vurgulanmıştır. Bohm mekaniği veya pilot dalga teorisi olarak bilinen bu çalışma ile kuantuma daha geniş bir kavramsal çerçeve sunulmuştur [115].

Kuantum mekaniğinde yaşanan gelişmeler ile birlikte 1970'de 'Kuantum Bilgi Teknolojisi' kavramı ortaya çıkmıştır. 1981 yılında gerçekleştirilen konferansta Richard Feynman kuantum mekaniği prensiplerine dayanan yeni bir bilgisayarın geliştirilmesi konusundaki görüşleriyle kuantum bilgisayarlarının ortaya çıkmasında öncü olmuştur. Barnett vd., 1993'te kuantum dolanıklık kavramıyla bilginin uzak mesafelere iletilmesini sağlamıştır. 2010'da 128 kübit işlemciye sahip olan ilk kuantum bilgisayarı D-Wave One tanıtılmıştır. 2014'te 100 kübitlik


kuantum bilgisayarlar geliştirilmiştir. 2016'dan itibaren ise IBM, kuantum hesaplama ortamını bulut üzerinden kullanıma açarak kuantum devrelerinin uygulanmasını mümkün kılmıştır. [116]. Kuantum bilgi teknolojisi kavramının yaygınlaşması ve kuantum bilgisayar sürecine erişimin kolaylaşması ile birlikte kuantum hesaplama alanında birçok çalışmanın gerçekleştirilmesine olanak tanınmış oldu.

4.1. Kuantum Mekanikinin Temel Deneyleri

Kuantum mekaniği, fiziksel olayları anlamak için ayrıntılı bir şekilde incelenen, ancak anlaşılması genellikle zor olan bir alandır. Bu alandaki çeşitli deneyler, kuantum mekaniğinin temel prensiplerini ve belirsizliklerini anlamak için yapılmıştır. Bu deneyler, modern fiziğin temellerini sorgulamanın yanı sıra kuantum fiziğinin karmaşıklığını anlamak için oldukça büyük öneme sahiptir.

4.1.1. Schrödinger'in Kedisi

Fizikçi Erwin Schrödinger, parçacıkların birden fazla yerde aynı anda bulunması ve birbirleriyle ışık hızından daha hızlı bir şekilde iletişim kurması gibi özelliklerinin klasik fiziğin ötesinde yer alan davranışlar olduğunu belirtmiştir. 1935 yılında gerçekleştirmiş olduğu düşünce deneyinde, parçacıkların dalgalanma özellikleri sayesinde potansiyel olarak birden fazla durumda bulunabileceğini ancak gözlemlendiğinde parçacıkların sadece tek bir durumda bulunduğunu vurgulamıştır. Şekil 4.1'de Schrödinger'in kedisi düşünce deneyinin şematik gösterimine yer verilmiştir.




Şekil 4.1. Schrödinger'in kedisi düşünce deneyi

Schrödinger'in Kedisi deneyinde, bir kutunun içerisine radyoaktif atom, bir çekiç tarafından tetiklenen bir mekanizma ve bir kedi yerleştirilmiştir. Atomun bir saat içerisinde radyoaktif bozunma olasılığı vardır. Eğer bu olasılık gerçekleşirse kutunun içine yerleştirilen mekanizma harekete geçmekte ve antikedi serumunun bulunduğu bir tüpü kırarak kediye öldürmektedir. Kutu açılmadan önce, kedinin canlı veya ölü olduğu bilinmediği için iki durumda da olduğu kabul edilmektedir. Ancak gözlem yapıldığında, kedinin bulunduğu durum tam olarak belirlenmektedir. Bu deney, kuantum mekaniğinin belirsizlik ilkesini ve süperpozisyon kavramını vurgulamak için kullanılan ve düşünce düzeyinde gerçekleştirilen bilimsel bir araştırmadır [100].

4.1.2. Çift Yarık Deneyi

Kuantum mekaniğinin önemli deneylerinden biri olan çift yarık deneyi ilk olarak Young tarafından fotonlar kullanılarak gerçekleştirilmiştir. Clinton Davisson ve Lester Germer elektronların düzenli bir yapıya çarptığında yayılan dalga benzeri desenlerinin olduğunu raporlamıştır. Bu elektronların dalga özelliklerinin bir sonucudur. Feynman ise aynı deneyi elektronlar ve fotonlarla gerçekleştirerek tek tek fotonların yerini tespit etmeyi önermiştir [118]. Young'un yaptığı deneyde, bir ışık kaynağı, iki yakın paralel yarıktan oluşan bir engelden geçirilmeye çalışılmıştır. Sonrasında, bu iki yarıktan geçen ışık dalgalarının ekranda oluşturduğu parlak ve karanlık bantlar incelenmiştir. Bu deney, ışığın hem dalga hem de parçacık özelliklerini gösteren kuantum mekaniğinin temel deneylerinden biridir [119]. Şekil 4.2'de çift yarık deneyinin gösterimine yer verilmiştir.



Şekil 4.2. Çift Yarık Deneyi

Dedektörler kullanılmadan yapılan çift yarık deneyinde, parçacıkların her iki yarıktan geçerek aralarında girişim yapması beklenmektedir. Ancak dedektörler kullanıldığında, hangi yarıktan geçtiklerini belirlemek amacıyla parçacıkların hareketleri izlenmektedir. Dedektörler, yarıklardan

geçen parçacıkları algıladığında, parçacıkların her birinin hangi yarıktan geçtiği tespit edilmektedir. Bu durumda, her bir parçacık ya bir yarıktan ya da diğerinden geçmekte ve dedektörlerin her biri bu geçişi tespit etmektedir. Sonuç olarak, parçacıkların yalnızca bir yarıktan geçtiği belirlendiği için, çift yarık deseni yerine iki tek yarık deseni oluşmaktadır. Bu durum, dedektörlerin kullanılmasıyla parçacıkların davranışlarının değiştiğini ve girişim deseninin gözlenmediğini göstermektedir. Bir foton ya da herhangi başka bir kuantum nesnesi hem parçacık hem de dalga gibi davranır. Bu da kuantum mekaniğinde ‘dalga-parçacık ikiliği’ olarak adlandırılır. Klasik fiziğe göre anlaşılması zor olan bu deneysel sonuç, kuantum mekaniği teorisiyle tutarlı olduğu için önem arz etmektedir [118].

4.2. Kuantum Mekaniği ve Kuantum Hesaplamanın Temel Kavramları

Kuantum mekaniği, atom ve atom altı parçacıkların davranışlarını inceleyen fizik dalıdır ve klasik fiziğin açıklayamadığı birçok fenomeni açıklamaktadır. Kuantum hesaplama, bu temel prensipleri kullanarak bilgi işlemeyi sağlar ve klasik bilgisayarların çözemediği karmaşık problemleri çözme potansiyeline sahiptir. Kuantum süperpozisyonu, dolanıklık, ışınlanma ve kübit gibi kavramlar, kuantum hesaplamanın temel yapı taşlarını oluşturur. Bu kavramlar sayesinde kuantum bitler aynı anda birden fazla durumu temsil edebilir ve birbirleriyle güçlü bir şekilde bağlantılı olabilir.

4.2.1. Süperpozisyon ve Paralel Evrenler

Kuantum durumlarının süperpozisyonu Schrödinger’in dalga fonksiyonlarının doğrusallığı sonucu ortaya çıkan, kuantum sistemlerinin temel ilkelerindendir. Bu denklem, kuantum mekaniğinde bir parçacığın durumunu tanımlayan doğrusal, ikinci dereceden, kısmi bir diferansiyel denklemdir. Kuantum süperpozisyonu, tüm doğrusal olarak bağımsız çözümlerin süperpozisyonunu içerir. Bu durum, klasik fizikte karşılığı olmamasına rağmen kuantum mekaniğinde oldukça önemli bir kavramdır.

Süperpozisyon kavramı, Schrödinger’in kedisi düşünce deneyi ile açıklanabilmektedir. Kutu açılmadan önce kedinin durumu hakkında hiçbir bilgiye sahip olunamaz. Yani kedinin hem yaşayan hem de ölü olduğunu düşünülmektedir. Bu durumda kedi süperpozisyon halindedir, yani hem yaşam hem de ölüm durumlarından oluşan bir kombinasyondadır. Ancak odanın içine bakarak ölçüm yapana kadar, kedinin durumu belirsizdir ve süperpozisyon devam eder. Süperpozisyonu açıklayan bir diğer deneyde çift yarık deneyidir. Bu deneyde ise bir ışık demeti iki yarıktan geçerken, her foton hem birinci hem de ikinci yarıktan geçer gibi davranmaktadır. Bu durum, fotonun süperpozisyon halinde olduğunu ve her iki yarıktan geçerek kendisiyle girişim yaptığını gösterir. Süperpozisyon durumu, ölçüm yapıldığında çöker ve parçacığın belirli bir durumu almasına neden olur [120].

ψ , fotonun kuantum davranışını tam olarak açıklayan Schrödinger dalga fonksiyonudur. İki durumlu bir kuantum sistemi, karmaşık iki boyutlu bir Hilbert uzayında bir vektör olarak temsil edilebilir. $|\mu\rangle$ ve $|\nu\rangle$ Hilbert uzayının temel vektörlerini temsil eder. Bu durumda kübit gösterimi Denklem 4.1'deki gibidir.

$$|\psi\rangle = \alpha|\mu\rangle + \beta|\nu\rangle \quad (4.1)$$

α ve β karmaşık olasılık genliklerini temsil etmektedir. $|\mu\rangle$ ve $|\nu\rangle$, kübitlerin temel durumlarını ifade etmektedir. Genellikle, hesaplama temeli olarak $|0\rangle = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ ve $|1\rangle = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$ durumları kullanılmaktadır. Bir kuantum durumu Denklem 4.2'deki gibi ifade edilir.

$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle = \begin{pmatrix} \alpha \\ \beta \end{pmatrix} \quad (4.2)$$

Dalga fonksiyonu ile olasılık genliği arasındaki bağlantıyı ortaya koyan bu denklem ile $|0\rangle$ ve $|1\rangle$ 'in kuantum süperpozisyonunu gösterir. Ancak kuantum süperpozisyonu ölçülmeye çalışıldığı durumda 0 veya 1 gibi klasik bir sonuç elde edilir. Bu sonuçların olasılıkları ise $|\alpha|^2$ ve $|\beta|^2$ ile orantılıdır. Daha basit ifadesiyle kuantum durumu belirlenmeye çalışıldığında, klasik bir bitin ölçümü ile sonuçlanır. Ölçümlerin olasılıksal sonucu Denklem 4.3'de gösterilmiştir.

$$1 = |\alpha|^2 + |\beta|^2 \quad (4.3)$$

Kuantum süperpozisyonu aynı anda birden fazla durumda bulunmayı sağlamaktadır. Bu da kuantum paralellliğini mümkün kılar. n kübitin her biri iki boyutlu Hilbert uzaylarında ($H_0, H_1, \dots, H_{n-1}$) bulunur. Bu kübitler, birbirleriyle etkileşim olmadan hazırlanmışsa, matematiksel olarak tensör çarpımı ile tanımlanır. Bu tensör çarpımına ait gösterim Denklem 4.4 ile verilmiştir.

$$|\psi_0\rangle \otimes |\psi_1\rangle \otimes \dots \otimes |\psi_{n-1}\rangle \in H_0 \otimes H_1 \otimes \dots \otimes H_{n-1} \quad (4.4)$$

Bu, tüm kübitlerin birleşik durumunu tanımlar ve bu da kuantum hesaplamalarda büyük bir avantaj sağlar.


4.2.2. Dolanıklık ve Kuantum İletişimi

Kuantum mekaniğinin temel özelliklerinden biri olan kuantum dolanıklığı, kuantum fenomenlerini matematiksel olarak açıklamak için kullanılan ve belirli kurallar setine dayanan bir yaklaşımdır. Bu kavram Einstein, Podolsky ve Rosen'in ERP paradoksuna ve Bell'in eşitsizliklerine dayanmaktadır. Schrödinger dolanıklığı, aralarında bilinen güçler nedeniyle birbiri ile etkileşime giren sistemlerin ayrıldığında artık eskisi gibi olamayacağı şeklinde tanımlanmıştır [121]. Eğer birbiri ile geçmişte etkileşim halinde olan iki sistem varsa, genellikle bu iki alt sistemin her birine tek bir durum vektörü atamak mümkün değildir. Yani bu sistemlerin bireysel durumları birbirlerinden bağımsız olarak tanımlanamayacağı için sistemlerin bireysel durum vektörleri kullanılamaz. Ayrılmazlık ilkesi

olarak da adlandırılan bu durum, iki sistemin ayrılamaz şekilde birbirine bağlı olmasını ifade etmektedir. Dolaşık bir durumun yaygın bir örneği singlet durumudur. Singlet durumunun matematiksel gösterimine Denklem 4.5’de yer verilmiştir [122].

$$\psi = \frac{1}{\sqrt{2}}(|01\rangle - |10\rangle) \quad (4.5)$$

İki parçacığın durumlarının birbirine bağlı olduğunu gösteren bu denklem, birleşik sistemin durumu olarak tanımlanmaktadır. Şekil 4.3’de birbiri ile dolanık olan bir sistemin basit bir gösterimine yer verilmiştir.



Şekil 4.3. Kuantum dolanıklığı

4.2.3. Kuantum Işınlanma

Kuantum ışınlanma, maddesel ışınlanmadan ziyade bilgi aktarımı olarak tanımlanmaktadır. Klasik bilgilerin kolayca kopyalanabildiği halde, kuantum dünyasında bir kübitin tam olarak kopyalanması mümkün değildir. Bu durum bilinmeyen bir kuantum durumunun ölçülmesinin sınırlarını belirler. Kuantum durumunu kopyalama işlemi, durumun ölçülmesini gerektirir ve ölçüm kuantum durumu değiştirmektedir. 1993 yılında Bennett vd., bir kuantum durumunun bir yerden başka bir yere aktarılmasının ERP çiftleri kullanılarak mümkün olduğunu ortaya koymuştur. Bu süreçte Alice (mesajı gönderen kişi), paylaşılan dolaşık parçacıklar üzerinde bir Bell durumu ölçümü yapar ve sonucu Bob’a gönderir. Bob (mesajı alan kişi), aldığı bu klasik bilgiyi kullanarak, orijinal kuantum durumunu kendi parçacığı üzerinde yeniden oluşturur.

Bu işlemin temelinde, kuantum dolanıklığı yer alır. Dolanıklık, iki parçacık arasında mesafe ne olursa olsun devam eden güçlü bir bağlantı kurar. Dolanıklık, fiziksel bir kaynak olarak önceden dağıtılabılır ve bu durum ışınlanmanın mesafeler arasında etkili olmasını sağlamaktadır. Ancak bu süreç, anlık bilgi aktarımı sağlamaz çünkü Bob, Alice’in ölçüm sonuçlarına ihtiyaç duyar; bu bilgiye erişmeden, Bob yalnızca karışık bir duruma sahip olur. Ayrıca, ışınlanma süreci kuantum klonlama teoremini ihlal etmez. Çünkü Alice’in yaptığı Bell durumu ölçümü sonucunda, orijinal parçacığın bilgisi tamamen yok olur. Heisenberg’in Belirsizlik İlkesi ve kuantum ölçüm teorisine

göre, bir kuantum sistemini ölçmek, sistemin durumunu kaçınılmaz olarak değiştirmektedir. Bu sayede, ışınlanma işlemi hem güvenli hem de kuantum mekanik prensiplerine uygun bir şekilde gerçekleşir [121].

4.2.4. Hilbert Uzayı

Hilbert uzayı kompleks bir vektör uzayıdır ve öklidyen uzayların sonsuz boyutlu uzaylara genellemesi şeklinde tanımlanmaktadır. Kuantum mekaniğinde, fiziksel sistemlerin temsili için Hilbert uzayında bulunan vektörler kullanılmaktadır. Bu vektör, sistemin olası tüm durumlarını içeren durum vektörleri olarak tanımlanır ve bir iç çarpım yapısına sahiptir. İç çarpım, iki vektör arasındaki mesafeyi ve ilişkileri tanımlamayı sağlamaktadır. Genellikle sonsuz boyutlu uzaylar için kullanılır. Ancak günümüzde sonlu boyutlu uzayları da içerecek şekilde genişletilmiştir [123].

Bir iç çarpım V üzerinde tanımlanan bir fonksiyon olup $\langle, \rangle: V \times V \rightarrow \mathbb{C}$ şeklinde gösterilir. Bu fonksiyon, $u, v, w \in V$ ve $\lambda \in \mathbb{C}$ için aşağıdaki özellikleri sağlar: Denklem 4.6'da u ile v arasındaki iç çarpımın simetrik olduğunu ve v ile u arasındaki iç çarpımın karmaşık eşleniğine eşit olduğunu ifade etmektedir [124].

$$\langle u, v \rangle = \overline{\langle v, u \rangle} \quad (4.6)$$

Denklem 4.7'de ki gösterim, bir vektörle bir skaler (λ) çarpıldığında, bu skalerin iç çarpımın dışına çıktığını göstermektedir.

$$\langle \lambda u, v \rangle = \lambda \langle u, v \rangle \quad (4.7)$$

Denklem 4.8'de iki vektörün toplamının başka bir vektörle olan iç çarpımının, bu iki vektörün ayrı ayrı iç çarpımlarının toplamına eşit olduğunu belirtmektedir.

$$\langle u + v, m \rangle = \langle u, m \rangle + \langle v, m \rangle \quad (4.8)$$

Denklem 4.9'da bir çarpımın bir vektör ile kendisi arasındaki değeri her zaman sıfır veya sıfırdan büyüktür ifadesi yer almaktadır.

$$\langle u, v \rangle \geq 0 \text{ ve } \langle v, v \rangle = 0 \Leftrightarrow v = 0 \quad (4.9)$$

İç çarpım uzayındaki en önemli eşitsizliklerden biri olan Cauchy-Schwarz eşitsizliği, herhangi bir u, v vektörü için Denklem 4.10 ile ifade edilir:

$$|\langle u, v \rangle| \leq \|u\| \|v\| \quad (4.10)$$

Eşitlik, u ve v vektörleri lineer olarak bağımlı olduğunda ve u vektörü 0 vektörü olmadığında sağlanır. Vektörlerinin normlarını göstermek için $\|u\|$ ve $\|v\|$ kullanılmaktadır. Hilbert uzayı, iç

çarpımı olan ve bu iç çarpıma dayalı olarak tanımlanan bir vektör uzayıdır. Hilbert uzayının en basit örneği olan C_n ve iç çarpımı $x=(x_1, x_2, x_3, \dots, x_n)$ ve $y=(y_1, y_2, y_3, \dots, y_n)$ için Denklem 4.11'de verilmiştir [124].

$$\langle x, y \rangle = \sum_{i=1}^n x_i \bar{y}_i \quad (4.11)$$

Sonsuz boyutlu vektörlerin bir araya geldiği yapılar, Hilbert uzayı olarak adlandırılmaktadır. Hilbert uzayı, iç çarpım uzaylarının genelleştirmesi olup tüm temel özelliklerini içermektedir. Kuantum bilgisayarlar, işlemleri gerçekleştirirken genellikle Hilbert uzayındaki vektörleri kullanmaktadır. Hilbert uzayı, kuantum mekaniği ve kubitlerin matematiksel yapılarının anlaşılmasında önemli bir rol oynamaktadır. Kubitlerin durumunu temsil etmek için genellikle Hilbert uzayındaki vektörler kullanılmaktadır.

4.2.5. Kuantum Bit (Kübit)

Kuantum bilişim, geleneksel hesaplama paradigmalarını aşarak daha hızlı ve verimli bilgi işlem olanakları sunmayı hedeflemektedir. Kuantum bit veya kısaca 'kübit', kuantum bilişimin temel yapı taşıdır. Klasik bitlerin aksine, kübitler aynı anda hem 0 hem de 1 durumunda olabilir; bu özellik 'süperpozisyon' olarak adlandırılır. Ayrıca, kübitler 'dolaşıklık' adı verilen bir fenomen ile birbirine bağlanabilir ve bu da, kübitlerin durumlarının birbirine bağlı olmasını sağlar. Bu ilkeye dayanarak, kuantum bilgisayarlar geleneksel bitler yerine kübitleri kullanır. Kübitler, dönüş (spin) yönüne bağlı olarak 0 ile 1 arasında sonsuz sayıda değere sahip olabilirler. Bu özellikler, kuantum bilgisayarlarının belirli problemleri klasik bilgisayarlardan çok daha hızlı çözmesini mümkün kılmaktadır [125].

Kuantum sisteminin durumları vektörlere karşılık gelir. Bir kuantum bitinde, 0 kuantum mantık durumu, iki boyutlu $\begin{pmatrix} 1 \\ 0 \end{pmatrix}$ vektörüne, 1 kuantum mantık durumu ise $\begin{pmatrix} 0 \\ 1 \end{pmatrix}$ vektörüne karşılık gelir.

Bu vektörler 'dirac bracket' gösterimi ile $|0\rangle \equiv \begin{pmatrix} 1 \\ 0 \end{pmatrix}$, $|1\rangle \equiv \begin{pmatrix} 0 \\ 1 \end{pmatrix}$ şeklinde ifade edilmektedir. Dirac bracket, kuantum mekaniğinde kullanılan bir notasyon sistemidir ve kuantum durumlarını ve operatörlerini ifade etmek için kullanılır.

Bir kübit için genel durum, $|\psi\rangle$, $\begin{pmatrix} \alpha \\ \beta \end{pmatrix}$ vektörüne karşılık gelir ve $\alpha|0\rangle + \beta|1\rangle$ şeklinde gösterilir.

Bu gösterimdeki α ve β , $|\alpha|^2 + |\beta|^2 = 1$ şartını sağlayan karmaşık sayıları ifade etmektedir. Bir vektörün bileşenlerinin karelerinin toplamının bir'e eşit olması gerekliliğine 'normallik' denir. Normallik (normalization), kuantum mekaniğinde genliklerin karelerinin olasılıklarla ilişkili olması nedeniyle ortaya çıkar. Özellikle, bir kübitin $|\psi\rangle$ durumunda hazırlandığını ve ardından bu kübitin 0 veya 1 değerini alıp almadığını belirlemek amacıyla bir ölçüm yapıldığını varsayıldığında, bir ölçüm, $|\alpha|^2$ olasılığı ile 0 sonucunu ve $|\beta|^2$ olasılığı ile 1

sonucunu verecektir. Bu olasılıkların toplamı bir olmalıdır. Buna karşılık gelen satır vektörleri denklem 4.12’de ki gibi gösterilmektedir.

$$\langle 0| \equiv (1 \ 0), \langle 0| \equiv (0 \ 1), \langle \psi| \equiv (\bar{\alpha} \ \bar{\beta}) \quad (4.12)$$

Kübit için iki boyutlu, kompleks vektör uzayı C^2 olarak adlandırılır. Dirac braket notasyonunun tanıtılmasının nedeni, bu vektör uzayının, kuantum mekaniğindeki tüm vektör uzayları gibi, doğal bir iç çarpıma sahip olmasıdır. İç çarpım, denklem 4.13’de ki gibi satır vektörleri ile sütun vektörlerinin çarpımı olarak tanımlanmaktadır.


$$|\psi\rangle = \begin{pmatrix} \alpha \\ \beta \end{pmatrix} \text{ ve } |\phi\rangle = \begin{pmatrix} \gamma \\ \delta \end{pmatrix} \quad (4.13)$$

$\langle \phi| = (\bar{\gamma} \ \bar{\delta})$ burada satır vektörleri $\langle \phi|$ ‘bra’ vektörünü, sütun vektörleri $|\psi\rangle$ ‘ket’ vektörünü temsil etmektedir. Ket, kuantum durumlarını ifade etmek için kullanılır. Bra ise ‘ket’in duali olarak bilinir. Bir bra ve ket’in iç çarpımını $\langle \phi|\psi\rangle$ şeklinde yazılır. Bu, $|\phi\rangle$ durumunun $|\psi\rangle$ durumuyla olan iç çarpımını temsil eder.

$$\langle \phi|\psi\rangle = (\bar{\gamma} \ \bar{\delta}) \begin{pmatrix} \alpha \\ \beta \end{pmatrix} = \bar{\gamma}\alpha + \bar{\delta}\beta \quad (4.14)$$

Bu iç çarpım, kuantum durumlarının olasılık genliklerini ve diğer önemli özelliklerini hesaplamak için kullanılmaktadır. İç çarpımın $\langle \psi|\psi\rangle = |\alpha|^2 + |\beta|^2 = 1$ tanımı, kübitler için vektör uzayını Hilbert uzayına dönüştürmektedir [126].

Kübitler Bloch Küresi ile gösterilir ve bu küre üzerindeki her noktada bulunma olasılığına sahip bir dizi durumu içermektedir. Bir kübitin bloch küresi üzerindeki durumu Şekil 4.4’te gösterilmektedir.



Şekil 4.4. Bloch küresi üzerinde bir kübit’in durumu

Bloch küresine göre γ, θ, ϕ reel sayılar olmak üzere bir kübit, Denklem 4.15'te verildiği gibi ifade edilmektedir.




$$|\psi\rangle = e^{i\gamma} \left(\cos\left(\frac{\theta}{2}\right) |0\rangle + e^{i\phi} \sin\left(\frac{\theta}{2}\right) |1\rangle \right) = e^{i\gamma} \begin{pmatrix} \cos\left(\frac{\theta}{2}\right) \\ e^{i\phi} \sin\left(\frac{\theta}{2}\right) \end{pmatrix} \quad (4.15)$$

Bloch küresindeki bir noktanın yerini $0 \leq \theta \leq \pi$ aralığındaki yükseltiyi, $0 \leq \phi \leq 2\pi$ aralığı ise azimut açıları ile verilmektedir. $e^{i\gamma}$ ile global faz vektörü ifade edilmektedir. Bu faz vektörünün gözlemlenebilir bir özelliği bulunmamaktadır. $|0\rangle$ ve $|1\rangle$ vektörleri arasında bulunan faz vektörleri ise gözlemlenebilirdir ve kübitle alakalı bilgilerin alındığı vektörlerdir [127].

4.2.6. Kuantum Mantık Kapıları

Kuantum mantık kapıları klasik mantık kapıları benzeri özellikler taşımaktadır. Ancak kuantum mekaniğinin özelliklerini kullanarak çalışmaktadır. Tek kübit işlemler, Bloch küresi üzerindeki bir kuantum durumunu belirli bir eksen etrafında belli bir açıyla döndürerek başka bir konuma taşır. Bir matrisle ifade edilir ve bu matris, X, Y, Z operatörlerinin özvektörlerine dayalı hesaplama temelindeki kuantum işlemi tanımlar. Bu, kübitlerin durumu ve davranışını belirleyen matematiksel bir temsildir. Bu matrisler, kübitlerin Bloch küresi üzerindeki dönüşlerini ve durum değişimlerini yönetir, bu da kuantum bilgisayarlarının işleyişinin temelini oluşturur. İki ve daha fazla kübit kullanılan kapılarda ise bir kontrol kübiti kullanarak belirli bir birim işleminin bir hedef kübite uygulanıp uygulanmayacağını belirlenmektedir. Klasik bir mantık kapısında kontrol biti (C) eğer 0 ise kapı hiçbir işlem yapmazken, 1 olduğu durumda belirli bir işlemi gerçekleştirmektedir. Tıpkı klasik mantık kapılarında olduğu gibi kuantum mantık kapılarında da bir hedef kübitte işlemlerin gerçekleştirilebilmesi için kontrol kübiti kullanılmaktadır. Tablo 4.1'de tek ve çoklu kübitler için kullanılan kuantum mantık kapılarına yer verilmiştir [128].

Tablo 4.1. Kuantum mantık kapıları

	Operatör	Devre Temsili	Matris
Tek Kübit Kuantum Kapıları	Birim (I)		$\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$
	Pauli-X		$\begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$
	Pauli-Y		$\begin{bmatrix} 0 & -i \\ i & 0 \end{bmatrix}$

	Operatör	Devre Temsili	Matris
Tek Kübit Kuantum Kapıları	Pauli-Z		$\begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$
	Hadamard (H)		$\frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}$
	Faz (S,P) ($\sqrt{Z}$, $P(\frac{\pi}{2})$)		$\begin{bmatrix} 1 & 0 \\ 0 & i \end{bmatrix}$
	$\frac{\pi}{8}$ (T)		$\begin{bmatrix} 1 & 0 \\ 0 & e^{i\pi/4} \end{bmatrix}$
Çoklu Kübit Kuantum Kapıları	Kontrollü Değil (CNOT)		$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$
	Kontrollü Z (CZ)		$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & -1 \end{bmatrix}$
	Kontrollü Faz (CS)		$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & i \end{bmatrix}$
	Toffoli (CCNOT, CCX, TOFF)		$\begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}$

4.3. Kuantum Makine Öğrenmesi

Makine öğrenimi, verilerden desenler çıkararak bilinmeyen girdileri anlamlandıran bir bilgisayar bilimi dalıdır. Yapay zeka ve istatistiklerin bir parçası olarak, görüntü ve konuşma tanıma, desen tanımlama ve strateji optimizasyonu gibi görevlerde kullanılır. Önemli uygulamaları arasında Google'ın PageRank algoritması, spam e-posta filtreleri, güvenlik sistemleri, tüketici davranışlarının analizi ve finansal risk değerlendirmesi bulunur. Kısacası, makine öğrenimi, bilgisayarların büyük miktarda veriyi deneyimlere dayanarak yorumlamasına yardımcı olur. Ancak hesaplama gücü eksikliği nedeniyle bu algoritmaların kullanımı kısıtlanmaktadır.

Dünya genelinde veri depolama hacmi her yıl %20 artarak birkaç yüz eksabayt düzeyine ulaşmıştır, bu durum makine öğrenimi için yenilikçi yaklaşımlar bulma ihtiyacını artırmaktadır. Grafik işleme birimleri ve tensör işleme birimleri gibi özel donanım mimarilerinin kullanımı mevcut hesaplama araçlarının performansını önemli ölçüde arttırırsa da bu soruna yapısal bir çözüm sunamamaktadır.

Bu nedenle, son yıllarda hem akademide hem de önde gelen BT şirketlerinde klasik makine öğrenimi algoritmalarını optimize etmek için kuantum hesaplamanın potansiyelini araştıran çalışmalar artmıştır [129].

Kuantum Hesaplama, bilgisayar bilimi, matematik ve fiziği birleştiren iddialı bir yeni alandır. Bu alan, aynı anda üst üste 0 ve 1 kombinasyonları içerebilen kuantum bitlerinden (kübitler) yararlanan kuantum bilgisayarları oluşturmak için kuantum fiziğinin bazı özel özelliklerini kullanmanın yollarını araştırır [130]. Kuantum bilgisayarlar, fizikçilerin bilgi işleme için gösterdiği etkileyici özellikleri kullanarak, klasik bilgisayarların aksine bir kübitin iki kuantum durumunun üst üste binmesini avantaja çevirmektedir. Ancak, kuantum mekaniğinin yasaları, kuantum sistemlerinde depolanan bilgilere erişimi kısıtlamakta ve klasik yöntemlerden daha iyi performans gösteren kuantum algoritmalarını bulmayı zorlaştırmaktadır. Kuantum hesaplamanın teknolojik uygulamalarının ortaya çıkmasıyla, teorik önerilerin gerçek makinelerde test edilebilmesi sağlanmaktadır. Bu bağlamda, kuantum makine öğrenimi (QML), akıllı veri işleme alanında devrim yaratma potansiyeline sahiptir [129].


Kuantum mekaniğinin verilerde alışılmadık desenler oluşturduğu bilinmektedir. Derin sinir ağları gibi klasik makine öğrenme yöntemleri, genellikle verilerdeki istatistiksel desenleri tanıma ve bu desenlere sahip veriler üretme yeteneğine sahiptirler: yani, tanıdıkları desenleri üretebilirler. Bu durum, küçük kuantum bilgi işlemcilerinin klasik bilgisayarların hesaplama açısından zorlandığı istatistiksel desenleri üretebilmesi durumunda, klasik bilgisayarların tanımakta zorlandığı desenlerin de kuantum sistemleri ile tanımlanabileceği ihtimalini ortaya çıkarmıştır.

Kuantum algoritmaları, iki grafiğin izomorfik olup olmadığını belirlemek gibi belirli problemleri çözmek için kuantum bilgisayarlarda uygulanabilen talimat dizileridir. Kuantum makine öğrenimi yazılımı, bu algoritmaları daha büyük uygulamaların bileşeni olarak kullanır. Kuantum algoritmalarının adımları analiz edildiğinde, klasik algoritmalara kıyasla belirli problemleri daha etkin bir şekilde çözme potansiyelleri, yani gereken işlem sayısını azaltma yeteneği ortaya çıkmaktadır. Bu potansiyel ‘kuantum hızlandırma’ olarak tanımlanmaktadır. ‘Kuantum hızlandırma’ kavramı, iki farklı bakış açısından değerlendirilebilir. Birincisi, matematiksel kanıtlar gerektiren resmi bir bilgisayar bilimi perspektifidir. İkincisi ise, belirli bir problem boyutunda ölçekleme avantajının istatistiksel kanıtlarını gerektiren, gerçekçi ve sonlu boyutlu aygıtlarla neler yapılabileceğine dayalı bir yaklaşımdır [131].

Kuantum hesaplamaındaki hızlandırmaların temelinde, kuantum süperpozisyonunda bilgi işleme yeteneği yer almaktadır. Makine öğrenimi büyük miktarda veriyi analiz etmeyi içerdiğinden, verilerin kuantum süperpozisyonuna nasıl dönüştürüleceği önemli bir konudur. İki tür algoritma arasında ayırım yapmak gerekmektedir: kuantum verileri üzerinde çalışan algoritmalar ve klasik bellekte depolanan verileri işlemeyi amaçlayan algoritmalar. İlk durum, kuantum makine öğrenimi için daha kolay bir problemdir çünkü veriler analiz edilmeye hazırdır ve bu verileri kuantum

biçimine dönüştürmek için ek hesaplama kaynakları gerektirmez. İkinci durumda ise, klasik bilgileri kuantum durumuna kodlayan bir prosedür gerektiği için süreç daha karmaşıktır. Bu işlemin hesaplama maliyeti, klasik veriler için ML’de kuantum hızlandırmaların elde edilip edilemeyeceğini belirlemek açısından kritik öneme sahiptir [132].

Kuantum makine öğrenimi alanında yapılan çalışmalar, bu teknolojinin veri işleme kapasitesini ve hızını artırma potansiyeline sahip olduğunu göstermektedir. Örneğin, kuantum bilgisayarların büyük veri setleri üzerinde daha hızlı ve etkili analizler yapabileceği öngörülmektedir. Bu, özellikle karmaşık veri setlerinin incelenmesi gereken alanlarda büyük avantajlar sağlayabilir. Bununla birlikte, QML’nin yaygınlaşması için aşılması gereken çeşitli zorluklar da bulunmaktadır. Bu zorluklar arasında kuantum bilgisayarların güvenilirliği, hata düzeltme mekanizmaları ve kuantum algoritmalarının geliştirilmesi gibi teknik engeller yer almaktadır. Ayrıca, kuantum bilgisayarların maliyeti ve erişilebilirliği de önemli bir konudur. Bu zorluklara rağmen, mevcut kuantum makine öğrenme algoritmaları, klasik makine öğrenimi algoritmalarına benzer şekilde çalışmakta ancak kuantum bilgi işlem gücünden yararlanarak daha karmaşık ve hızlı çözümler üretebilmektedir. Klasik makine öğrenme yöntemlerinde, veriler doğrudan algoritmalara giriş olarak verilir, algoritmalar tarafından veriler analiz edilir ve bir çıktı üretilir. Ancak kuantum makine öğrenme algoritmalarında bu süreç klasik verilerin özellik haritaları yardımıyla kuantum algoritmalarında kullanılacak bir dönüşüme tabi tutulması ile başlar. Gerçekleştirilen bu dönüşüm işlemi verilerin bit formundan kübit formuna dönüştürülmesi işlemidir ve veri kodlama olarak adlandırılmaktadır. Kuantum algoritmaları, kübit formundaki verileri alır, işler ve kuantum verileri olarak çıktı üretir. Son aşamada ise veriler kuantum halinden klasik verilere dönüştürülür. Şekil 4.5’te klasik makine öğrenme yöntemlerinin genel mimarisi ile QML mimarisine yer verilmiştir [130].



Şekil 4.5. Klasik makine öğrenimi ve kuantum makine öğreniminin aşamaları

Kuantum tabanlı makine öğrenme algoritmalarından bazıları şunlardır: Kuantum Destek Vektör Makinesi (QSVM), Kuantum K-En Yakın Komşu (Q-KNN), Kuantum Sinir Ağları (Quantum Neural Network, QNN), VQC ve Pegasus Kuantum Destek Vektör Makinesi. Bu algoritmalar, kuantum bilgi işlem gücünden yararlanarak daha karmaşık ve hızlı çözümler üretmekte, klasik makine öğrenme algoritmalarına kıyasla önemli avantajlar sunmaktadır.

QSVM, klasik olarak sağlanan verilerin analizi için kuantum durum uzayını bir özellik uzayı olarak kullanan bir sınıflandırıcı türüdür. Kuantum hesaplama özelliklerini kullanan SVM algoritmasının dönüştürülmüş bir versiyonudur. Bu algoritmanın kuantum sistemlerinde kullanılabilmesi için, klasik verilerin kuantum durumuna doğrusal olmayan bir şekilde haritalanması gerekmektedir. Kuantum durumlarına haritalama, özelliklerin kübit formunda kodlanmasıyla gerçekleştirilir. Bu işlemi gerçekleştirmek için, kuantum haritaları başlangıç durumuna uygulanır. Sonuç olarak, bu yöntem kullanılarak bir çekirdek kuantum devresi oluşturulur. Bu, verilerin yüksek boyutlu alanlarda sınıflandırılmasını sağlar. Her kuantum haritası farklı çekirdeklerle sonuçlanır, dolayısıyla sınıflandırma performansını etkiler. Son adımda, doğrusal olmayan bir çekirdek kullanılarak bir hiper düzlem oluşturularak veriler sınıflandırılır [13].

Kuantum K-En Yakın Komşu (Q-KNN) algoritması, klasik KNN algoritmasının kuantum hesaplama uyarlanmış bir versiyonudur. Q-KNN, zaman karmaşıklığını azaltmak için kuantum hesaplamanın avantajlarından yararlanır. Q-KNN, veriler arasındaki en yakın komşuları belirlemek için Grover'in kuantum arama algoritmasını kullanır. Bu sayede, Q-KNN, klasik KNN algoritmasına kıyasla üstel hızlanma sağlayarak daha yüksek performans gösterir [133].

Kuantum sinir ağları (QNN) kuantum mekaniği ve sinir ağları arasında bağlantı sonucu ortaya çıkan kuantum tabanlı bir makine öğrenme algoritmasıdır. Bu iki alanın ana kavramları, kuantum

mekanikinde kuantum durumlar, süperpozisyon, dolaşıklık, kuantum ölçüm ve kuantum geçiş olasılıkları; sinir ağlarında ise yapay sinir hücreleri, bağlantı ağırlıkları, aktivasyon fonksiyonları, öğrenme algoritmaları ve bilgi işlem süreçleri gibi temel prensipler olarak değerlendirilebilir. Yapay sinir ağları, analizleri gerçekleştirmek için nöronlardan yararlanırken, kuantum sinir ağları sonuçları elde etmek için kübitleri ve aktivasyon fonksiyonu olarak kuantum kapılarını kullanır. Bu sayede, QNN'ler, kuantum hesaplamanın benzersiz özelliklerinden faydalanarak daha verimli ve etkili analizler gerçekleştirebilir [134].

Kuantum makine öğrenme algoritmaları, klasik algoritmalara kıyasla daha hızlı ve etkili çözümler sunma potansiyeline sahiptir. Ancak, bu algoritmaların tam anlamıyla uygulanabilmesi için gerekli olan teknik engellerin aşılması gerekmektedir. Gelecekte, kuantum makine öğrenimi alanındaki gelişmeler, veri işleme ve analizinde devrim yaratabilir ve bu da birçok alanda önemli değişikliklere yol açabilir.

4.3.1. Kuantum Özellik Haritaları

Kuantum özellik haritaları, klasik formdaki verilerin kuantum ortamlarında işlenebilmesi için kuantum bit şekline dönüştüren yapılardır. Dönüşüm işlemi gerçekleştirilirken veriler Hilbert uzayında kodlanmaktadır. Özellik haritaları oluşturulurken farklı kuantum kapılarının yer aldığı devre sistemleri kurulmaktadır. Bu devreler sayesinde kübite dönüştürülen veriler QML algoritmalarında kullanılabilir hale gelir [135]. Özellik haritası seçiminde kullanılan temel faktörler şunlardır; özellik haritası devre derinliği, klasik verilerin kodlanmasında kullanılan veri eşleştirme, kuantum kapıları ve ikili kübit kombinasyonlarının işleme sırasıdır [136]. Genel olarak bilinen üç temel özellik haritası bulunmaktadır. Bunlar ZZ, Z ve Pauli özellik haritaları olarak bilinir.

ZZ Özellik Haritası

ZZ özellik haritası, ikinci dereceden bir Pauli-Z devresi olarak tanımlanmaktadır. Hadamart ve CNOT kapıları kullanılarak oluşturulmaktadır. Hadamart kapısı klasik verilerin süperpozisyon durumunun oluşturulması için oluşturulmaktadır. Süperpozisyon durumunda ki veriler CNOT kapısında dolanıklığa girmeden önce kübitler arası ilişkilerin belirlenmesi gerekmektedir [137]. Kübitler arasındaki etkileşimi belirlemek için


$$P(i, j) = \theta_{ij} * Z_i * Z_j \quad (4.16)$$

şeklinde bir denkleme sahip olan P fonksiyonu kullanılır [136]. Burada θ_{ij} ile i ve j kübitleri arasındaki etkileşim katsayısı belirlenir. Z_i ve Z_j olarak verilen değişkenler ile i ve j kübitlerinin kuantum kapısına kodlanmış durumları verilmektedir. Daha sonra CNOT kapısında, kontrol ve hedef kübitlere göre kübit çiftleri arasındaki durum belirlenir.

2 öznitelikle oluşturulan ZZ özellik haritasına ait devrenin Qiskit'te verilen karakteristik gösterimi

$$ZZFeaureMap(feature_dimension=2, reps=1, entanglement=linear)$$

şeklindedir [138]. Burada 'reps' olarak verilen parametre oluşturulan devrelerin tekrar sayısını ifade ederken, 'entanglement' parametresi kubitlerin dolanıklık durumu belirtmektedir. Bu parametre 'linear', 'full' ve 'circular' olmak üzere üç değer almaktadır. Parametrenin 'linear' olarak belirlenmesi, her bir kubitin sırasıyla kendisinden sonraki kubit ile dolaşıklığa gireceğini belirtmektedir. Dolanıklığın 'full' seçildiğinde, kubitler rastgele ve karmaşık bir şekilde birbirleriyle dolanıklık oluşturur. 'Circular' seçildiğinde ise, kubitler bir halka şeklinde sıralanır ve her kubit ardışık olarak bir sonraki kubit ile dolanıklık oluşturur; bu durumda, son kubit de birinci kubit ile dolanıklık oluşturur. ZZ özellik haritasına ait devre modeli Şekil 4.6'da verilmektedir.




Şekil 4.6. ZZ özellik haritası devre çizimi

Burada H ile gösterilen temsil Hadamart kapsını ifade etmektedir. P ile öznitelikler arası ilişkinin belirlendiği fonksiyon gösterilmektedir. $\text{---} \oplus \text{---}$ ifadesi ile CNOT kapısı belirtilmektedir.

Z Özellik Haritası

Birinci derecen bir Pauli Z devresidir. Bu özellik haritasına ait genel yapı Şekil 4.7'de verilmektedir.



Şekil 4.7. Z özellik haritasının gösterimi

Z özellik haritasının Qiskit ortamında genelleştirilmiş gösterimi;

$$ZFeatureMap(feature_dimension = 2, reps=1)$$

şeklindedir [139]. Şekil 4.7'de verilen devre modelinin parametre özellikleri Z özellik haritası içerisindeki değerlerdir. Z özellik haritası içerisinde 'entanglement' parametresinin olmadığı

görülmektedir. Bu da dolanıklığa ait herhangi bir işlemin yapılmadığını göstermektedir. Z özellik haritası daha basit yapıdaki veri setlerinin kullanımına uygun bir haritadır.

Pauli Özellik Haritası

Özellik haritalarının en genel hali olan Pauli devresi, Z ve ZZ formlarının olmasının dışında farklı kapı kombinasyonları kullanılarak verilere ve problemlere durumuna göre çeşitli özellik haritalarının oluşturulmasına olanak sağlar. Kübitler arasındaki etkileşimleri oluşturmak ve ilişkileri belirlemek için kullanılan temel iki parametresi vardır [140].

$$\text{PauliFeatureMap}(\text{feature_dimension}=2, \text{reps}=1, \text{entanglement}='full', \text{paulis}=\text{None}, \dots)$$

ile verilen ‘paulis’ parametresi seçilecek olan operatörü belirlemek için kullanılır. Pauli operatörleri olarak bahsedilen değişkenleri kuantum kapılarından oluşturmaktadır [141]. Bu kapıların verilerin özelliklerine göre farklı birleşimleri ile oluşturulan Pauli devreleri belirlenen dolanıklık niteliğine göre kodlanır.

Bir Pauli devresi dönüşümü [140] oluşturmak için $\vec{x} \in \mathbb{R}^n$ giriş verileri, n ise özellik boyutu (feature_dimension) olmak üzere

$$U_{\Phi\vec{x}} = \exp\left(i \sum_{S \in I} \phi_S(\vec{x}) \prod_{i \in S} P_i\right) \quad (4.17)$$

verilmektedir. Burada S ile özellik haritasında tanımlanan bağlantıları veren bir kübit indeks kümesini ifade edilir. I, verilen tüm indeks kümelerini içeren genel bir kümedir. P_i ise I, X, Y ve Z kapılarını içeren bir küme olarak tanımlanmaktadır. ϕ_S ise

$$\phi_S(\vec{x}) = \begin{cases} x_i & \text{eğer } S = \{i\} \\ \prod_{j \in S} (\pi - x_j) & \text{eğer } |S| > 1 \end{cases} \quad (4.18)$$

ile verilen özellik haritalama işlemini gerçekleştirmek için kullanılır.

4.3.2. Kuantum Destek Vektör Makinesi

QSVM, klasik olarak sağlanan verilerin analizi için kuantum durum uzayını bir özellik alanı olarak kullanan bir sınıflandırıcı türüdür. Bu algoritma, SVM algoritmasının kuantum hesaplama özellikleri kullanılarak dönüştürülmüş bir versiyonu olarak bilinir. SVM, doğrusal ayırım problemlerinin çözümü için kullanılan bir tür denetimli öğrenme algoritmasıdır. İki farklı özellik vektörü sınıfını ayırt edebilmek için bir hiper düzlem oluşturmaktadır. Bu hiperdüzlem verilerin kategorize edilmesinde bir karar eşiği olarak kullanılır. SVM, hiperdüzlem ile ona en yakın veri noktalarının destek vektörleri arasındaki mesafeyi maksimize etmeyi hedefler. SVM yönteminde

kullanılan çekirdeğe bağlı olarak, amaç fonksiyonu konveks olabilmektedir. Konveks olmayan fonksiyonlar genellikle yerel maksimuma daha yakındır. Bu nedenle, geleneksel SVM, optimizasyon verimliliği ve doğruluk oranı arasında bir ilişki sağlar. QSVM, Grover algoritmasının bir kuantum alt yordamı olarak kullanır. Bu, konveks olmayan maliyet fonksiyonlarının küresel optimum değerine ulaşmasını mümkün kılar [142]. SVM için karar sınırını ve marjları tanımlayan Denklem 4.19'da yer almaktadır.

$$\theta^T x - c = \pm 1 \quad (4.19)$$

Bu denklemde yer alan c karar yerinin sınırını belirleyen sabit bir değerdir, x giriş vektörü ve θ^T ağırlık vektörünün transpozudur. Eğer θ minimum olacak şekilde sınırlandırılırsa, margin verileri doğru bir şekilde kategorize etmek için güvenilir hale gelir. Bu marjlar, destek vektörlerinin bulunduğu konumları belirler. Denklem 4.20'de destek vektör makineleri için optimizasyon probleminin amaç fonksiyonunu ifade edilmiştir.

$$\min_{\theta, c} \frac{1}{2} \|\theta\|^2 \quad (4.20)$$

$\|\theta\|^2$ ağırlık vektörünün öklidiyen normunu ifade eder. Bu optimizasyon problemi, iki sınıf arasındaki ayrımı en iyi şekilde yapacak olan hiper düzlemi bulmayı hedefler. Ağırlık vektörünün normunu minimize ederek, SVM'nin genel performansını artırır ve daha doğru sınıflandırma işleminin gerçekleştirilmesini sağlar. Denklem 4.21 SVM için optimizasyon probleminin kısıtlamasını ifade eder.

$$y^i(\theta^T x^{(i)} - c) \geq 1 \quad (4.21)$$

Eğitim verilerinde $i=\{1, \dots, M\}$ ve $y^{(i)} = \{-1, 1\}$ olduğunda, Lagrange çarpanları α^i kullanılarak, kısıtlama bir amaç fonksiyonuna dahil edilebilir ve bu şekilde problem Denklem 4.22'de ki gibi tanımlanır.

$$\min_{\theta, c} \max_{\alpha^i \geq 0} \left(\frac{1}{2} \|\theta\|^2 - \sum_{i=1}^M [\alpha^i (\theta^T x^{(i)} - c) - 1] \right) \quad (4.22)$$

Önemli bir nokta, $\alpha^{(i)}$ değerinin sıfır olmayan tek değeri, destek vektörlerinin x^i toplamına eşittir. Amaç fonksiyonu F'yi α ile ilgili olarak maksimize etmek amacıyla Denklem 4.23'de verilen türevlerin hepsi sıfıra eşitlenmiştir.

$$\frac{\partial F}{\partial \theta^{(i)}} = \theta^{(i)} - \alpha^{(i)} y^{(i)} x^{(i)} = 0; \quad \frac{\partial F}{\partial c} = \sum_{i=1}^M \alpha^{(i)} y^{(i)} = 0 \quad (4.23)$$

Denklem 4.24 destek vektör makinelerinin eğitim sürecinde elde edilen ağırlık vektörünü (θ) tanımlar. α^i lagrange çarpanını, $y^{(i)}$ i. örneğin sınıf etiketini ve $x^{(i)}$ i. örneğin özellik vektörünü ifade eder. α^i her bir örneğin karar sınırına katkısını belirler. Eğitim sürecinde, bu çarpanlar ve özellik vektörleri ile sınıf etiketleri kullanılarak ağırlık vektörü hesaplanır.

$$\theta = \sum_{i=1}^M \alpha^{(i)} y^{(i)} x^{(i)} \quad (4.24)$$

Denklem 4.25, destek vektör makinelerinin optimizasyon probleminin Lagrange dual formunu ifade eder. Dual form, doğrudan çözmek yerine çift problem olarak çözülmesi daha kolay olan optimizasyon problemlerini ifade eder.

$$\min_{\alpha^{(i)}} \left\{ \frac{1}{2} \sum_{i,j} \alpha^{(i)} \alpha^{(j)} y^{(i)} y^{(j)} (x^{(i)})^T - \sum_{i=1}^M \alpha^{(i)} \right\} \quad (4.25)$$

SVM için Lagrange çarpanlarının $\alpha^{(i)}$ ile ilgili bir kısıtlamayı ifade eder. Denklemin genel formu Denklem 4.26'da verilmiştir.

$$\alpha^{(i)} \geq 0 \quad (4.26)$$

Eğitim setindeki her i için, $i=1, \dots, M$ için Denklem 4.27 Lagrange çarpanları $\alpha^{(i)}$ ve sınıf etiketleri $y^{(i)}$ arasındaki ilişkiyi ifade eder. Bu denklem, SVM'nin optimizasyon sürecinde kullanılan bir kısıtlamadır ve tüm eğitim örnekleri için Lagrange çarpanları ve sınıf etiketlerinin toplamının sıfır olması gerektiğini belirtir. Bu kısıtlama, destek vektörlerinin karar sınırının (hiper düzlemin) doğru bir şekilde oluşturulmasını ve her iki sınıftaki veri noktalarının dengeli bir şekilde temsil edilmesini sağlar.

$$\sum_i \alpha^{(i)} y^{(i)} = 0 \quad (4.27)$$

Denklem 4.28'de SVM için optimizasyon probleminin Lagrange dual formudur. Bu form, kernel fonksiyonları, $K(x^{(i)}, y^{(i)})$ kullanılarak doğrusal olmayan verileri ayırmayı sağlar.

$$\min_{\alpha^{(i)}} \left\{ \frac{1}{2} \sum_{i,j} \alpha^{(i)} \alpha^{(j)} y^{(i)} y^{(j)} K(x^{(i)}, y^{(i)}) - \sum_{i=1}^M \alpha^{(i)} \right\} \quad (4.28)$$

Bu denklem, SVM'nin eğitim sürecinde kullanılmak üzere amaç fonksiyonunu tanımlar. Amaç fonksiyonu, Lagrange çarpanları $\alpha^{(i)}$ ve kernel fonksiyonlarını kullanarak optimize edilir.

QSVM algoritmasının aşamaları şu şekilde sıralanabilir;

- Problemin niteliğine uygun çekirdek fonksiyonu ve parametreler seçilir. Çekirdek fonksiyonu hesaplanarak bir çekirdek matrisi oluşturulur.
- Amaç fonksiyonu segmentlere ayrılır ve bileşenleri kübitlere kaydedilir. Parametreler ve klasik bilgilerin kuantum durumları hazırlanır. Klasik verileri temsil etmek için ikili diziler kullanılabilir. Denklem 4.29'da klasik verilerin kuantum bilgisayarlarda nasıl temsil edileceğini göstermektedir. Burada x vektörü, ikili dizi b şeklinde kodlanarak kuantum durumlarına dönüştürülür. $(b_1, b_2, \dots, b_m)$ klasik verinin bileşenlerini temsil eden ikili değerleri ifade etmektedir. Verilerin bu şekilde kodlanması, kuantum bilgisayarların geleneksel veri setleri üzerinde çalışmasına olanak tanır.

$$x \rightarrow b = (b_1, b_2, \dots, b_m)^T \quad (4.29)$$

- Oluşturulan ikili diziler k kübitlik kuantum durumlarına dönüştürülür. $|b_1, b_2, \dots, b_m\rangle$ Bu 2^k boyutlu Hilbert uzayı oluşturur ve bu uzay $\{|00\dots 0\rangle, |10\dots 0\rangle, \dots, |11\dots 1\rangle\}$ şeklinde ifade edilir.
- Grover tekniği, tüm olası amaç fonksiyonlarının uzayını arayarak θ ve c değerlerini çözen optimal $\alpha^{(i)}$ değerini belirler. Bu süreç, bir kuantum amaç fonksiyonunu ifade eden tüm potansiyel girdilerin süperpozisyonunu oluşturarak gerçekleştirilir ve SVM optimizasyon problemi için küresel bir minimum elde eder. Bu alt programın ölçümü, yüksek bir olasılıkla cevabı sağlar.

Grover yaklaşımı, verilen SVM optimizasyon probleminin zaman karmaşıklığını $O(N)$ 'den $O(\sqrt{N})$ 'ye düşürür, burada N eğitim vektörünün boyutudur ve küresel bir minimum sağlar. Çekirdek matrisinin hesaplanması, herhangi bir SVM algoritmasının en zaman alıcı yönlerinden biridir ve hesaplama karmaşıklığı $O(M^2N)$ olarak ifade edilir.

Grover yaklaşımının sınırlamaları, kuantum gürültüsü nedeniyle algoritmanın kabul edilebilir sonuçlar üretememesidir. SVM optimizasyon probleminde kullanılan amaç fonksiyonu bir kuantum bilgisayarında kullanılan özel bir kuantum alt programı kullanılarak elde edilir. QSVM algoritmasında kuantum süperpozisyonu ve paralelliği kullanılarak, birçok olası girdi aynı anda değerlendirilir ve en uygun çözümü bulmak için kullanılır [130].

4.3.3. Değişken Kuantum Sınıflandırıcı

Varyasyonel Kuantum Sınıflandırıcı (VQC), QML algoritmaları arasında önemli bir yere sahiptir ve özellikle Gürültülü Orta Ölçekli Kuantum (Noisy Intermediate-Scale Quantum, NISQ) cihazları üzerindeki sınıflandırma problemleri için yaygın olarak kullanılan gözetimli bir algoritmadır. Havlicek vd., ekstra hata düzeltme yöntemlerine ihtiyaç duymadan NISQ cihazları üzerinde keşifsel bulgular elde etmeyi sağlayan VQC modelini önermişlerdir. VQC modeli, gürültülü

verileri optimizasyon hesaplamalarına entegre eden yinelemeli cihaz ölçümleri kullanarak maliyet fonksiyonunu hesaplar ve hataları azaltır [143].

Varyasyonel Kuantum Sınıflandırıcısı (VQC), kuantum bilgisayarlar üzerinde $f(x,\theta)=y$ fonksiyonunun kullanımını temel olarak oluşturulmuştur. Bu fonksiyonda, giriş verisi x 'i bir kuantum durumu olarak kodlamak amacıyla Sx olarak adlandırılan bir devre aracılığıyla uygulanır ve özellikle bu durumun genlikleri kullanılır. Sonrasında, $U\theta$ olarak adlandırılan bir kuantum devresi kullanılarak işlem yapılır ve nihayetinde basit bir kübit ölçümü gerçekleştirilir. Bu son ölçüm, VQC'nin '0' veya '1' tahmin etme olasılığını sağlar ve bu olasılıklar ikili sınıflandırmanın tahminini belirlemek amacıyla kullanılır. Ayrıca, bu sınıflandırmanın devre parametreleri (θ) eğitilebilir olup, varyasyonel bir teknik kullanılarak optimize edilebilir [144]. VQC algoritmasının çalışma prensibine bakıldığında ilk aşama durum hazırlamadır. Klasik verileri kuantum durumlarına kodlayabilmek için, kuantum devresinde verilerle çalışabilmesini sağlayan belirli işlemler kullanılmaktadır. Kuantum kodlama, klasik verileri Hilbert uzayında bir kuantum durumu biçiminde temsil etmeyi içeren yöntemlerden biridir ve kuantum özellik haritası kullanılarak gerçekleştirilir. Özellik haritası, parametrelerin giriş verileri tarafından belirlendiği varyasyonel bir devreye benzer. Varyasyonel bir devrenin, klasik yöntemlerle optimize edilebilen parametrelere bağlı olduğunu vurgulamak önemlidir.

İkinci aşama sınıflandırıcının oluşturulmasıdır. φ' , $\varphi(x)$ olarak belirtilen ve n -kübitli bir sistemde bir kuantum durumu vektörü haline gelen özellik vektörüne uygulanan parametrelili bir üniter operatör $U\theta$ kullanılarak oluşturulur. Model, girdinin durumunu değiştiren ve üniter süreçlere dayalı kapılardan oluşan bir devre kullanır ve bu kapılar ayarlanabilir dış faktörlere bağlıdır. $U\theta$, $\varphi(x)$ 'i model devresinde hazırlanan $|\varphi(x)\rangle$ durumuna sahip başka bir vektör φ' 'ye dönüştürür. $U\theta$, bir dizi üniter kapıdan oluşur. Bir kuantum sisteminden bilgi elde etmek için ölçümler yaparız. Kuantum sisteminin sonsuz sayıda potansiyel durumu olmasına rağmen, kuantum ölçümünden yalnızca sınırlı miktarda bilgi geri kazanabiliriz. Son olarak, sonuçlar öğrenilebilir bir yanlılık parametresi ve sonucu 0 veya 1'e çevirmek için bir adım fonksiyonu içerecek şekilde işlenir [130].

5. KUANTUM MAKİNE ÖĞRENMESİ UYGULAMALARI

Bu bölümde, tez kapsamında gerçekleştirilen deneysel analizlere yer verilmiştir. EEG sinyallerinin sınıflandırılması için klasik makine öğrenme algoritmalarının yanı sıra kuantum tabanlı makine öğrenme algoritmalarından QSVM ve VQC kullanılmıştır. Çalışmada, kuantum makine öğrenme yöntemlerinin performansı, doğruluk ve çalışma süresi açısından klasik yöntemlerle karşılaştırılmıştır. Üç farklı EEG veri seti kullanılarak yapılan deneylerde, veri setleri çeşitli ön işlemlerden geçirilmiş ve PCA yöntemiyle boyutları azaltılmıştır. Deneysel çalışmalarda kullanılan kuantum algoritmalarının çeşitli parametreleri değiştirilerek sonuçlar elde edilmiştir. Analizlerin sonuçları, kuantum makine öğrenme yöntemlerinin EEG sinyallerinin analizinde potansiyel avantajlarını ortaya koymaktadır.

5.1. EEG Sinyalleri Üzerinde QSVM ve Diğer Makine Öğrenimi Algoritmalarının Karşılaştırılması

EEG sinyalleri, sadece hastalık tespitleri için kullanılan bir sinyal çeşidi olmayıp aynı zamanda insanların günlük yaşantıdaki görevler esnasında bilişsel durumlarının modellenmesi için de kullanılmaktadır. EEG sinyalleri kullanılarak gözün açık veya kapalı olma durumunun belirlenmesi ile bebeklerin uyku uyanıklık durumlarının otomatik tespiti [145], sürüş esnasında uyku halinin tespit edilmesi [146], stres özellikleri ve etki ettiği bölgelerin tanımlanması [147] gibi problemler incelenmiştir. Kuantum makine öğrenme algoritmalarıyla EEG sinyali analizi üzerine yapılan çalışmalar oldukça sınırlıdır. Bu tez kapsamında, *EEG Göz Durumu* veri seti kullanılarak göz durumu (açık veya kapalı) ile EEG sinyalleri arasındaki ilişki incelenmiştir.

EEG sinyallerinin kullanıldığı beyin-bilgisayar arayüzlerinde, verilerin hızlı ve doğru bir şekilde analiz edilmesi kritik bir adımdır. Kuantum alanındaki gelişmeler ve kuantum bilgisayarların ortaya çıkışı, klasik verilerin kuantum sistemleri kullanılarak makine öğrenmesi algoritmalarıyla analiz edilmesi fikrini doğurmuştur. Kuantum sistemleri aracılığıyla, klasik makine öğrenmesi algoritmalarının ötesinde, sıra dışı ve daha karmaşık modellerin elde edilmesi hedeflenmektedir. Başka bir deyişle, kuantum makine öğrenimi çalışmaları, makine öğrenmesi yöntemlerini kuantum hesaplamanın en son teknolojisinin avantajlarına uyarlayarak hem kuantum bilgisayarların yeteneklerinden hem de makine öğrenme tekniklerinden faydalanmayı amaçlamaktadır. Günümüzde birçok araştırmacı, bu potansiyeli değerlendirmek amacıyla kuantum makine öğrenmesi yöntemleri üzerinde çalışmalar yapmaktadır. Bu alanda yapılan çalışmalardan bazıları aşağıda sıralanmıştır;


Cattan vd., Brain Invaders adlı oyunu oynarken elde edilen EEG verilerini içeren bir veri setini kullanarak çalışmalarını gerçekleştirdiler. Bu veri seti, 26 katılımcıdan elde edilmiş olup, katılımcıların 7'si kadın ve ortalama yaşları 24.4'tür. Araştırmalarında QSVM ve SVM

algoritmalarını uygulamışlar ve analizleri Kuantum bilgisayar ile QasmSimulator ortamlarında gerçekleştirmişlerdir. Yazarlar, kuantum bilgisayarları kullanarak yapılan analizlerin çalışma süresinin simülasyon ortamında yapılan analizlere kıyasla önemli ölçüde azaldığını vurgulamışlardır. Bununla birlikte, QSVM algoritmasından elde edilen doğruluk oranının, SVM algoritması ile karşılaştırıldığında daha düşük olduğu sonucuna varılmıştır [23]. Başka bir çalışmada ise, 12 katılımcıya belirli kelimeleri zihinsel olarak tekrar etmeleri istenmiş ve bu süreçte katılımcıların EEG verileri kaydedilmiştir. Bu veriler, ALS hastalarında kullanılmak üzere geliştirilecek bir beyin-bilgisayar arayüzü oluşturmak amacıyla değerlendirilmiştir. QSVM algoritması kullanılarak elde edilen sonuçlar, diğer bilinen yöntemlere kıyasla daha yüksek doğruluk oranına ulaştığını göstermiştir [25]. Li vd., EEG sinyallerini sınıflandırmak ve özelliklerini çıkarmak için hiyerarşik kuantum mekaniğini kullanmıştır. EEG veri seti, bir kuantum durumu olarak hazırlandıktan sonra Kuantum Dalgacık Paketi Dönüşümü yöntemiyle analiz edilmiştir. Araştırmacılar, QSVM'yi lineer olmayan bir çekirdek olarak önererek, dalga paketi enerji entropisi özelliğini kuantum sınıflandırıcının girişi olarak belirlemiştir [16]. Andreev ve Cattani, EEG verilerini sınıflandırmak için LDA ile kuantum destekli SVM algoritmasını karşılaştırmıştır. EEG analizini Riemann Geometrisi yöntemiyle hazırlamışlar ve kuantum sınıflandırıcıda LDA ile yapılan analizlerden daha düşük sonuçlar elde ettiklerini belirtmiştir. Ayrıca, iyi ayrılabilir verilerin sınıflandırılmasında, kuantum hesaplamanın klasik hesaplama göre bir avantaja sahip olmadığını vurgulamıştır [26]. Padma ve Sahoo, insanların zihinsel sağlığı üzerindeki stres etkilerini incelemek amacıyla SWELL KW veri setine Kuantum K-En Yakın Komşu, QSVM ve VQC algoritmalarını uygulamıştır. 25 katılımcıdan çeşitli koşullar altında elde edilen verilere, PCA ve QPCA uygulayarak veri boyutunu azaltmıştır. Çalışmanın sonucunda, PCA kullanılarak özellikleri azaltılan verilere QSVM uygulandığında en yüksek doğruluk değerine ulaşıldığını belirtmiştir [27]. Huerga vd., insan davranışlarını tahmin etmek için Kasteren veri setini kullanmıştır. Analizlerinde, kuantum hesaplama algoritmalarından Kuantum Kernel Alignment, QSVM ve klasik makine öğrenme algoritmalarından Karar Ağacı, Rastgele Orman, Destek Vektör Makinesi ve Ada Boost yöntemlerini kullanmıştır. Mevcut donanım ve simülatörlerde sınırlı sayıda eğitim verisi işlenebildiği için veri setinin belirli bir kısmını çalışmada kullanmıştır. Analizlerinde, kübit gürültüsü olmayan IBMQ-Manila ortamını tercih etmiştir. Deneysel sonuçlara göre, kuantum tabanlı algoritmalar, klasik algoritmalarından daha iyi performans göstermiştir. Ayrıca, analizlerini farklı kübit gürültü değerleri için tekrarlayarak, kübit gürültüsünün doğruluk değerini büyük ölçüde etkilediğini raporlamıştır [148].

Bu çalışmada, kuantum makine öğrenimi yöntemlerinden biri olan Kuantum Destek Vektör Makinesi ile klasik makine öğrenimi yöntemlerinden SVM, NB, KNN, LR, DT ve RF algoritmaları, *EEG göz durumu* veri setine uygulanmıştır.

5.1.1. EEG Göz Durumu Veri Seti

Yapılan analizlerde veri madenciliği sınıflandırma çalışmaları için uygun olan *EEG göz durumu* veri seti kullanılmıştır. Oliver Roesler tarafından hazırlanan bu veri seti, UC Irvine Machine Learning Repository veri tabanından alınmıştır [149]. Bu veri setinde, EEG ölçümleri için Emotiv EEG Neuroheadset ve göz durumu analizi için kamera kullanılarak veriler elde edilmiştir. Deney, sessiz bir odada gerçekleştirilmiş ve EEG sinyalleri, bireyin kafa derisinin farklı bölgelerine yerleştirilen 14 farklı kanaldan (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, AF4, F8, F4, FC6, T8) 117 saniyelik bir ölçüm süresi boyunca kaydedilmiştir. Video kayıtlarının manuel analizi sonucunda, gözün açık olma durumu ‘0’ ve kapalı olma durumu ise ‘1’ olarak veri setine etiketlenmiştir. Veri setinde, gerçel ve tam sayı değişkenleri bulunmaktadır. Toplamda 15 özellik içeren veri setinde, 14 özellik EEG değerlerini gösterirken, diğer özellik gözün açık veya kapalı olup olmadığına dair bilgiyi içermektedir. Veri seti 14980 örnekten oluşmaktadır [150]. Şekil 5.1’de sensörlerin kafatasındaki yerleşimi gösterilmiştir.




Şekil 5.1. EEG Göz Durumu veri setinde kullanılan kanallar

5.1.2. Deneysel Çalışma


QSVM ve klasik makine öğrenimi algoritmaları, farklı beyin bölgelerinden kaydedilen EEG sinyalleri ve bir video yardımıyla elde edilen göz hareketlerini içeren EEG göz durumu veri setine uygulanmıştır. Ancak IBM kuantum bilgisayarları tarafından sunulan sınırlı kaynaklar nedeniyle, analiz sırasında 14980 örneği içeren veri setinin tamamı kullanılamamıştır. Bu nedenle, veri setindeki örnek sayısı azaltılarak 575 örneğe düşürülmüştür. Bu deneylerde, veri setine ön işlem süreci uygulanmamış ve ham veri seti kullanılmıştır. İlk olarak veri seti sisteme aktarılmış ve QML’deki kuantum donanımının sınırlı kübit sayısı nedeniyle PCA yöntemiyle veri boyutu 14

öznitelikten 3 özniteliğe kadar azaltılmıştır. Kuantum sınıflandırma algoritmasında gerçekleştirilen işlemlerin şematik gösterimi Şekil 5.2’de sunulmuştur.



Şekil 5.2. QSVM metoduna ait blok diyagram

Verileri kübit formuna dönüştürebilmek için 2 kez tekrarlanan ZZ özellik haritası lineer olarak kullanılmıştır. Kuantum sınıflandırma algoritmasının uygulanması için kullanılan devre modeli ise Şekil 5.3’te gösterilmiştir.




Şekil 5.3. ZZFeatureMap (2 tekrar)

Her kübit için çekirdekten alınan ölçüm sayısı (shot) 1024 olarak belirlenmiştir. Daha sonra hazırlanan veri, QSVM sınıflandırıcısına girdi olarak verilmiştir. Tüm analizler, IBM Kuantum laboratuvar ortamındaki QasmSimulator kullanılarak bulut sistemde gerçekleştirilmiştir. Qasm simülatörü, IBM’in kuantum analizlerinin gerçekleştirilebilmesi için sunduğu QiskitAer içerisinde yer alan bir simülatör ortamıdır. Bu ortam, gerçek kuantum cihazları gibi davranarak kuantum devrelerinin çalıştırılmasını mümkün kılmaktadır. Python programlama dili kullanılan Qiskit Kütüphanesi, IBM kuantum laboratuvarında simülatör ve gerçek kuantum bilgisayarlarda QSVM algoritmasının kullanılmasını sağlamaktadır. Tablo 5.1’de gerçekleştirilen çalışmada elde edilen doğruluk değerleri sunulmuştur.


Tablo 5.1. Öznitelik sayısına göre makine öğrenme algoritmalarının performans karşılaştırması

Öznitelik Sayısı	Klasik Makine Öğrenme Algoritmaları						Kuantum Makine Öğrenme Algoritması
	Doğruluk Oranı (%)						Doğruluk Oranı (%)
	SVM	NB	DT	RF	LR	KNN	QSVM
3	72.0	68.17	70.61	71.65	67.65	72.52	69.39
4	81.91	75.30	77.22	80.87	70.96	80.35	81.56
5	100.0	99.30	98.09	99.65	99.83	100.0	99.47
6	100.0	99.65	98.09	99.83	100.0	100.0	99.30
7	100.0	99.65	97.91	99.83	99.83	100.0	98.43
8	100.0	99.65	98.09	99.48	100.0	100.0	98.26
9	99.3	99.65	97.91	99.65	99.83	99.83	98.43
10	99.3	99.65	98.09	99.83	100.0	100.0	97.91
11	99.13	99.65	98.09	99.83	100.0	99.83	97.56
12	99.13	99.65	98.09	100.0	100.0	100.0	96.34
13	98.98	99.65	97.27	100.0	100.0	100.0	96.24
14	98.98	99.65	97.27	100.0	100.0	100.0	96.24

PCA ile boyutları azaltılan verilerin öznitelik sayılarına göre elde edilen sonuçlar Tablo 4.1’de belirtilmiştir. Sonuçlar, QSVM algoritmasının doğruluğunun klasik yöntemlere göre daha düşük olmasına rağmen, sınıflandırıcının verilerden öğrenme yeteneğine sahip olduğunu göstermektedir. Yapılan analizlerde elde edilen doğruluk oranlarının grafiği ise Şekil 5.4’te sunulmuştur.

**Şekil 5.4.** Farklı öznitelik sayılarına göre klasik makine öğrenme yöntemlerinin doğruluk oranları

Şekil 5.5’te SVM ve QSVM algoritmalarının farklı kübit sayılarında elde edilen doğruluk değerleri sunulmaktadır.



Şekil 5.5. Farklı öznitelik sayılarına göre SVM ve QSVM algoritmasının doğruluk oranı grafikleri

Şekil 5.5 incelendiğinde, kübit sayısındaki değişikliklerin algoritmalarından elde edilen sonuçları etkilediği görülmüştür. QSVM algoritması, 3 kübit durumunda minimum ve 5 kübit durumunda maksimum performansı elde etmiştir. Kübit sayısının 5'in üzerinde olduğu durumlarda, doğruluk oranının maksimum performansa göre azaldığı gözlemlenmiştir. Tablo 5.2'de, 5 kübit için QSVM'in performansını değerlendirmede kullanılan metriklere yer verilmiştir.

Tablo 5.2. 5 kübit için QSVM'in performans metrikleri

Duyarlılık (%)	Özgüllük (%)	Hassasiyet (%)	F1-Skor
99.68	99.60	99.37	99.4

Duyarlılık ve özgüllük, kullanılan modelin performansını değerlendirmede önemli kriterler arasında yer almaktadır. Elde edilen veriler incelendiğinde, QSVM algoritmasının EEG sinyallerinin analizinde oldukça yüksek bir performans sergilediği görülmüştür. Bu durum, QSVM'in yüksek öğrenme yeteneğini kanıtlamaktadır. Veri boyutundaki artışla birlikte, 10 kübitten itibaren elde edilen doğruluk oranları sabit kalmış ve bu nedenle 14. kübitten itibaren deneysel çalışma sonlandırılmıştır. Ayrıca, QasmSimulator'de 5 kübit için yapılan analizlerde QSVM algoritmasının hesaplama süresinin yaklaşık 5 saat olduğu, klasik makine öğrenme yöntemlerinde ise bu sürenin yaklaşık 1 dakika olduğu tespit edilmiştir. Bu bulgu, kuantum makine öğrenme tekniklerinin simülatorlerde çalıştırıldığında hesaplama süresi açısından avantaj sağlamadığını ortaya koymuştur.

5.1.3. Sonuçlar ve Tartışma

Bu çalışmada, *EEG göz durumu* veri setine kuantum destekli bir SVM ve klasik makine öğrenme algoritmaları, kuantum simülatör ortamında uygulanmıştır. Verilerin analizi simülatör ortamında oldukça uzun sürdüğü için, veri setindeki örnek sayısı azaltılmış ve boyut azaltma işlemi PCA yöntemiyle gerçekleştirilmiştir. Daha sonra Öklid uzayındaki veriler, Hilbert uzayındaki kuantum durum verilerine ZZ özellik haritası kullanılarak eşlenmiş ve bu veriler QSVM algoritmasına girdi olarak verilmiştir. Farklı kübit değerleri için yapılan analizlerde, QSVM'nin en iyi performansının 5 kübitlik veri setinde %99,47 olarak elde edildiği görülmüştür. QSVM algoritması, SVM algoritmasına oldukça yakın sonuçlar üretmiş ve bu durum, sistemin verileri öğrenme yeteneğini göstermiştir.

Bu çalışmada kullanılan veri setine dayalı olarak yapılan çeşitli çalışmalar da incelenmiş ve elde edilen sonuçlar değerlendirilmiştir. Roesler ve Suedermann, EEG analizi ile göz durumunu tahmin etmek için gerçekleştirdikleri analizlerde, her bir kanaldan elde edilen verilerin gözün açık veya kapalı olma durumuna göre maksimum, minimum ve ortalama değerlerini kaydetmişlerdir. Veri setini WEKA yazılımında 42 sınıflandırma yöntemi ile analiz eden araştırmacılar, 10 kat çapraz doğrulama ile en yüksek performansı %97 oranında K* algoritmasından elde etmiştir [150]. Sahu vd., özellik altkümesi seçimi için Artımlı Özellik Yeniden Sıralama (Incremental Feature Reordering- IFR) algoritmasını kullanmıştır. Özellik seçiminde baskın olmayan özellikleri çıkararak yeniden sıralama kümesi oluşturmuştur. Araştırmacıların elde edilen optimal altküme özelliği ile sınıflandırıcıların başarımını arttırmayı hedeflediği bu çalışmada, K* algoritması ile %95.01 doğruluk oranı elde edilmiştir [151]. Yapılan bir başka çalışmada sinir ağlarına dayalı artımlı öznelik öğrenme dayalı yeni bir makine öğrenme stratejisi göz durumlarının tespitinde kullanılmak için önerilmiştir. Bu yöntemde özelliklerin belirli bir düzenle içe aktararak modelin eğitilmesi sağlanmaktadır. Araştırmacılar, zaman serisi sınıflandırma problemlerinde bu yöntemin geleneksel yöntemlere göre daha düşük hata oranı ile sınıflandırma yapabildiğini belirtmiştir [152]. Al-Taei, *EEG göz durumu* veri kümesine SVM, Gizli Markov Haritası ve Radyal Temel Fonksiyon algoritmalarını uygulamıştır. Ayrıca iki çekirdekli (K* ve RF algoritmalarına dayalı) bir oylama algoritması önermiştir. Önerdiği yöntemle en yüksek performansı %97.27 olarak belirlemiştir [153]. Weka yazılımı kullanılarak KNN ve çok katmanlı algılayıcı sinir ağı modellerinde göz durumu tespiti yapılmaya çalışılmıştır. Çeşitli sayıda nöronlar kullanılarak eğittikleri sinir ağı modelinde en yüksek performansı nöron sayısı 7 olduğu durumda %56.45 olarak elde etmişlerdir. Çalışmada KNN modelinde k değeri 3 olduğu durum için başarımları %84.05 olarak hesaplanmıştır [154]. Ketu ve Mishra çalışmalarında, sentetik azınlık aşırı örnekleme tekniği ile *EEG göz durumu* veri setindeki sınıf dengesizliğinin giderildiği yeni bir veri seti oluşturmuştur. Hiper parametreleri ayarlanmış bir klasik makine öğrenme algoritması kullanılarak veri setini analiz etmiştir. %94.1 ile en yüksek başarımları hiper parametreleri ayarlanmış KNN algoritmasından elde etmiştir [155].

EEG sinyallerinin alınması, veri setlerinin hazırlanması, yorumlanması ve beyin-bilgisayar arayüzü oluşturulması, birçok hastalığın teşhisini kolaylaştırmıştır. Bu süreçlerde çeşitli klasik makine öğrenme algoritmaları kullanılmaktadır. Klasik yöntemlerin geliştirilmesi ve daha hızlı, daha doğru sonuçların elde edilmesi, BBA oluşturma açısından oldukça önemlidir. Kuantum hesaplama alanındaki gelişmeler, bu süreçleri desteklemektedir. Son yıllarda, kuantum tabanlı makine öğrenme yöntemlerinin geliştirilmesi ve farklı alanlara uygulanması, yeni algoritmaların ortaya çıkmasına yol açmıştır.

Bu çalışmada *EEG göz durumu* veri seti için QSVM algoritması ile klasik makine öğrenme yöntemlerinin performansı doğruluk açısından karşılaştırılmıştır. Veri setinin sinyal-gürültü oranı P300 durumuna göre daha iyidir. Dinlenme durumu verilerinin zaman örneklerine göre yapılan sınıflandırmada, kuantum sınıflandırmanın oldukça iyi sonuçlar elde ettiği gözlemlenmiştir. Algoritma, yalnızca 5 kübit ve sınırlı ön işleme adımlarıyla %99.47 doğruluk oranı yakalayarak etkileyici bir başarı elde etmiştir. Bu bulgu, kuantum tabanlı makine öğrenme algoritmalarının farklı EEG sinyallerinde kullanıma uygun olduğunu göstermektedir.

5.2. Şizofreni Tespiti için Kuantum Makine Tabanlı Karar Destek Sistemi

Şizofreni, günlük hayatı etkileyen ciddi bir kronik zihinsel işlev bozukluğudur. Elektroensefalogram beyindeki zihinsel aktiviteleri ölçmede kullanılan, bu sebeple şizofreni teşhisinde de faydalanan yöntemler arasında yer almaktadır. Belirtileri çocukluk döneminde başlayan hastalık, ilerleyen yaşlarda daha belirgin hale gelmektedir. Ancak belirli tedavilerin uygulanması ile kontrol altında tutulabilmektedir. Bilgisayar destekli yöntemler kullanılarak bu hastalığın erken teşhisi sağlanabilmektedir. Bu çalışmada EEG sinyalleri kullanılarak şizofreni hastalığının tespiti için çeşitli makine öğrenme algoritmaları ve yeni gelişen bir teknoloji olan kuantum tabanlı makine öğrenme algoritması kullanılmıştır. EEG sinyallerine çeşitli ön işlemler uygulanarak veri seti düzenlenmiştir. Elde edilen verilerin kuantum sistemlerde işlenebilmesi için temel bileşen analizi yöntemi uygulanmıştır. Boyutları küçültülen veriler çeşitli özellik haritaları kullanılarak kübit formuna dönüştürülmüş ve QSVM algoritmasına girdi olarak verilmiştir. Böylece klasik makine öğrenme algoritmalarının yanı sıra farklı kübit sayıları ve farklı devreler kullanılan QSVM algoritması uygulanmıştır.

Şizofreni halüsinasyonlar, iletişim ve düşünce bozuklukları, anormal motor davranışlar, sanrılar ve günlük aktivitelerdeki bozulmalar şeklinde kendini gösteren son derece ciddi bir nöropsikolojik rahatsızlıktır. Hastalığın kesin sebebi tam olarak bilinmemekle birlikte, genetik yatkınlık ve çevresel faktörlerin (göç, çocukluk travmaları, bulaşıcı hastalıklar, uyuşturucu kullanımı, beslenme, toksinler, kentleşme vb.) hastalığın gelişiminde önemli rol oynadığı düşünülmektedir [156], [157]. Genellikle genç yetişkinlik döneminde başlayan şizofreni, dünya nüfusunun yaklaşık %1'ini etkileyen bir hastalıktır ve çoğu ülkede benzer oranlarda görülmektedir. Hastalık, erkeklerde

kadınlara kıyasla daha sık ortaya çıkmaktadır [158]. Şizofreni hastalığı tedavi edilmediği takdirde depresyon, asosyallik, davranışları kontrol edememe, şiddet eğilimi, anksiyete bozuklukları, intihar etme gibi çeşitli komplikasyonların görülme sıklığı artmaktadır. Ayrıca genel nüfusa kıyasla şizofreni hastalarının yaşam süresi 10-25 yıl daha kısadır [159]. Şizofreni hastalarının yaklaşık %4.9'luk bir kısmı ise intihar yoluyla ölümü seçmektedir. Hastalığın maliyeti, alınması gereken sağlık hizmetleri, sosyal ihtiyaçlar ve istihdamın azalması gibi sebeplerle diğer hastalıklara kıyasla oldukça yüksektir [160]. Ömür boyu tedavi gerektiren şizofreni gibi hastalıklarda, erken teşhis semptomların kontrol altında tutulmasına olanak tanıyarak hastaların yaşam kalitesini önemli ölçüde artırmaktadır.

Teknolojideki hızlı ilerlemeler, hastalıkların erken teşhisini kolaylaştıran bir dizi tıbbi görüntüleme tekniğinin ortaya çıkmasına neden olmuştur. Elektroensefalografi, Bilgisayarlı Tomografi ve Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging-MRI) gibi yöntemler sağlık sektöründeki gelişmelere önemli katkılar sağlamıştır. Bu görüntüleme teknikleri arasında, özellikle şizofreninin tanı sürecini kolaylaştırmada MRI ve EEG etkili araçlar olarak öne çıkmaktadır. EEG, kafa derisine yerleştirilen elektrotlar aracılığıyla sinir hücrelerinin ürettiği elektrik sinyallerini kaydederek bilgi iletimini sağlar [161]. Beynin elektriksel aktivitesi, güçlü doğrusal olmayan ve dinamik özelliklerle karakterize edilen karmaşık davranışlar sergiler. Bu nedenle, EEG sinyallerinden yalnızca gözlem yoluyla bilgi çıkarmak oldukça zordur. Anlamlı bilgiler elde edebilmek için bu sinyallerin veri toplama sürecinde çeşitli makine öğrenmesi yöntemleri kullanılmaktadır. Makine öğrenimi, verilerden öğrenme yeteneğini geliştirmeyi amaçlayan ve bunun için bilgisayar sistemlerini kullanan bir araştırma dalıdır. Veri madenciliği, yapay zekâ ve istatistik gibi farklı disiplinleri bir araya getirerek veriler arasındaki gizli kalıpların ortaya çıkarılmasını, verilerin analiz edilmesini ve öngörülerde bulunmayı sağlar [162]. Makine öğreniminin özel bir dalı olan derin öğrenme, büyük ve karmaşık veri setlerinde otomatik öğrenme yeteneklerini geliştirmektedir. Özellikle yapay sinir ağlarının katmanlı mimarisi, karmaşık desenleri daha iyi anlama yeteneği sunar. Derin öğrenme yöntemleri, genelleme yeteneğini artırmak için genellikle büyük miktarda veriye ihtiyaç duyar. Bu yöntemler, karmaşık ağ yapılarına dayandığından eğitim için yüksek hesaplama gücü ile özel donanımlar gerektirir. Bu sebeplerle, kuantum makine öğrenme yöntemlerinin kullanımı daha cazip hale gelmiştir.

Kuantum tabanlı makine öğrenme algoritmaları, karmaşık ve yenilikçi bir yaklaşımı benimseyerek klasik algoritmaların sınırlarının ötesine geçmektedir. Bu yöntemler, kuantum bilgisayarların paralel işleme, süperpozisyon, dolanıklık ve girişim gibi özelliklerinden yararlanarak problemleri ele almaktadır. Derin öğrenmenin büyük veri kümelerini analiz etme kapasitesi ile kuantum hesaplamaların ortaya çıkışı arasındaki sinerji, veri bilimi alanındaki teknolojik gelişmeleri hızlandırmıştır [163].

Bu çalışmada, EEG sinyallerinin şizofreni tanısında kullanılabilirliğini değerlendirmek amacıyla hem klasik makine öğrenmesi algoritmaları hem de kuantum makine öğrenmesi algoritması kullanılmıştır. Bu amaç doğrultusunda, 16 kanaldan elde edilen EEG verilerinden farklı beyin bölgelerini temsil eden 4 kanal seçilmiştir. Seçilen sinyaller, belirli ön işleme adımlarından geçirilmiştir. Veri setinin boyutunu 3 ile 15 öznitelik arasındaki değerlere indirmek için PCA kullanılmıştır. Ardından, klasik makine öğrenmesi yöntemleri ve farklı özellik haritalarına sahip kuantum destek vektör makinesi uygulanarak performansları değerlendirilmiştir.

Bu çalışmanın alana katkıları şu şekilde özetlenebilir:

- Bu çalışma, şizofreni tespiti için EEG veri setleri üzerinde QSVM'yi kullanan ilk çalışmadır.
- EEG kanallarından en iyi sonuçları üreten kanalların seçimi sağlanmıştır.
- QSVM algoritması için PCA yöntemi kullanılarak oluşturulan farklı sayıdaki kübitlerin ayrıntılı sonuçları elde edilmiştir.
- Kuantum makine öğreniminde kullanılan temel özellik haritaları, sınıflandırma üzerindeki etkileri açısından karşılaştırılmıştır. Sonuçlar, X ve Z özellik haritaları gibi birinci dereceden Pauli haritasının EEG verileriyle en iyi doğruluğu sağladığını göstermektedir.
- QSVM algoritmasının performansı klasik makine öğrenmesi yöntemleriyle karşılaştırılmıştır.
- Araştırma, sağlık alanında kuantum makine öğreniminin kullanımına ilişkin umut verici sonuçlar sunmuştur. Kuantum sınıflandırıcılar, yalnızca EEG verileri üzerinde genelleme yapma yeteneğine sahip olmakla kalmamış, aynı zamanda sınırlı sayıda bileşenle, mevcut tekniklere benzer veya biraz daha iyi sonuçlar elde etmişlerdir.
- Bu çalışma, kuantum sınıflandırıcıların klasik teknikleri tamamlayıcı bir yaklaşım olarak kullanılabileceğini ve şizofreni tanısına yardımcı olabileceğini göstermektedir.

5.2.1. Şizofreni Alanında Kullanılan Klasik Makine Öğrenimi Teknikleri

Şizofreni alanında yapılan makine öğrenme ve derin öğrenme modelleriyle gerçekleştirilen çeşitli çalışmalar incelenmiştir. Şizofreni tespitinde, istatistiksel teknikler, derin öğrenme ve makine öğrenme modelleri kullanılarak yapılan çalışmalar oldukça popülerdir. Buettner vd, 14 şizofreni teşhisi konulmuş birey ile 14 sağlıklı bireyin yer aldığı çalışmada, EEG verilerine Bağımsız Bileşen Analizi (ICA) uygulamıştır. Sensörler üzerindeki ortalama değerleri alarak spektral analizler gerçekleştirmiştir. Yapılan ön işlemlerin ardından, sınıflandırıcı olarak RF algoritması kullanılmış ve %96.77'lik bir başarı elde edilmiştir [164]. Johannesen vd., 18-70 yaş aralığında 40 hasta ve 12 sağlıklı bireyin yer aldığı bir çalışmada, delta, teta ve alfa bantlarının şizofreni üzerindeki etkisini incelemiştir. Çalışmada, SVM algoritması kullanılarak %87 başarı elde edilmiştir [165]. Miras vd.,

şizofreni teşhisi için DT, SVM, LR, RF ve KNN algoritmalarını kullanmıştır. Dinlenme durumu EEG sinyallerine uyguladıkları karmaşıklık ölçümlerinin performansa yüksek etkisi olduğunu belirterek, en yüksek başarının %89 ile SVM algoritmasından elde edildiğini ifade etmiştir [166]. Başka bir çalışmada 19 kanallı EEG veri seti Çok Değişkenli Yinelemeli Filtreleme (MIF) yöntemi kullanılarak çok değişkenli MIMF'lere ayrıştırılmıştır. Farklı EEG bant sinyallerinde çeşitli istatistiksel yöntemler kullanılarak 30 öznitelik elde edilmiştir. Sınıflandırma yöntemi olarak LDA, KNN algoritması ve farklı çekirdek fonksiyonlarına sahip SVM uygulanmıştır. Çalışmada, en yüksek performansın, %98.9 ile SVM algoritmasından elde edildiği belirtilmiştir [167]. Sharma ve Acharya, EEG sinyallerine altıncı dereceden Butterworth filtresi uygulamıştır. Kayıtları 25 saniyelik parçalara ayırdıktan sonra filtreleme işlemiyle alt bantları elde etmiştir. Sınıflandırma işlemi için KNN, Ensemble Bagged Tree (EBT), Ensemble Boosted Tree, LR ve SVM kullanılmıştır. Cz kanalı için en iyi sonucu %99.21 ile KNN algoritmasından elde etmiştir [168]. Zhang, 81 denekten ve 9 kanaldan alınan EEG kayıtları ve yaş, cinsiyet gibi bilgilerle zenginleştirilen öznitelikleri kullanarak bir veri seti oluşturmuştur. Bu veri setine RF algoritması uygulayarak şizofreni hastalarını sağlıklı bireylerden ayırt etmeye çalışmıştır. 8 öznitelik içeren çalışmada %81.1 doğruluk performansı elde edilmiştir [169]. 256 kanaldan elde edilen EEG sinyallerini içeren bir çalışmada, 8 farklı bölgeden gelen sinyaller 6. seviye dalgacık dönüşümü ile işlenmiştir. Her bir frekans bandına ve bölgeye uygulanan 12 istatistiksel özellik toplamda 480 öznitelik elde edilmiştir. Bu veri setinde kernel-SVM algoritması kullanılarak sınıflandırma yapılmış ve %78.9 doğruluk oranına ulaşılmıştır [170]. Sharma vd., 32 sağlıklı ve 49 şizofreni hastası bireyin yer aldığı çalışmalarında, 19 kanallı EEG sinyallerini kullanmıştır. Farklı ön işlemler sonrasında elde edilen veri setine DT, SVM, RF, Naive Bayes, XGBoost, Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM), Evrişimli Sinir Ağları (Convolutional Neural Networks, CNN) ve LSTM-CNN algoritmalarını uygulanmıştır. Çalışma sonuçlarına göre, SVM algoritmasının %100 başarı oranı ile şizofreni teşhisinde kullanılabileceği belirtilmiştir [171]. 28 denekten elde edilen 19 kanallı EEG verileri, farklı frekans bantlarına ayrılarak analiz edilmiştir. Generalized Partial Directed Coherence (GPDC) ve Directed Transfer Function (DTF) yöntemleri ile sinyaller arasındaki nedensel ilişkiler anlaşılmıştır. Elde edilen veri setine RF algoritması uygulanarak %87 doğruluk oranı elde edilmiştir [172]. 68 deneğin katıldığı bir çalışmada, işitsel görevler sırasında alınan EEG sinyalleri kaydedilmiştir. Bu sinyallerden sensör ve kaynak düzeyinde öznitelikler çıkarılmış ve 1-20 arasında değişen öznitelik sayıları SVM algoritmasıyla analiz edilmiştir. Elde edilen doğruluk değerlerinin ortalama %78.24 olduğu raporlanmıştır [173]. İncelenen çalışmalar makine öğrenme yöntemlerinin şizofreni alanında etkin bir şekilde kullanıldığını göstermektedir.


Şizofreni alanında derin öğrenme odaklı çalışmalara sıklıkla rastlanmaktadır. Nairo ve Alamo, EEG sinyallerini ve derin öğrenme modelini kullanarak şizofreni hastalarını sağlıklı bireylerden ayırt

etmeye çalışmıştır. Pearson Korelasyon Katsayısı ile çoklu kanallar arasındaki ilişkileri anlamlandırdıkları bu çalışmada CNN modeli kullanılarak %90 doğruluk elde edildiği belirtilmiştir [174]. 28 denekten alınan dinlenme durumu EEG verilerine Katz Fraktal Boyut ve Yaklaşık Entropi yöntemleri uygulanarak zaman-etki alanı varyans ölçümleri hesaplanmıştır. 32 nöron kullanılan LSTM modeli, 6790 örnekle çalıştırılarak %99 doğruluk oranı elde edilmiştir [175]. Başka bir çalışmada, iki farklı EEG veri setinde hibrit bir derin öğrenme yöntemi kullanılmıştır. CNN ve LSTM tabanlı oluşturulan Şizofreni Hibrit Sinir Ağı (SzHNN) adı verdikleri yöntemde %99.9 oranında diğer yöntemlerden daha yüksek başarı sağlandığı vurgulanmıştır [176]. 11 katmanlı CNN modeli, 14 sağlıklı ve 14 şizofreni hastası bireyden alınan EEG kayıtlarına uygulanmıştır. Konu bazlı olmayan testlerde %98.07, konu bazlı testlerde ise %81.26'lık doğruluk oranları elde edilmiştir [177]. Şizofreni hastalığının otomatik teşhisi için zaman-frekans analizi ve CNN modelinin kullanıldığı bir çalışmada, Smoothed Pseudo-Wigner–Ville Distribution (SPWVD) vb. teknikler uygulanmıştır. SPWVD tabanlı 4 evrişimli katmana sahip CNN modeli ile %93.36 doğruluk elde edilmiştir [178]. 101 denekten alınan 64 kanallı ham EEG veri setine CNN (%75.9) ve CNN-LSTM (%71.5) derin öğrenme modelleri uygulanmıştır. Araştırmacılar, sınıflandırma performansında T8 ve C3 kanallarının, delta ve gama bantlarının etkisinin yüksek olduğunu belirtmişlerdir [179]. Hibrit bir derin öğrenme modelinde, EEG sinyallerinden zaman-frekans alanı özellikleri çıkarılarak görüntü dizisine dönüştürülmüştür. CNN ve LSTM modelleri tabanlı hibrit yöntemde bulanık entropi kullanılarak %99.2'lik bir doğruluk oranına ulaşılmıştır [180]. 28 kişilik bir denek grubundan elde edilen EEG verilerine AlexNet, ResNet-18, VGG-19 ve Inception-v3 yöntemleri uygulanmıştır. Bu yöntemlerden elde edilen çıktılar, SVM algoritmasına girdi olarak kullanılmıştır. Çalışmada ResNet-18 ve SVM algoritması kullanılarak merkezi bölgede %99.65'lik bir performans görülmüştür [181]. Alzheimer hastalığı ve şizofreni teşhisinde ham EEG verilerinin kullanıldığı bir çalışmada, CNN modelinin yöntemlerinden olan AC, Grad-CAM ve Saliency Map tercih edilmiştir. Bu yöntemler kullanılarak %98'lik bir başarı elde edilmiştir [182]. Derin öğrenme modelleri ve oluşturulan hibrit yaklaşımlar yeterli veri ve uygun eğitimle etkileyici sonuçlar verebilmektedir.

Bu çalışmalar incelendiğinde kullanılan veri setlerinin ve bu veri setlerine uygulanan ön işleme ve sınıflandırıcıların farklı olduğu görülmektedir. Bu nedenle tüm çalışmalarda sinyal-gürültü oranlarından kaynaklanan performans farklılıkları görülmektedir. Bu değişikliklere rağmen makine öğrenimi çalışmalarının çoğunun, verilerden genellemeler yapabilmesi ve son teknolojiye benzer veya daha iyi sonuçlar elde edebilmesi açısından şizofreni tespiti konusunda etkili olması dikkat çekicidir. Kuantum makine öğreniminin sağlık alanında kullanımı yaygınlaşmaya başlamasına rağmen, literatürde şizofreni alanında EEG sinyalleri ile gerçekleştirilen bir kuantum uygulamasına rastlanmamıştır.

5.2.2. EEG Şizofreni Veri Seti


Bu çalışmada 39 sağlıklı ve 45 ergen erkek bireyden toplanan EEG sinyallerinden oluşan bir veri seti kullanılmıştır [183]. Etkilenen bireylerin (çocukluk çağı şizofreni, şizofreni ve şizoaffektif bozukluklar) tanıları Ruh Sağlığı Araştırma Merkezi'nde (MHRC) çalışan uzman doktorlar tarafından belirlenmiştir. Hastalığa yakalanan bireylerin yaşları 10 yıl 8 ay ile 14 yıl arasında değişirken, sağlıklı bireylerin yaşları ise 11 ile 13 yıl 9 ay arasında değişmektedir. Hem hasta hem de kontrol grubundaki bireylerin yaş ortalaması 12 yıl 3 aydır. Elektrot yerleşimi için 10-20 sistemine göre 16 kanaldan EEG sinyalleri elde edilmiştir (O1, O2, P3, P4, Pz, T5, T6, C3, C4, Cz, T3, T4, F3, F4, F7 ve F8). Kayıt sırasında bireylerin gözlerinin kapalı, uyanık ve rahat bir pozisyonda oldukları belirtilmiştir. Bu çalışmada yapay EEG segmentleri kullanılmamış olup, kayıtlar 128 Hz örnekleme hızında yapılmıştır. Bu veri seti, 84 ergen birey için her kanaldan 1 dakikalık bölümlerin kaydedilmesiyle elde edilmiştir [184]. Veri setinin elde edildiği kanallar ve bir hastadan alınan EEG sinyal verileri Şekil 5.6'da gösterilmektedir.



5.2.3. Deneysel Çalışma


Bu çalışmada, kuantum tabanlı SVM algoritmasının şizofreni tespitindeki performansını değerlendirmek için bir *EEG şizofreni* veri seti kullanılmıştır. Örüntü tanıma süreci; veri toplama, ön işleme adımları, özellik çıkarma ve sınıflandırma olmak üzere dört aşamada gerçekleştirilmiştir.

İlk aşama veri toplama, ayrık dalgacık dönüşümleri, bilgi ölçüm yöntemleri ve istatistiksel teknikleri içermektedir. Daha sonra boyut azaltma yöntemlerinde PCA kullanılarak veriler farklı boyutlarda analize hazır hale getirilmiştir. Hazırlanan veriler, IBM Quantum Lab ortamında klasik sınıflandırma algoritmalarıyla analiz edilmiştir. Boyutu azaltılan veriler, farklı özellik haritaları kullanılarak bit formatından kübit formatına dönüştürülmüş ve kuantum tabanlı makine öğrenme modelleri uygulanmıştır. Klasik ve kuantum tabanlı modellerin performansları, doğruluk ve zaman açısından analiz edilerek EEG sinyallerine uygunluğu incelenmiştir. Yapılan çalışmanın blok diyagramı Şekil 5.7’de sunulmaktadır.




Şekil 5.7. Önerilen yöntemin şematik görünümü

Şizofreni veri setinde, farklı beyin bölgelerini temsil eden dört kanal seçilmiştir. Bu kanallar; frontal bölgeden F4, temporal bölgeden T3, oksipital bölgeden O1 ve merkezi bölgeden Cz'dir. Seçilen bu kanallara ayrık dalgacık dönüşümü uygulanmıştır. Şekil 5.8’de veri setinin hazırlanma sürecinde gerçekleştirilen işlemler gösterilmiştir.




Şekil 5.8. Dördüncü seviye ayrık dalgacık dönüşümünün blok diyagramı

EEG verilerinden özellikler elde etmek için, ham EEG sinyalleri ilk olarak verileri belirli bir aralığa getirecek şekilde normalize edilmiştir. Normalleştirme işleminin ardından, sinyaller temel ana dalgacık modellerinden biri olan Daubechies 2 dalgacığı kullanılarak alt bileşenlere ayrıştırılmıştır. Normalleştirilmiş verilere 4. seviye Ayrık Dalgacık Dönüşümü (DWT) uygulanmış ve bunun sonucunda Delta (0,5–4 Hz), Teta (4–8 Hz), Alfa (8–15 Hz), Beta (14–30 Hz) ve Gamma (30–60 Hz) dalgaları elde edilmiştir [185]. Şekil 5.9’da, bir hastanın Cz kanalından elde edilen EEG sinyaline ayrık dalgacık dönüşümünün uygulanması sonucu elde edilen alt bant sinyalleri gösterilmektedir.



Şekil 5.9. Cz kanalındaki EEG sinyaline ayrık dalgacık dönüşümü uygulanarak elde edilen dalgalar

Ayrık Dalgacık Dönüşümü işleminin ardından her kanal için elde edilen beş farklı dalgacık tipine ortalama, varyans, standart sapma, Shannon entropisi ve logaritmik entropi yöntemleri uygulanmıştır. İstatistiksel yöntemlerin uygulanması sonucunda, çalışmada kullanılmak üzere 25 özellik ve bir çıktı vektöründen oluşan bir veri seti elde edilmiştir. Bu veri setinin Kuantum Destek Vektör Makinesi'nde kullanılabilmesi için boyutu azaltılmıştır. PCA'nın uygulanma aşaması Şekil 5.10'da gösterilmektedir.




Şekil 5.10. PCA'nın veri kümesine uygulanmasını gösteren bir blok diyagram

Öncelikle, her EEG alt bandına çeşitli ön işleme adımları uygulanmıştır. Yaygın olarak kullanılan boyut azaltma tekniği PCA kullanılarak, veri boyutu 3 ile 15 arasında değişen şekilde azaltılmıştır. Özellik çıkarma ve boyut indirgeme aşamasıyla oluşturulan özellik vektörleri, sinyalleri temsil eden farklı özellikleri içermektedir. Elde edilen veri setinde, çeşitli makine öğrenme algoritmaları kullanılarak bu algoritmaların performansları test edilmiştir.

Klasik Makine Öğrenimi Algoritmalarından Elde Edilen Sonuçlar

Çalışmada, EEG sinyalleri kullanılarak hazırlanan veri seti, PCA yöntemi ile 13 farklı özelliğe dönüştürülmüştür. Dört kanaldan elde edilen EEG sinyallerinin her biri için Rastgele Orman, Lojistik Regresyon, Karar Ağacı, K-En Yakın Komşu, Naive Bayes ve Destek Vektör Makinesi algoritmaları, 3'ten 15'e kadar değişen öz nitelikler için uygulanmıştır. Her kanala ayrı ayrı uygulanan bu farklı makine öğrenimi yöntemlerine göre elde edilen doğruluk değerlerini gösteren grafikler, Şekil 5.11'de sunulmuştur.



Şekil 5.11. Klasik makine öğrenmesi algoritmalarının 4 kanal için performans grafiği

Şekil 5.11'deki grafikler incelendiğinde, en iyi performansın merkezi bölgede yer alan Cz ve temporal bölgedeki T3 kanallarından elde edildiği görülmektedir. Bu nedenle Tablo 5.3'de Cz ve T3 kanallarından elde edilen doğruluk oranları verilmiştir.

Tablo 5.3. Klasik sınıflandırıcılar için Cz ve T3 kanalından elde edilen doğruluk oranları

Öznitelik	Cz Kanalı						T3 Kanalı					
	Metotlar											
	Sayısı	RF	LR	DT	KNN	NB	SVM	RF	LR	DT	KNN	NB
3	100.0	92.31	100.0	96.15	96.15	100.0	92.31	80.77	96.15	96.15	96.15	96.15
4	96.15	92.31	100.0	96.15	96.15	100.0	96.15	84.62	96.15	100.0	96.15	96.15
5	96.15	92.31	96.15	92.31	96.15	100.0	96.15	84.62	96.15	100.0	92.30	96.15
6	96.15	100.0	100.0	100.0	92.30	100.0	96.15	100.0	96.15	100.0	96.15	96.15
7	96.15	100.	96.15	100.0	92.30	100.0	96.15	96.15	96.15	100.0	96.15	92.31
8	96.15	100.0	96.15	100.0	92.30	96.15	96.15	96.15	96.15	100.0	96.15	88.46
9	96.15	100.0	96.15	100.0	92.30	92.31	96.15	96.15	96.15	100.0	88.46	88.46
10	97.06	100.0	85.29	100.0	92.30	88.46	96.15	96.15	96.15	100.0	92.30	80.77
11	96.15	100.0	96.15	100.0	92.30	88.46	96.15	96.15	96.15	100.0	92.30	80.77
12	96.15	100.0	96.15	96.15	96.15	88.46	96.15	96.15	96.15	96.15	92.30	80.77
13	100.0	100.0	100.0	96.15	96.15	80.77	96.15	96.15	96.15	96.15	92.30	84.62
14	96.15	100.0	92.31	96.15	96.15	73.08	96.15	96.15	96.15	100.0	92.30	76.92
15	96.15	100.0	92.31	100.0	96.15	69.23	96.15	96.15	96.15	92.31	92.30	69.23

Cz kanalında, öznitelik sayısına göre çoğunlukla en yüksek doğruluk oranı, öznitelik sayısı 6-15 arasında %100.0 olarak Lojistik regresyon algoritmasından elde edilmiştir. T3 kanalında ise en iyi performans, öznitelik sayısı 4-11 arasında %100 doğruluk oranıyla KNN algoritmasından elde edilmiştir. Genel olarak, dört kanal için Lojistik Regresyon algoritması diğer algoritmalarından daha yüksek performans göstermiştir. SVM algoritmasında ise öznitelik sayısı arttıkça doğruluğun düştüğü gözlemlenmiştir. Cz ve T3 kanallarından 5 özellik için elde edilen sınıflandırma performans metriklerinin sonuçları Tablo 5.4’de sunulmaktadır.


Tablo 5.4. Cz ve T3 kanallarından 5 kübit için elde edilen sınıflandırma performansları

Sınıflandırma Performans Metrikleri	Cz Kanalı						T3 Kanalı					
	Metotlar											
	RF	LR	DT	KNN	NB	SVM	RF	LR	DT	KNN	NB	SVM
Özgüllük	1.00	0.81	1.00	0.81	0.90	1.00	0.90	0.69	0.90	1.00	0.81	0.90
Hassasiyet	1.00	0.88	1.00	0.88	0.94	1.00	0.94	0.76	0.94	1.00	0.88	0.94
Duyarlılık	0.94	1.00	0.94	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
F1-Skor	0.96	0.93	0.97	0.93	0.96	1.00	0.96	0.86	0.96	1.00	0.93	0.96

Her iki kanalda da RF ve SVM yöntemleri genel olarak yüksek özgüllük değerleri sergilerken, LR ve DT yöntemlerinde belirli bir değişkenlik gözlemlenmiştir. RF, SVM ve DT yöntemleri yüksek hassasiyet değerlerine sahipken, genel olarak tüm yöntemler için yüksek duyarlılık değerleri gözlemlenmiştir. Bu kanallarda, 5 kübit için KNN algoritmasının yüksek performansı ise açıkça öne çıkmaktadır.

QSVM Algoritmasından Elde Edilen Sonuçlar

Çalışma kapsamında kuantum tabanlı makine öğrenme algoritmalarından biri olan QSVM kullanılmıştır. QSVM'nin uygulanabilmesi için klasik bit verileri, kuantum bilgisayarın çalışabileceği kubitlere dönüştürülmüştür. Bu süreçte, 13 farklı özellik haritası, her biri 2 tekrarlı olarak kullanılmıştır. Çalışmada kullanılan 3 kubit ve tek tekrar içeren özellik haritaları Şekil 5.11'de gösterilmiştir. Bu haritalar, Qiskit 0.44.3 (IBM, Armonk, NY, ABD) kütüphanesi ile oluşturulmuştur. Özellik haritaları, verilerin Hilbert uzayında kodlanmasını sağlar ve bu haritalar, QSVM'nin çekirdeği olarak işlev görür. Şekil 5.12'de gösterilen Pauli özellik haritası, ZZ özellik haritası ve Z özellik haritası, Qiskit'in sunduğu özellik haritalarını temsil eder. Özellik haritalarının analizi, tüm haritalarda Hadamard kapısının tüm kubitlere uygulandığını ve kubitleri süperpozisyon durumuna getirdiğini ortaya koymuştur. Süperpozisyon, bir kubitin aynı anda birden fazla durumda olma yeteneğini ifade eder. ZZ özellik haritasında, verilerin sonraki kubitlerle mi yoksa tüm sonraki kubitlerle mi dolanık hale geleceği, doğrusal (lineer) veya tam (full) özellik kullanılarak belirlenir. Pauli X, Y ve Z özellik haritaları dışında tüm haritalarda, bir kubitin değerinin diğer bir kubitin değeri temel alınarak oluşturulduğu kuantum dolanıklığı olarak bilinen işlemi gerçekleştiren CNOT kapıları kullanılmaktadır. P fonksiyonu, tüm haritalarda kubitler arasındaki etkileşimi temsil ederken, Rx kapısı, kubitin x ekseninde belirli bir açıyla dönmesini sağlar. Oluşturulan özellik haritaları, QSVM'de çekirdek olarak hizmet eder. Son aşamada, kuantum çekirdek dönüşümü kullanılarak doğrusal olmayan yüksek boyutlu bir özellik alanı oluşturulur ve etiketli verileri ayırmak için klasik bir SVM tarafından kullanılan bir hiper düzlem oluşturularak sınıflandırma işlemi gerçekleştirilir [137]. Özellik haritalarının her biri, bağımsız olarak farklı kuantum kapılarıyla oluşturulmuştur ve QSVM'nin performansını artırmak için kullanılmıştır.



Şekil 5.12. Çalışmada kullanılan kuantum özellik haritaları

Özellik haritalarının uygulanması sırasında, kübit sayısı 3 ile 15 arasında değiştirilmiştir. Her bir özellik sayısı için kübit formuna dönüşüm işlemi ayrı ayrı gerçekleştirilmiştir. Klasik makine öğrenmesi algoritmaları kullanıldığında, dört kanal arasında en yüksek doğruluk değerleri Cz ve T3 kanallarından elde edilmiştir. Cz kanalı için QSVM algoritmasıyla elde edilen doğruluk değerleri Tablo 5.5'te sunulmuştur.

Tablo 5.5. Cz kanalı EEG sinyallerine farklı özellik haritaları uygulandığında elde edilen QSVM doğruluk oranları

Kübit Sayısı	ZZFeatureMap		Pauli FeatureMap											
	Linear	Full	Z	X	Y	XX	XZ	ZX	YZ	ZY	Z, YY	Z, XX	Z, Y, ZZ	
3	100.0	100.0	100.0	100.0	34.61	92.30	76.92	88.46	92.30	80.76	69.23	88.46	73.07	
4	100.0	92.30	100.0	100.0	34.61	80.76	80.76	84.61	96.15	80.76	73.07	92.30	73.07	
5	92.30	76.92	100.0	100.0	34.61	92.30	84.61	80.76	84.61	76.92	76.92	80.76	65.38	
6	92.30	73.07	100.0	100.0	34.61	73.07	69.23	76.92	84.61	73.07	61.53	73.07	65.38	
7	84.61	65.38	100.0	100.0	34.61	96.15	61.53	80.76	65.38	65.38	53.84	61.53	46.15	
8	80.76	53.84	100.0	100.0	34.61	84.61	46.15	73.07	57.69	57.69	42.30	53.84	38.46	
9	76.92	50.00	100.0	100.0	34.61	80.76	38.46	57.69	50.00	53.84	34.61	50.00	38.46	
10	76.92	38.46	100.0	100.0	34.61	91.17	55.88	73.52	61.76	58.82	50.00	61.76	50.00	
11	69.23	34.61	100.0	100.0	34.61	80.76	34.61	34.61	34.61	34.61	34.61	34.61	34.61	
12	61.53	34.61	100.0	100.0	34.61	57.69	34.61	34.61	34.61	34.61	34.61	34.61	34.61	
13	57.69	34.61	96.15	100.0	34.61	73.07	34.61	34.61	34.61	34.61	34.61	34.61	34.61	
14	46.15	34.61	96.15	100.0	34.61	42.30	34.61	34.61	34.61	34.61	34.61	34.61	34.61	
15	42.30	34.61	96.15	100.0	34.61	46.15	34.61	34.61	34.61	34.61	34.61	34.61	34.61	

Tablo 5.5 incelendiğinde, ZZ özellik haritalarının dolanıklığın lineer olduğu durumlarda daha iyi performans sağladığı gözlemlenmiştir. Z ve X özellik haritaları dışında, QSVM'nin doğruluk oranı 11-15 kübit aralığında oldukça düşük seviyelerde kalmıştır. En iyi performans, 4 kübit kullanıldığında elde edilmiştir. X özellik haritası ise tüm kübit değerlerinde %100 performansa ulaşmıştır. 5 kübitten itibaren, çeşitli özellik haritalarında performans düşüşü gözlemlenmiştir. Tablo 5.6'da ise diğer sınıflandırma performans metriklerine göre Cz kanalında 5 kübit için elde edilen sonuçlar sunulmuştur.

Tablo 5.6. Cz kanalından 5 kübit için elde edilen sınıflandırma performans metriklerinin sonuçları

Sınıflandırma Performans Metrikleri	ZZFeatureMap		Pauli FeatureMap										
	Lineer	Full	Z	X	Y	XX	XZ	ZX	YZ	ZY	Z, YY	Z, XX	Z, Y, ZZ
Özgüllük	0.81	0.61	1.00	1.00	0.34	0.81	0.72	0.64	0.72	0.61	0.63	0.64	0.50
Kesinlik	0.88	0.70	1.00	1.00	0.00	0.88	0.82	0.70	0.82	0.70	0.76	0.70	0.52
Duyarlılık	1.00	0.92	1.00	1.00	0.00	1.00	0.93	1.00	0.93	0.92	0.86	1.00	0.90
F1-Skoru	0.93	0.79	1.00	1.00	0.00	0.93	0.87	0.82	0.87	0.79	0.81	0.82	0.66

Cz kanalında 5 kübit için elde edilen performans değerleri incelendiğinde, ‘X’ ve ‘Z’ özellik haritalarının çeşitli metrikler genelinde iyi bir performans sergilediği, ‘Y’ özellik haritasının ise oldukça düşük performans sergilediği gözlemlenmiştir. Tablo 5.7’de QSVM algoritması kullanılarak T3 kanalında farklı özellik haritalarının uygulanmasıyla elde edilen sonuçlar sunulmuştur.

Tablo 5.7. T3 kanalı EEG sinyallerine farklı özellik haritaları uygulandığında elde edilen QSVM doğruluk oranları


Kübit Sayısı	ZZFeatureMap		Pauli FeatureMap										
	Lineer	Full	Z	X	Y	XX	XZ	ZX	YZ	ZY	Z, YY	Z, XX	Z, Y, ZZ
3	92.30	92.30	96.15	96.15	34.61	92.30	84.61	92.30	88.46	88.46	88.46	88.46	84.61
4	92.30	92.30	96.15	100.0	34.61	80.76	84.61	92.30	88.46	88.46	92.30	84.61	84.61
5	92.30	80.76	100.0	100.0	34.61	100.0	80.76	84.61	88.46	84.61	84.61	84.61	76.92
6	92.30	76.92	100.0	100.0	34.61	84.61	73.07	80.76	80.76	76.92	69.23	69.23	76.92
7	88.46	73.07	100.0	100.0	34.61	92.30	65.38	76.92	73.07	69.23	73.07	69.23	61.53
8	88.46	65.38	100.0	100.0	34.61	88.46	65.38	65.38	65.38	65.38	53.84	65.38	46.15
9	80.76	53.84	100.0	100.0	34.61	88.46	46.15	57.69	50	42.30	38.46	42.30	34.61
10	76.92	38.46	100.0	100.0	34.61	69.23	34.61	38.46	38.46	34.61	34.61	34.61	34.61
11	73.07	34.61	100.0	100.0	34.61	80.76	34.61	38.46	34.61	34.61	34.61	34.61	34.61
12	61.53	34.61	100.0	100.0	34.61	46.15	34.61	38.46	34.61	34.61	34.61	34.61	34.61
13	57.69	34.61	96.15	100.0	34.61	69.23	34.61	34.61	34.61	34.61	34.61	34.61	34.61
14	38.46	34.61	96.15	96.15	34.61	38.46	34.61	34.61	34.61	34.61	34.61	34.61	34.61
15	38.46	34.61	96.15	96.15	34.61	42.30	34.61	34.61	34.61	34.61	34.61	34.61	34.61

T3 kanalından alınan EEG sinyallerine göre elde edilen sonuçlar incelendiğinde, 2 tekrarlı özellik haritaları için en iyi performansın Z ve Pauli X özellik haritası ile elde edildiği sonucuna ulaşılmıştır. Diğer özellik haritaları kullanıldığında, kübit sayısı arttıkça doğruluk oranının azaldığı gözlemlenmiştir. Tablo 5.8’de T3 kanalı için elde edilen performans ölçümlerinin sonuçları verilmiştir.

Tablo 5.8. T3 kanalından 5 kübit için elde edilen sınıflandırma performans metriklerinin sonuçları

Sınıflandırma Performans Metrikleri	ZZFeatureMap		Pauli FeatureMap										
	Lineer	Full	Z	X	Y	XX	XZ	ZX	YZ	ZY	Z, YY	Z, XX	Z,Y,ZZ
Özgüllük	0.81	0.64	1.00	1.00	0.34	1.00	0.70	0.69	0.75	0.69	0.69	0.69	0.60
Kesinlik	0.88	0.70	1.00	1.00	0.00	1.00	0.82	0.76	0.82	0.76	0.76	0.76	0.64
Duyarlılık	1.00	1.00	1.00	1.00	0.00	1.00	0.87	1.00	1.00	1.00	1.00	1.00	1.00
F1-Skoru	0.93	0.82	1.00	1.00	0.00	1.00	0.84	0.86	0.90	0.86	0.86	0.86	0.78

Aşağıda, her iki kanal için de en iyi performansı sergileyen Z ve Pauli X özellik haritaları kullanılarak elde edilen sonuçların grafiksel gösterimi sunulmuştur. Şekil 5.13’e göre, en iyi performansın Cz ve T3 kanallarında Pauli X ve Z özellik haritalarının kullanılmasıyla elde edildiği görülmüştür. Bu özellik haritalarında kübit sayısının analiz sonuçlarına herhangi bir etkisi olmamıştır. Ancak O1 ve F4 kanalları için kübit sayısındaki değişikliklerin doğruluk oranını etkilediği gözlemlenmiştir.



Şekil 5.13. 4 kanal için Pauli X ve Pauli Z Özellik Haritalarını kullanan QSVM algoritmasının performans grafiği

5.2.4. Sonuçlar ve Tartışma

Bu çalışmada, şizofreni tanısına yönelik olarak hem şizofreni hastalarından hem de sağlıklı bireylerden elde edilen EEG veri setlerine çeşitli klasik ve kuantum tabanlı makine öğrenmesi algoritmaları uygulanmıştır. Klasik makine öğrenmesi yöntemleri kullanılarak elde edilen sonuçlara göre, Cz kanalı için en iyi performans LR algoritması, T3 kanalı için ise KNN algoritması göstermiştir. LR, Cz kanalında 6-15 özellik için %100 doğruluk elde ederken, KNN, T3 kanalında 2-11 özellik için en yüksek performans vermiştir. Dört kanalın tümünde, özellik sayısı arttıkça destek vektör makinesi (SVM) algoritmasının performansında bir düşüş olduğu gözlemlenmiştir. Kuantum destek vektör makinesi algoritmasının, SVM algoritmasının kuantum bilgisayarlar için uyarlanmış hali olduğu göz önüne alındığında, bu performans düşüşü dikkat çekicidir. Klasik makine öğrenmesi yöntemleriyle karşılaştırıldığında, QSVM algoritması belirli özellik haritalarının, özellikle X ve Z özellik haritalarının kullanıldığı durumlarda benzer ve bazen biraz daha iyi sonuçlar vermiştir.

QSVM algoritması ile elde edilen sonuçlar incelendiğinde, özellik haritalarının kuantum makine öğrenmesi yöntemlerinin performansı üzerinde önemli bir etkiye sahip olduğu belirlenmiştir. Her kanal için elde edilen sonuçlara göre, QSVM algoritması, kübit sayısı düşük olduğunda tüm özellik haritaları için daha iyi performans göstermiştir. Z ve X özellik haritaları dışındaki diğer haritalarda, 5 kübit sonrasında performansta bir düşüş meydana geldiği gözlemlenmiştir. Analizler devam ettirildiğinde, özellikle 10. kübitten itibaren algoritmanın başarımında ciddi oranda kayıplar tespit edilmiştir. Kübit sayısının artması ve CNOT ile Rx kapılarının kullanılması, devrelerin karmaşıklığını artırarak bu sonuca yol açtığı belirlenmiştir. Tüm devreler dikkate alındığında, performans açısından kübit sayısındaki artıştan yalnızca Hadamard kapıları ve P fonksiyonunu içeren devrelerin etkilenmediği tespit edilmiştir. CNOT kapılarının kullanıldığı durumlarda, devrenin karmaşıklığının arttığı, doğruluğun azaldığı ve bir kübitin durumu, devredeki hedef kübitin durumunu etkilediği için algoritmanın yürütme süresinde de artış yaşandığı belirlenmiştir. Kübit sayısı arttığında, ZZ özellik haritasında dolanıklık parametresi doğrusal olarak seçildiğinde, tam özelliğin seçilmesine kıyasla doğrulukta daha küçük bir düşüşe neden olduğu gözlemlenmiştir. Y özellik haritası için QSVM algoritması çalıştırıldığında ise 3'ten 15'e kadar tüm kübitlerde sonuçların oldukça düşük olduğu tespit edilmiştir. Bu özellik haritası için devre tekrarı artırıldığında sonuçların iyileştiği görülmüştür. Ancak bu çalışmada tüm özellik haritalarının parametreleri sabit tutulduğundan, bu yön analize dahil edilmemiştir. Y özellik haritasının 2 tekrarlı olarak çalıştırılmasının bu veri seti için uygun olmadığı sonucuna varılmıştır.

Oluşturulan modelde, klasik ve kuantum makine öğrenimi yöntemleri doğruluk oranları ve algoritma yürütme süreleri açısından karşılaştırılmıştır. Tüm analizler, sonuçların karşılaştırılabilmesi için IBM Quantum Lab ortamında gerçekleştirilmiştir. Klasik makine öğrenmesi algoritmalarının, işlem sürelerinin genel olarak 0,01 saniye gibi oldukça kısa bir sürede

tamamlandığı tespit edilmiştir. Bu, klasik yöntemlerin yüksek işlem hızıyla dikkat çektiğini göstermektedir. QSVM algoritmasının yürütme süresi, kullanılan özellik haritasına bağlı olarak değişiklik göstermiştir. Genel olarak, kübit sayısının az olduğu durumlarda analizler 1 dakikadan kısa sürede tamamlanmıştır. Ancak kübit sayısı arttıkça devrelerin karmaşıklığı artmış ve bu da yürütme sürelerinin önemli ölçüde uzamasına neden olmuştur. Özellik haritaları karşılaştırıldığında, Pauli X ve Z özellik haritalarının QSVM algoritması için en kısa yürütme sürelerine sahip olduğu bulunmuştur. Kuantum bilgisayarlar yerine kuantum simülatör ortamının kullanılması, çalışmanın yürütme süresi üzerinde olumsuz bir etki yaratmıştır. Kuantum bilgisayarlarda işlemlerin sıraya alınması ve kamuya açık kuantum bilgisayarlarda maksimum 7 kübit sınırlamasının bulunması, analizler için gerçek kuantum bilgisayarları yerine kuantum simülatörlerini tercih etmemize neden olmuştur. Tablo 5.9’da, bu çalışma için kullanılan veri seti ile gerçekleştirilen farklı çalışmalara yer verilmiştir.

Tablo 5.9. EEG şizofreni veri setiyle ilgili bazı çalışmalardan performans karşılaştırmaları

Araştırmacılar	Ön işleme	Yöntemler	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)
Piryatinska vd. [186]	ϵ -karmaşıklık fonksiyonu	SVM RF	89.38 85.30	88.6	82.6
Naira ve Alamo [174]	Pearson Korelasyon Katsayısı	CNN	90.00	90.00	90.00
Bougou vd. [187]	Butterworth filtresi Bağlantı Analizi	RF	82.36	-	-
Phang vd. [188]	Zaman alanı VAR katsayıları, Frekans etki alanı PDC, Topolojik tabanlı CN önlemleri	MDC-CNN DVM	93.06 85.83	95.00 87.50	91.11 88.89
Singh vd. [189]	Butterworth bant geçişi Filtre, Hjorth tanımlayıcıları	CNN-SF LSTM	94.08 76.78	92.70 80.72	95.31 73.18
Phang vd. [190]	VAR, PDC, CN	SVM CNN RNN	90.37 91.69 77.50	91.11 91.11 86.67	89.64 92.50 66.79
Aslan ve Akın [191]	Kısa Zamanlı Fourier Dönüşümü	CNN (VGG-16)	95.00	95.00	95.00
Rajesh vd. [192]	Simetrik Ağırlıklı Yerel İkili Model	Logitboost	91.66	89.74	93.33

Araştırmacılar	Ön işleme	Yöntemler	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)
Khodabakhsh vd. [193]	Beyin Fonksiyonel Bağlantısı	MDC-CNN	90.44	97.78	81.79
		FC-UNET	94.11	91.66	100.0
Supakar vd. [194]	Rastgele Projeksiyon (Random Projection, RP)	RNN-LSTM	98.00	98.00	98.00
Xin vd. [195]	Normal ve Geliştirilmiş yüksek dereceli fonksiyonel bağlantı matrisleri, Sonlu Dürtü Tepkisi (FIR).	DVM	94.05	95.56	92.31
Sairamya vd. [196]	Ayrık dalgacık dönüşümü, Gevşetilmiş Yerel Komşu Farkı Modeli (Relaxed Local Neighbor Difference Pattern, RLNDiP).	ANN	100.0	100.0	100.0
Aslan ve Akın [197]	Hilbert Huang Dönüşümü, Hilbert Spektrumu.	VGG16	96.00	96.00	96.00
		Xception,	95.00	95.50	97.50
		ResNet152	95.00	95.50	94.50
		BaşlangıçV3	87.50	88.50	92.00
Sobahi vd. [198]	Daubechies 4. dereceden dalgacık fonksiyonu, Yerel ikili desen.	CNN	97.70	97.80	97.60
Alves vd. [199]	Granger nedensellik testi, Pearson korelasyon katsayısı, Spearman'ın korelasyon ölçümleri.	CNN	52.00	73.00	-
			57.00	100.0	-
			62.00	100.0	-
Kumar vd. [200]	Simetrik Ağırlıklı Yerel İkili Modeller (SLBP), Yerel Varyans Histogramı (HLV)	AdaBoost	92.85	97.80	87.20
Balasubramanyan vd. [201]	Butterworth bant geçiren filtre, WICA, Rölyef algoritması.	Hibrit Gri Kurt-Yarasa Algoritması ANFİS	99.51	95.87	-
Önerilen Yöntem	DWT, İstatistiksel Yöntemler	QSVM (Pauli X, Z)	100.0	100.0	100.0

Tablo 5.9’da bu çalışmalarda kullanılan ön işleme ve sınıflandırma algoritmaları sunulmuştur. Analizler, klasik makine öğrenme algoritmaları ve derin öğrenme modelleri kullanılarak gerçekleştirilmiştir. Literatürde kullanılan ön işleme aşamalarındaki ve yöntemlerindeki farklılıklar, elde edilen performansların da farklılık göstermesine neden olmuştur. Bu çalışmada veri setine ön işleme aşamasında Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform- DWT) yöntemi ve çeşitli istatistiksel teknikler uygulanarak veri setinin en verimli hale getirilmesi amaçlanmıştır. Literatürdeki diğer çalışmalardan farklı olarak, analizler tek kanal üzerinden gerçekleştirilmiştir. Kuantum platformlarının sunduğu sınırlı kübit sayısı nedeniyle, PCA algoritması ile veri setinin boyutu kademeli olarak azaltılmıştır. Bu işlemler sonucunda elde edilen yeni veri seti, QSVM ve klasik sınıflandırma algoritmaları ile deneysel olarak işlenmiştir. Analiz sonuçları incelendiğinde, önerilen yöntemin performansının daha önce yapılan çalışmalara göre daha yüksek olduğu tespit edilmiştir.

Yapılan analizler sonucunda, kuantum makine öğrenme yönteminin, yeni gelişen bir teknoloji olmasına rağmen, şizofreni teşhisinde kullanılan veri setinde Cz kanalında %100 doğruluğa ulaştığı görülmüştür. Bu da kuantum teknolojilerinin, klasik öğrenme yöntemlerinin yerini alabilecek kadar başarılı olduğunu göstermektedir. Araştırmada, en iyi sonuçlar sınırlı sayıda kübit kullanılarak elde edilmiştir. Ancak, daha yüksek sinyal-gürültü oranına sahip veri kümeleri, daha fazla kübit gerektirebilir. Ancak bu durum, EEG sınıflandırması açısından genel olarak ümit vericidir. Deneysel çalışma sonuçları, kuantum teknolojilerinin sağlık hizmetlerine yönelik potansiyelini göstermektedir. Şizofreni alanında yaptığımız çalışma, sınırlı sayıda bileşen kullanırken bile kuantum makine öğreniminin şizofreni tanısına yardımcı olabileceğini ve klasik yaklaşımlara kıyasla önemli bir alternatif olabileceğini öne sürmektedir.

5.3. Yalan Tespit Sistemleri: Bir Kuantum Uygulaması

Yalan, bireyleri manipüle etmek, çıkar sağlamak veya kendini zor durumlardan kurtarmak amacıyla olayların bilerek çarpıtılması olarak tanımlanabilir. İnsanlar, kişisel ilişkilerde, tıbbi ve psikolojik değerlendirmeler esnasında, işe alım süreçlerinde, adalet ve güvenliği etkileyen durumlarda ve finansal dolandırıcılık ile yasadışı mali kayıplara yol açabilecek durumlarda sıklıkla yalan söylemektedir. Etik açıdan olumsuz bir durum olmasının yanı sıra, yalan toplumsal düzenin bozulmasına ve güvenin zedelenmesine sebebiyet verir. Bu sebeple, yalanın doğası ve tespiti üzerine yapılan çalışmalar giderek daha popüler hale gelmiştir.

1920’li yılların başında Larson tarafından modern yalan makinesi icat edilmiştir [202]. Yalan makinesinin ortaya çıkışının ardından özellikle adli vakalar üzerinde incelemeler yapılmıştır. Bu yöntem ile suçlulardan kalp atış hızı, solunum ve cilt iletkenliği verileri fizyolojik bir kayıt cihazı kullanılarak elde edilmiştir. Yalan tespit cihazı kullanılan araştırmalarda aynı zamanda sorgulama teknikleri ve yalan testlerinden de faydalanılmıştır [203]. 1930’larda fizyolojik yalan tespiti ile

başlayan süreç 1950’li yıllarda sözsüz yalan tespiti ile devam etmiştir. 1970’lerde yalan ile belirli kelimeler arasındaki ilişkinin incelenmesiyle yapılan çalışmalar ile sözlü yalan tespiti araştırmaları başlamıştır. 1980’lerin sonlarına doğru “kriter tabanlı içerik analizi” yöntemi oluşturulmuştur [204]. Bu yöntem yazılı metinlerin doğruluğunun değerlendirilmesini sağlayan bir araçtır. Dünyanın birçok bölgesinde ceza mahkemelerinde kullanılmıştır. Yalan söylemenin, doğruyu söylemekten daha zor olduğu ve yalan söyleyenlerin, başkaları üzerinde bıraktıkları intibayı daha fazla umursadıkları varsayımı üzerine bu görüş geliştirilmiştir [205]. Bu yöntemi “gerçeklik izleme kriterleri” ve “ifade analizi” takip etmiştir. Gerçeklik izleme, algıyla oluşturulan gerçek anılar ile hayal gücü tarafından üretilen anılar arasındaki ayrımı yapma sürecini ifade eden bir terim olarak kullanılmaktadır [206]. Psikolojik rahatsızlığı olan kişilerde ve ilerleyen yaşlarda gerçeklik algısında bozulmalar meydana gelmektedir. Bu sebeple genelde klinik psikoloji alanında ve adli araştırmalarda sıklıkla kullanılarak gerçekliğin test edilmesi sağlanmaktadır [207]. İfade analizi ise kelimelerin anlamına ve dil bilgisi kurallarına odaklanmaktadır. Ancak insanların yaşadıkları çevre ve kültürel etkiler düşünüldüğünde yanlış kararlara sebep olabilmektedir [208]. 1980’lerde yalan tespiti için beyin aktivitesi sonucu elde edilen veriler kullanılmaya başlanmıştır. Yapay zekâ ve makine öğrenme alanında yaşanan gelişmeler ile birlikte bu alanda yapılan analizler bilgisayar ortamında geliştirilmeye başlanmıştır.

Yalan makinesi ile elde edilen verilerin incelenmesi ile başlayan süreç, yerini 2000’li yıllarda doğal dil işleme algoritmalarında yaşanan gelişmeler ve makine öğrenme algoritmalarının yaygın kullanımı sonucunda bilgisayar destekli sistemlere bırakmıştır. Bu sistemlerde kalp atış hızı, solunum gibi verilerin yanı sıra yüz ifadeleri gibi biyometrik veriler, ses düzeyi ve tonlama, dil yapılarının kullanımı ve EEG sinyalleri gibi bilgilerin incelenmesi ile bu çalışmalarda daha başarılı sonuçlar elde edilmiştir.

Bu alanda beyin sinyalleri kullanılarak yapılan ilk çalışmalardan biri Rosenfeld vd. tarafından gerçekleştirilmiştir. Bir deney sistemi kurularak, bireylerin uyarılara karşı olay ilişkili potansiyellerinin kaydedilmesi sağlanmıştır. Bu kayıtlar incelenerek, bireylerin yalan söyleyip söylemediklerini belirlemek amaçlanmıştır [209]. Farwell, EEG sinyalleri ile gizli bilgilerin ortaya çıkarılması ve doğruluğun tespiti üzerine geliştirdiği sisteme ‘beyin parmak izi’ adını vermiştir. Bu sistemle, mevcut bilgiyi tespit ederek istatistiksel olarak doğruluğunu incelemiştir [210]. Makine öğrenme ve derin öğrenme tekniklerinin bu alanda uygulanmasıyla birlikte, yalan tespiti için bilgisayar tabanlı otomatik sistemler geliştirilmiştir.

Karnati vd., yanıltıcı davranışları otomatik olarak tespit etmek amacıyla LieNet adını verdikleri bir sistem geliştirmiştir. Bu sistem, video, ses ve EEG sinyallerinden özellikler çıkarmaya olanak tanımakta ve yeni bir derin evrişimli sinir ağı ortaya koymaktadır. LieNet’in etkinliği, “Bag-of-Lies (BoL)”, “real-life (RL) trail” ve “Miami University Deception Detection (MU3D)” veritabanlarında doğrulanmıştır. Bag-of-Lies veritabanında %95,91 başarı elde edilmiştir [211].

Anwar vd. ise gizli bilgilerin tespiti için yalan makinesine alternatif olarak beyin aktivitesinin kullanılmasını incelemişlerdir. Makine öğrenmesi tabanlı bir sınıflandırma algoritması geliştirmek için giyilebilir bir EEG cihazı kullanmıştır. Çalışmada, verilerin boyutunu azaltmak için 3. seviye ayrık dalgacık dönüşümü ve temel bileşen analizi kullanılmıştır. Sınıflandırma işlemi, SVM kullanılarak gerçekleştirilmiş ve %83'lük bir doğruluk elde edilmiştir [212]. Javaid vd., yalan tespiti için görsel, ses ve EEG bilgilerinin önemini araştırdıkları bir çalışma gerçekleştirmiştir. Çalışmalarında, sistem yüz hareketlerini görsel olarak incelerken evrişimli sinir ağı kullanılmıştır. Ses sinyallerinin frekans dağılımlı spektrogramları çıkarılarak CNN modelinde analiz edilmiştir. EEG sinyallerine ise çift yönlü uzun kısa süreli bellek uygulanarak, geçmiş ve gelecek sinyaller arasındaki ilişkiler incelenmiştir. Deneyler “Bag-Of-Lies” veri setinde gerçekleştirilmiş ve tüm bileşenlerin dâhil edildiği analizde %83.5 doğrulukla yalan tespiti yapılmıştır [213].

Bir başka yalan tespiti çalışmasında, EEG verileri Bag-Of-Lies veri setinden elde edilmiştir. EEG verilerine ayrık dalgacık dönüşümü uygulanmış ve sinyaller alt sinyallere ayrılmıştır. NCP derin öğrenme modeli ve LSTM yönteminin kullanıldığı hibrit bir sistem geliştirilmiş ve yalan tespiti deneylerinde kullanılmıştır. Bu deneyler sonucunda %97.88'lik bir performans elde edilmiştir [214].

Gao vd., suçlu ve masumlardan oluşan 28 kişilik denek grubunda yalan söylemeyi sınıflandırmak için yeni bir yöntem önermişlerdir. EEG sinyallerinden elde edilen her bir özelliğin ayırt edici etkisini belirlemek için F-skorunu kullanmıştır. “F-skor_ELM” olarak adlandırdıkları bu yöntemde, ortalama test doğruluğunun %98.72 olduğunu belirtmişlerdir [215]. BrainVision kayıt cihazı ve analizörü ile elde edilen EEG sinyallerinin kullanıldığı bir yalan tespit sistemi çalışmasında, bant geçiren filtre kullanılmıştır. Dalgacık Paket Dönüşümü uygulanan sinyaller, 10 gizli katmanlı ve iki otomatik kodlayıcıya sahip bir Derin Sinir Ağına girdi olarak verilmiştir. Yapılan deneyler sonucunda %95 doğruluk elde edilmiştir [216]. Gao vd., yalan tespiti sırasında doğruluğu artırabilmek için gürültüden arındırılmış P3 bileşeni ve makine öğrenimine dayalı yeni bir gizli bilgi testi yöntemi önermişlerdir. Çalışmada, suçlu ve masum katılımcılar olarak 30 kişi seçilmiş ve üç farklı uyaran paradigması uygulanmıştır. Bağımsız bileşen analizi ile artefaktları ayırmak için kullanılmıştır. Oluşturulan yeni dalga formlarından zaman, frekans ve dalgacıklara dayalı 3 grup özellik çıkarılmıştır. Bu özellikler, iki sınıf örneği kullanılarak SVM sınıflandırıcısında değerlendirilmiş ve %84.29'luk bir başarımla elde edilmiştir [217]. Farahani ve Morani, gizli bilgilerin çoklu duyuşal tespitini sağlamak amacıyla bir çalışma gerçekleştirmişlerdir. Sınıflandırıcı olarak Genetik Destek Vektör Makinesi kullandıkları bu çalışmada, otonom özellikler ve bunların kombinasyonları kullanıldığında %95.45'lik bir doğruluk oranına ulaşıldığını belirtmişlerdir [218]. Alarfaj ve Mahmoud, HD-72 Cognionics kulaklık kullanarak elde ettikleri EEG sinyallerinde Fourier serisi dönüşümünü uygulamıştır. EEG sinyallerini hem zamansal hem de mekânsal boyutlarda analiz etmiştir. Veri setini %80 eğitim ve %20 test olarak ayırdıkları çalışmada, model

performansını doğrulamak için çapraz doğrulama yöntemini kullanmıştır. V-TAM dikkat modeline dayalı bir analiz platformunu yalan tespiti için önermişlerdir ve önerilen yöntemin %98.5 hassasiyetle yalan tespiti analizi gerçekleştirdiğini belirtmiştir [219].

Bu çalışmada ise kuantum makine öğrenimi teknikleri kullanılarak yalan tespiti üzerine bir araştırma gerçekleştirilmiştir. Araştırmada halka açık erişime sahip olan *LieWaves* veri seti kullanılmıştır. Veri setinde yer alan sinyaller, çeşitli ön işlemlerden geçirilmiş ve analizlerin gerçekleştirilebilmesi için hazırlanmıştır. QSVM ve VQC algoritmaları kullanılarak, yalan tespit sistemlerinde kuantum algoritmalarının başarımı incelenmiştir.

5.3.1. *LieWaves* Veri Seti

LieWaves veri setinde, AF3, T7, Pz, T8 ve AF4 kanallarını içeren 5 kanallı Emotiv Insight cihazı kullanılarak, hiçbir sağlık sorunu olmayan 27 denekten toplanan veriler yer almaktadır [220]. Deneklerin yaş ortalaması 23,1'dir. Her denek, biri doğruyu söylemeyi, diğeri yalan söylemeyi içeren iki deneye katılmıştır. Bu deneyler sırasında deneklere farklı tesbihler görsel uyaran olarak sunulmuştur. Kullanılan 10 adet tespihten 5 tanesi birinci deneyde, diğeri 5 tanesi ise ikinci deneyde kullanılmıştır. Uyaranlar, video klipler halinde katılımcılara sunulmuştur. Deneyler, gürültüden ve sinyal dalgalarını etkileyebilecek parazitlerden uzak, sessiz bir odada gerçekleştirilmiştir. Uyaranlar, projeksiyon cihazı kullanılarak duvara yansıtılmış ve katılımcılar, 2-3 metre uzaklıkta oturarak uyaranları net bir şekilde görebilmiştir. Elektrotların yerleşiminde 10-20 sistemi kullanılmıştır. Tablo 5.10'da veri seti ile ilgili genel bilgilere yer verilmiştir.

Tablo 5.10. *LieWaves* veri seti hakkında genel bilgiler

Sinyal Tipi	EEG sinyalleri (Zaman Serisi)
Kullanım Amacı	Yalan Tespiti
Kullanılan Cihaz	Emotiv Insight
Kanal Sayısı	5
Katılımcı Sayısı	27
Deney Sayısı	2
Örnek Sayısı	9600
Uyaran Türü	Resim


EEG kayıtları alınırken, çalışmada kullanılan tüm tesbihlerin 2'ser saniye boyunca gösterildiği, 25 kareden oluşan bir video kaydı kullanılmıştır. Her bir sunumda, 1 saniyelik siyah ekranın ardından 2 saniyelik görüntüler yer almış ve toplamda 75 saniyelik EEG verileri elde edilmiştir. Bu işlem 5 defa tekrarlanmıştır.

Her katılımcıdan, bir kutuda yer alan tesbihlerden ikisini seçmeleri istenmiştir. Ardından, hangi deneyde doğruyu, hangi deneyde yalan söylemek istediklerine karar vermeleri gerektiği

belirtilmiştir. Her bir katılımcıya konsantre olmaları için 20 saniye süre verilmiştir. Eğer katılımcı ilk deneyde yalancı rolünü oynamaya karar verdiyse, seçtiği tespih resmini gördüğünde “HAYIR” yazan sol tuşa basmıştır. Doğruyu söylemeye karar verdiyse “EVET” yazan sağ tuşa basmıştır. Bu süreç boyunca EEG sinyalleri kaydedilerek veri seti elde edilmiştir [221].


5.3.2. Deneysel Çalışma

Bu çalışmada, kuantum tabanlı SVM algoritmasının yalan tespitindeki performansını değerlendirmek için P300 verilerinin yer aldığı *LieWaves* veri seti kullanılmıştır. Örüntü tanıma süreci; ön işleme adımları, özellik çıkarma, otomatik özellik haritası seçimi ve sınıflandırma olmak üzere beş aşamada gerçekleştirilmiştir. İlk aşamada verilerin elde edilmesi için ayırık dalgacık dönüşümü ve istatistiksel metotlar kullanılmıştır. Daha sonra, PCA yöntemi kullanılarak veriler farklı boyutlara indirgenmiş ve analizler için hazır hale getirilmiştir. Boyutu azaltılan verilerin Hilbert uzayında tanımlanabilmesi için özellik haritaları kullanılmıştır. Farklı özellik haritaları kullanılarak oluşturulan kuantum tabanlı modellerin performansları, doğruluk ve zaman açısından analiz edilerek veri setine uygunluğu incelenmiştir. Şekil 5.14’te EEG sinyallerinde VQC algoritması ile gerçekleştirilen deneysel çalışmanın şematik görünümüne yer verilmiştir.




Şekil 5.14. VQC modelinin şematik görünümü

EEG sinyallerini içeren LieWaves veri setinde, sağ frontal kutup bölgesinden AF4, sol frontal kutup bölgesinden AF3, sağ temporal bölgeden T8, sol temporal bölgeden T7 ve parietal bölgeden Pz olmak üzere 5 kanaldan elde edilen veriler bulunmaktadır. Seçilen bu kanallara ayırık dalgacık dönüşümü uygulanmıştır. Şekil 5.15’te veri setinin hazırlanma sürecinde yapılan işlemler gösterilmiştir.



Şekil 5.15. Veri setinin hazırlanma süreci


Ayrık dalgacık dönüşümü işlemiyle elde edilen alfa, beta, teta, delta ve gama dalgalarının her birine istatistiksel yöntemler uygulanmıştır. Bu istatistiksel yöntemler; ortalama, varyans, standart sapma, Hjort parametreleri, logaritmik entropi ve Shannon entropisidir. Böylece, biri çıkış değeri olmak üzere toplamda 36 özneliğe sahip yeni bir veri seti elde edilmiştir. Elde edilen bu özellik vektöründe analizlerin gerçekleştirilmesi için boyut indirgeme yöntemlerinden PCA kullanılmıştır. PCA yöntemi ile veri setinin öznelilik sayısı 3 ile 6 arasında olacak şekilde 4 farklı boyuta indirgenmiştir. Şekil 5.16'da temel bileşen analizi aşamasının şematik görünümüne yer verilmiştir.



Şekil 5.16. Temel bileşen analizi uygulaması


Analizlerde kullanmak amacıyla, veri seti %70'i eğitim verisi, %30'u test verisi olacak şekilde rastgele *bölümleme* yöntemi kullanılarak ayrılmıştır. Analizler, Jupyter ortamında Qiskit kütüphaneleri ve Statevector simülatörü kullanılarak gerçekleştirilmiştir. Çalışma iki aşamada yürütülmüştür. İlk olarak, VQC algoritmasının veri setindeki başarımını değerlendirebilmek için

ZZ özellik haritası, tek tekrar için kullanılarak veriler kübit formuna dönüştürülmüştür. Kullanılan özellik haritasının 3 kübit için oluşturulmuş devre yapısı Şekil 5.17’de gösterilmiştir.




Şekil 5.17. ZZFeaturemap (1 tekrar)

VQC algoritmasının bir diğer parametresi parametrik kuantum devreleridir. Bu çalışmada, kuantum hesaplamada sıklıkla tercih edilen RealAmplitude ve EfficientSU2 devreleri, 2 tekrar olacak şekilde kullanılmıştır. Kullanılan devrelerin şemalarına Şekil 5.18’de yer verilmiştir.



EfficientSU2



RealAmplitudes

Şekil 5.18. VQC algoritmasında kullanılan parametrik kuantum devreleri

VQC algoritmasının eğitim sürecinde, RealAmplitude ve EfficientSU2 devreleri ile elde edilen kapı açılarını belirlemek için COBYLA optimizasyon algoritması kullanılmıştır. Bu süreç, 100 iterasyon boyunca gerçekleştirilmiştir. Farklı kanallar ve farklı kübit sayıları için iki farklı devre yapısı kullanılarak elde edilen doğruluk oranlarını gösteren verilere Tablo 5.11’de yer verilmiştir.

Tablo 5.11. RealAmplitude ve EfficientSU2 kuantum devre yapılarının sınıflandırma performansı

Kanal	Kübit Sayısı	RealAmplitude		EfficientSU2	
		Doğruluk Oranları (%)		Doğruluk Oranları (%)	
		Ortalama	Maksimum	Ortalama	Maksimum
AF3	3	68.65	88.24	75.29	94.12
AF3	4	63.35	76.47	66.88	82.35
AF3	5	59.06	76.47	69.29	88.24
AF3	6	58.71	82.35	68.18	88.24
AF4	3	78.24	82.35	74.65	94.12
AF4	4	61.24	82.35	73.24	88.24
AF4	5	73.59	94.12	66.82	88.24
AF4	6	58.24	82.35	53.71	76.47
Pz	3	43.18	58.82	40.65	70.59
Pz	4	74.65	82.35	75.12	88.24
Pz	5	71.24	94.12	71.29	88.24
Pz	6	57.18	76.47	62.24	88.24
T7	3	73.53	76.47	70.65	70.65
T7	4	71.65	71.65	73.18	73.18
T7	5	67.94	67.94	67.59	67.59
T7	6	61.82	61.82	67.94	67.94
T8	3	70.18	76.47	56.94	70.59
T8	4	71.00	88.24	72.47	82.35
T8	5	57.71	94.12	69.47	69.47
T8	6	60.53	60.53	60.71	60.71

VQC algoritmasından elde edilen sonuçlar incelendiğinde, bu veri seti için en yüksek performansın AF3 ve AF4 kanallarından 3 kübit ile %94.12 olarak ölçüldüğü görülmüştür. T7 ve T8 kanallarının performansının ise diğer kanallara göre daha düşük olduğu dikkat çekmektedir. Parametrik kuantum devrelerinin her ikisi için de en iyi performans, farklı kübit sayılarında AF3 kanalından elde edilmiştir. Çalışmanın diğer bir aşamasında, QSVM algoritmasının bu veri seti üzerindeki performansı değerlendirilmiştir. QSVM algoritmasından elde edilen sonuçların VQC algoritmasının sonuçları ile karşılaştırılabilmesi amacıyla veri seti %70 eğitim, %30 test verisi olacak şekilde *rastgele bölümler* yöntemi kullanılarak ayrılmıştır. QSVM algoritmasının performansının iyileştirilebilmesi amacıyla PSO kullanılarak özellik haritası seçimi gerçekleştirilmiştir. Bu aşamada gerçekleştirilen işlemler aşağıda sıralanmıştır.

- *Parametrelerin Tanımlanması:* Rastgele sayı üretici için bir tohum değeri belirlenmiştir.
- *PSO Sınıfının Tanımlanması:* PSO algoritmasını uygulamak için PSO algoritmasının tüm bileşenlerini içeren bir sınıf oluşturulmuştur.
- *Parçacıkların Başlatılması:* Parçacıkların başlangıç konumları ve hızları rastgele olacak şekilde belirlenmiştir.

- *Kuantum Operatör Listesinin Oluşturulması:* Kuantum hesaplamada özellik haritaları için kullanılacak operatörlerin bir listesi oluşturulmuştur. Bu listede X, Y, Z, I ve bunların 2'li (XX, XY vb.), 3'lü (XXX, XYZ vb.) 45 adet durumu yer almaktadır. Oluşturulan bu durumlar pauli özellik haritası için 1'li, 2'li ve 3'lü kombinasyonlar olacak şekilde parametre olarak verilmiştir. Özellik haritalarında kullanılan devre tekrar sayısı ise 1 ile 5 aralığında rastgele değerlerden seçilmektedir.

PSO İterasyon Döngüsü:

- *Uygunluk Fonksiyonunun Tanımlanması:* Her parçacık için uygunluk değeri, Quantum SVM kullanılarak hesaplanmıştır.
- *Parçacık Hızının ve Konumunun Güncellenmesi:* Her parçacığın hızı atalet, bilişsel ve sosyal bileşenler kullanılarak, hesaplanarak güncellenmiştir. Her parçacığın yeni konumu hızlarına göre güncellenmiştir. Yeni konumlar belirli sınırlar içinde tutulmuştur.
- *PSO Algoritmasının Çalıştırılması:* Belirli bir iterasyon sayısı için PSO algoritması çalıştırılmıştır. Parçacıkların uygunluk değerleri her iterasyonda güncellenmiştir.
- *Ana Fonksiyon:* Veri kümesi yüklenerek, veri işlenmiş ve PSO algoritması çalıştırılmıştır. Veri işleme adımları arasında verilerin ölçeklenmesi, PCA uygulanması ve verilerin kuantum sınıflandırıcıları için hazırlanması yer almaktadır.


Tablo 5.12'de PSO algoritmasının temel parametrelerine yer verilmiştir.

Tablo 5.12. PSO algoritması için kullanılan temel parametreler

PSO Temel Parametreler	PSO Parametrelerinin Spesifik Değerleri
Ajan	5
Parçacık Boyutu	5
Atalet Ağırlığı	0.75
Bilişsel ve Sosyal Ağırlık	1.00
İterasyon Sayısı	100

Bu süreç, parçacıkların hem bireysel hem de kolektif bilgilerini kullanarak optimal çözüme ulaşmalarını sağlamaktadır. Yapılan deneysel çalışmada, QSVM algoritmasının en yüksek doğruluk oranının elde edilebilmesi için PSO algoritması kullanılarak özellik haritaları seçilmiştir. İlk aşamada, veriler standartlaştırma ve PCA ile ön işlemden geçirilmiştir. PSO algoritmasının başlangıç aşamasında ise parçacıkların pozisyonları ve hızları rastgele belirlenmiştir. Her iterasyonda, QSVM algoritması ile hesaplanan uygunluk değerleri, parçacıkların kişisel ve global en iyi değerleri ile karşılaştırılarak güncellenmiştir. Parçacıkların hızları ve pozisyonları, atalet, bilişsel ve sosyal bileşenler dikkate alınarak yeniden düzenlenmiştir. İterasyonların sonucunda, en

iyi çözüm ve uygunluk değerlerine göre özellik haritaları elde edilmiştir. Şekil 5.19’da yapılan deneysel çalışmanın blok diyagramına yer verilmiştir.



Şekil 5.19. PSO-QSVM ile gerçekleştirilen deneysel modleın şematik gösterimi


Her bir kanal ve kübit sayısı için analizler qasm ve statevector simülâtör ortamlarında gerçekleştirilmiştir. Tablo 5.13’te PSO-QSVM algoritmasının uygulanması sonucu elde edilen doğruluk oranları gösterilmiştir. Tablo’da verilen; QT: Qasm çalışma zamanı, ST:statevektör çalışma zamanı, R: devre tekrar sayısını göstermektedir.

Tablo 5.13. LieWaves veri setine QSVM algoritması uygulanması sonucu elde edilen doğruluk oranları

Kanal	Kübit Sayısı	Özellik Haritası	R	Qasm Simülâtörü		Statevector Simülâtörü	
				Doğruluk (%)	QT (sn)	Doğruluk (%)	ST (sn)
AF3	3	‘YZZ’, ‘XI’	2	94.11	45.09	94.11	3.20
	4	‘YYY’, ‘YX’	1	82.35	67.20	88.23	3.50
	5	‘XZY’, ‘XXX’	2	88.23	92.42	88.23	5.12
	6	‘YY’, ‘IX’	2	88.23	117.30	94.11	6.75
AF4	3	‘YX’	3	94.11	27.00	94.11	2.07
	4	‘Z’, ‘YZ’	1	94.11	53.00	94.11	6.70
	5	‘ZY’, ‘X’, ‘YZ’	2	94.11	174.0	94.11	8.06
	6	‘XI’, ‘ZX’	3	82.35	180.0	94.11	10.80
T7	3	‘XZ’, ‘YYZ’	2	94.11	56.00	94.11	2.96
	4	‘YYY’, ‘X’, ‘XXZ’	3	88.23	148.0	94.11	6.71
	5	‘YY’	2	88.23	94.00	88.23	4.14
	6	‘XYX’, ‘YI’	2	88.23	165.0	88.23	8.70
T8	3	‘XY’, ‘XXY’	2	88.23	54.00	88.23	3.02
	4	‘ZY’, ‘XX’, ‘XXX’	2	94.11	123.0	94.11	5.36
	5	‘ZX’, ‘ZY’	4	88.23	165.0	94.11	8.53
	6	‘Z’, ‘XYY’, ‘ZZ’	4	94.11	241.0	94.11	7.04
Pz	3	‘YY’, ‘XZX’, ‘ZZ’	3	88.23	138.0	88.23	5.71
	4	‘XYZ’, ‘IY’	1	94.11	77.00	94.11	3.72
	5	‘YI’, ‘YYY’	1	94.11	96.00	94.11	4.67
	6	‘Y’, ‘Y’	1	88.23	147.0	94.11	11.7

Elde edilen sonuçlar incelendiğinde, PSO algoritmasının kullanımı sonucunda her bir kanal ve kübit sayısı için en yüksek performansın farklı kuantum özellik haritaları ile elde edildiği görülmektedir. Geniş bir arama uzayında bu doğruluk seviyelerine ulaşmak oldukça zaman alıcı bir işlemdir. PSO ile QSVM algoritmasının en yüksek başarıma ulaşmasını sağlayan özellik haritaları belirlendikten sonra, analizler iki farklı simülasyon ortamında incelenmiştir. Statevector simülasyon ortamında elde edilen doğruluk değerleri, bazı kanallar ve kübit sayılarında QASM simülasyon ortamına göre daha yüksek çıkmıştır. Doğruluk oranlarındaki farklılıkların yanı sıra, en belirgin farkın çalışma sürelerinde olduğu gözlemlenmiştir. Statevector simülasyon ortamı, 6 kübit için çalıştırıldığında yaklaşık 12 saniyede sonuç verirken, QASM simülasyonunda bu süre oldukça fazladır.

LieWaves veri seti kullanılarak gerçekleştirilen bir diğer çalışmada, öncelikle PSO kullanılarak oluşturulan QSVM modelinin performansını daha güvenilir bir şekilde değerlendirmek için k-katlı çapraz doğrulama yöntemi kullanılmıştır. Ayrıca VQC algoritmasında da PSO yöntemi kullanılarak bu algoritmanın özellik haritaları ve kuantum parametrik devreleri belirlenmiştir. Önerilen çalışmanın blok diyagramı Şekil 5.20’de sunulmuştur.



Şekil 5.20. Önerilen modelin blok diyagramı

Çalışmada, öncelikle 5 katlı çapraz doğrulama işlemi uygulanarak klasik SVM algoritması kullanılmıştır. Ardından, PSO-QSVM algoritması ile elde edilen başarımların değerleri, klasik SVM algoritmasının sonuçları ile karşılaştırılmıştır. Bu analizlerin gerçekleştirilmesinde statevector simülasyon ortamı kullanılmıştır. SVM ve PSO-QSVM algoritmalarından 5 katlı çapraz doğrulama sonucu elde edilen ortalama doğruluk oranları Tablo 5.14’te sunulmuştur. Tabloda kullanılan kısaltmalar şunlardır: N, öznitelik sayısını; ORT_ACC, ortalama doğruluk oranını; K, kübit sayısını; R ise devre tekrar sayısını ifade etmektedir.

Tablo 5.14. SVM ve PSO-QSVM algoritmalarının parametreleri ve ortalama doğruluk oranları

Kanal	SVM			PSO-QSVM		
	N	ORT_ACC (%)	K	Özellik Haritası	R	ORT_ACC (%)
AF3	3	80.00	3	'IY','XXX','XXZ'	1	92.72
	4	76.36	4	'XZZ','X'	3	85.45
	5	78.18	5	'IZ','X'	2	83.45
	6	76.36	6	'YZZ','Z','ZZZ'	1	85.45
AF4	3	78.18	3	'YZ','X','IZ'	5	83.45
	4	78.18	4	'IY','XYZ'	3	81.63
	5	76.36	5	'YZ','ZX'	1	81.81
	6	76.36	6	'Z'	1	81.81
T7	3	74.18	3	'ZX','IY'	2	81.63
	4	76.00	4	'XXY','ZZ','YI'	1	85.27
	5	74.18	5	'XY'	2	83.63
	6	72.36	6	'ZZ','XI'	1	89.09
T8	3	48.36	3	'ZYZ','ZZZ','ZZZ'	1	63.09
	4	74.54	4	IY','X'	2	83.63
	5	76.36	5	'Y','XX'	2	81.81
	6	76.36	6	'XI','Y'	2	81.81
Pz	3	50.36	3	'XY','XZX','XI'	2	76.00
	4	76.36	4	'ZI','YZY'	2	81.27
	5	76.36	5	'YZ','X'	1	88.90
	6	80.00	6	'Z'	1	81.81

Yapılan çalışmada, her bir EEG sinyal kanalı ayrı ayrı değerlendirilmiştir. Bu kanalların 3 ile 6 kübit arasında performans değerleri ölçülmüştür. SVM algoritması kullanılarak yapılan analizlerdeki ortalama doğruluk oranı ile karşılaştırıldığında, PSO-QSVM algoritmasının sonuçları çok daha başarılıdır. PSO-QSVM modeli ile elde edilen analiz sonuçlarına göre, AF3 kanalının ortalama doğruluk oranının diğer kanallara kıyasla daha yüksek olduğu gözlemlenmiştir. Gerçekleştirilen tüm bu analizler çerçevesinde, AF3 kanalından 3 kübit en yüksek doğruluk oranı (%92.72) elde edilmiştir. PSO-QSVM algoritmasında oluşturulan tüm özellik haritalarının gösterimine **EK-2'**de yer verilmiştir. Elde edilen bu sonuçlar, PSO algoritmasının kuantum tabanlı SVM modelinde özellik haritalarının belirlenmesindeki başarısını göstermektedir.

PSO algoritmasının bu başarımı göz önüne alınarak, VQC algoritmasının özellik haritası ve kuantum parametrik devre seçiminde de optimizasyon işlemi gerçekleştirilerek yeni bir model oluşturulmuştur. VQC algoritmasında kuantum parametrik devresi olarak RealAmplitude, EfficientSU2 ve TwoLocal kullanılmaktadır. RealAmplitude devresinde yalnızca Ry ve CNOT kapıları kullanılırken, EfficientSU2 devresinde ise Ry, Rz ve CNOT kapıları yer almaktadır. Bu iki parametrik devrede farklı kapılar tanımlanamaz. Farklı kuantum kapıları kullanarak bir devre tasarımı gerçekleştirilmek istendiğinde, TwoLocal devresi içinde kapı tanımlamaları

yapılabilmektedir. TwoLocal devresi, kuantum algoritmalarında kullanılan, parametrik kapılar ile dolanıklık operasyonlarının ardışık olarak uygulanmasıyla oluşturulan bir kuantum devre tasarımıdır [222]. PSO algoritması kullanılarak VQC için oluşturulan modelde, özellik haritası parametrelerinin yanı sıra, TwoLocal parametrik devresinin parametrik kapıları da optimize edilmeye çalışılmıştır. PSO-QSVM de oluşturulan kuantum operatör listesine ek olarak bu algortmada ‘rx, ry, rz’ ve ‘cx, cy, cz’ parametreleriyle de bu parametrik devre modelleri elde edilmeye çalışılmıştır.

Ayrıca VQC algoritmasında doğrusal olmayan kısıtlı optimizasyon problemlerini çözmek için kullanılan COBYLA optimizasyon algoritması, parametrik devrelerin dönüş açılarını belirlemek amacıyla kullanılmıştır. Bu optimizasyon yöntemi, eğitim sürecinde önceden tanımlanmış bir kayıp fonksiyonunu minimize etmek için kullanılır. Ardından, bu şekilde eğitilmiş model, test verilerini sınıflandırmak için uygulanır [223]. Analizler 100 iterasyon boyunca gerçekleştirilmiş ve her iterasyonda, tüm katmanlar değerlendirilerek bu katmanlardan elde edilen ortalama doğruluk değerinin artırılması hedeflenmiştir. Gerçekleştirilen analizler sonucunda, AF3 ve AF4 kanallarından elde edilen doğruluk değerleri Tablo 5.15’te sunulmuştur. Tabloda kullanılan kısaltmalar şunlardır: K, kübit sayısını; ORT_ACC, ortalama doğruluk oranını; R ise devre tekrar sayısını ifade etmektedir.

Tablo 5.15. PSO-VQC algoritmasının parametreleri ve ortalama doğruluk oranları

PSO-VQC algoritması						
Kanal	K	Özellik Haritası	R	Kuantum Parametrik Devresi	R	ORT_ACC (%)
AF3	3	‘X’, ‘XYX’	2	["rx", "ry"], "cx"	2	85.45
	4	‘ZI’	2	["ry"], "cx"	2	80.00
	5	‘ZI’	1	["ry", "rz"], "cz"	2	78.18
	6	‘Y’, ‘YY’, ‘YY’	1	["rx", "rz"], "cy"	1	81.82
AF4	3	‘X’	2	["rz", "ry"], "cy"	2	83.63
	4	‘X’	4	["rx"], "cy"	2	85.45
	5	‘Z’	1	["rx"], "cx"	1	76.00
	6	‘X’, ‘Y’	1	["rx"], "cz"	2	74.54

PSO-VQC algoritması kullanılarak gerçekleştirilen analizler sonucunda, AF3 ve AF4 kanallarındaki ortalama doğruluk oranlarının artan kübit sayısı ile birlikte düştüğü gözlemlenmiştir. SVM algoritmasıyla elde edilen sonuçlarla karşılaştırıldığında, AF4 kanalında 6 kübit için elde edilen sonuçlar haricinde PSO-VQC algoritmasının başarımının daha yüksek olduğu söylenebilir. Ancak, VQC algoritmasında kullanılan karmaşık devre yapıları nedeniyle, bu algoritmanın çalışma süresi QSVM algoritmasına göre daha uzundur ve doğruluk oranlarında QSVM’yi geçememiştir.

PSO-VQC algoritmasından elde edilen en yüksek ortalama doğruluk değerine sahip özellik haritaları **EK-3**'te, kuantum parametrik devrelerin gösterimi ve dönüş açıları ise **EK-4**'te sunulmuştur.

5.3.3. Sonuçlar ve Tartışma

Bu çalışmada, *LieWaves* veri seti kullanılarak üç farklı çalışma gerçekleştirilmiştir. Tüm çalışmalarda veri seti öncelikle DWT işlemine tabi tutulmuş ve sinyallerin alt bantları elde edilmiştir. Bu alt bantlarda, ortalama, varyans, standart sapma, Hjort parametreleri, logaritmik ve Shannon entropisi olmak üzere beş farklı istatistiksel analiz uygulanmış ve her bir kanal için toplamda 36 özneliğe sahip veri seti hazırlanmıştır. Veri setinin analiz sürecinin simülasyon ortamında oldukça uzun sürmesi ve sınırlı kübit sayısının kullanılabilmesi nedeniyle, veri setinin boyutu PCA yöntemi kullanılarak azaltılmıştır.

Yapılan ilk çalışma, VQC algoritmasının 2 tekrarlı Real Amplitude ve EfficientSU2 parametrik devrelerinin kullanılması durumundaki başarımını incelemek amacıyla tasarlanmıştır. Veriler, rastgele bölümlendirme yöntemi ile %70 eğitim ve %30 test verisi olarak ayrılmıştır. Çalışmada, 50 iterasyon gerçekleştirilmiş ve COBYLA optimizasyon algoritması için iterasyon sayısı 100 olarak belirlenmiştir. Analizler sonucunda, her iki parametrik devre için elde edilen doğruluk oranlarının oldukça benzer çıktığı gözlemlenmiştir. İkinci çalışmada, QSVM algoritmasında farklı özellik haritalarının otomatik seçimi için PSO algoritması kullanılmıştır. Bu süreçte, Öklid uzayındaki veriler, Hilbert uzayındaki kuantum durum verilerine Pauli özellik haritaları aracılığıyla eşlenmiştir. Özellik haritalarının en genel hali olan Pauli devresi, Z ve ZZ formlarının olmasının dışında, farklı kapı kombinasyonları kullanılarak verilerin ve problemlerin durumuna göre çeşitli özellik haritalarının oluşturulmasına olanak sağlar. Bu sebeple, PSO algoritması Pauli özellik haritasının parametrelerini belirlemeye yönelik olarak tasarlanmıştır. Her kanal ve kübit sayısı için elde edilen özellik haritaları kullanılarak QSVM algoritması, hem Qasm hem de Statevector simülasyon ortamlarında çalıştırılmıştır. Bu analizler, simülasyon ortamlarının doğruluk ve çalışma süreleri üzerindeki etkilerini incelemeyi amaçlamıştır. Sonuçlar, Statevector simülasyonunun hem doğruluk hem de çalışma süresi açısından Qasm simülasyonuna göre çok daha iyi performans gösterdiğini ortaya koymuştur.

Son olarak, aynı veri seti üzerinde 5 katlı çapraz doğrulama yöntemi uygulanmıştır. İlk olarak, SVM algoritmasının veri seti üzerindeki performansı incelenmiştir. PSO-QSVM ile gerçekleştirilen deneyler sonucunda, bu yöntemin modelin performansı üzerinde SVM algoritmasına göre oldukça belirgin bir etkisi olduğu görülmüştür. PSO-QSVM'nin özellik haritalarını otomatik olarak belirlemesi, SVM'nin sağladığı sonuçlardan daha yüksek doğruluk oranları ve daha iyi performans elde edilmesini sağlamıştır.

PSO yöntemi kullanılarak, farklı veri boyutlarında her bir kanal için hem özellik haritaları hem de kuantum parametrik devreleri belirlenmiş ve VQC algoritmasının başarımının artırılması hedeflenmiştir. VQC algoritmasında kullanılan varyasyonel değerler (dönüş açıları) COBYLA optimizasyon algoritması ile belirlenmiştir. Bu çalışmanın sonucunda, PSO-VQC yönteminin SVM algoritmasına kıyasla daha iyi performans gösterdiği gözlemlenmiştir. Ancak tüm algoritmalar arasında en yüksek doğruluk oranı PSO-QSVM ile elde edilmiştir.



6. SONUÇLAR

EEG sinyalleri, biyomedikal veri analizi alanında yaygın olarak kullanılan ancak genellikle karmaşık ve gürültülü olan veri türlerindendir. Bu nedenle, EEG sinyallerinin sınıflandırılması işlemleri için ayırt ediciliği yüksek sınıflandırıcılar kullanılması gerekmektedir.

Sınıflandırma işlemleri için kullanılan temel adımlar sırasıyla; ön işleme, özellik çıkarımı ve sınıflandırma adımlarıdır. Bu çalışmada öncelikle, EEG verileri üzerinde ön işlem süreçleri uygulanmıştır. Bu süreçler arasında sinyal düzeltme, filtreleme ve zaman serisi analizi gibi teknikler bulunmaktadır. Ön işleme adımlarının amacı, verilerin analiz ve sınıflandırma algoritmaları için uygun hale getirilmesidir. Daha sonra, özellik çıkarımı adımları gerçekleştirilmiş ve elde edilen özellik vektörleri, kuantum tabanlı sınıflandırıcılar olan QSVM ve VQC algoritmaları için giriş olarak kullanılmak üzere hazırlanmıştır.

Kuantum bilgisayarlar ve simülatörler, geleneksel bilgisayarlardan farklı olarak kubitler üzerinde işlem yapmaktadırlar. Verilerin bu ortamlarda kullanılabilmesi için öncelikle kubit formuna dönüştürülmesi gerekmektedir. Özellik haritalarının kullanılması ile gerçekleştirilen bu süreç, verilerin doğru bir şekilde temsil edilmesini ve kuantum sınıflandırıcıların etkin bir şekilde çalışmasını sağlar.

Deneyisel çalışmalarda, hastalık teşhisi ve P300 uygulaması gibi EEG verilerinin farklı alanlardaki kullanımlarına yönelik üç farklı veri seti kullanılmıştır. Deneyler için kullanılan veri setlerine öncelikle 4. seviye ayrık dalgacık dönüşümü uygulanmış ve her bir kanalın beta, alfa, delta, teta ve gama alt bantları elde edilmiştir. Elde edilen her bir alt bantta istatistiksel yöntemler uygulanarak özellik vektörleri oluşturulmuştur.

Kuantum bilgisayarların henüz tam anlamıyla aktif olarak kullanılamaması ve kuantum makine öğrenme çalışmalarının büyük ölçüde bulut ortamlarında gerçekleştirilmesi, bunun yanı sıra kuantum hesaplama sağlayıcılarının sunduğu sınırlı kubit sayısı, büyük veri setleriyle yapılan kuantum makine öğrenme çalışmalarında zorluklar oluşturmaktadır. Bu nedenle, veri setlerinin hem örneklem hem de öznitelik sayısının kuantum analizlerinin gerçekleştirilmesinde önemi oldukça fazladır. Boyutsallık problemlerine çözüm üretmek amacıyla tez kapsamında veri setlerini QML algoritmalarında kullanabilmek amacıyla literatürde yaygın olarak boyut indirgeme tekniklerinden PCA kullanılmıştır.

Ön işlem süreçlerinden geçirilen ve boyut indirgeme yöntemi uygulanan verilerle oluşturulan yeni veri setleri, başlangıçta klasik makine öğrenme algoritmaları olan SVM, KNN, NB, LR, DT ve RF kullanılarak detaylı bir şekilde analiz edilmiştir. Bu algoritmalar, veri setlerinin sınıflandırılması ve performanslarının değerlendirilmesi için kullanılmıştır. Daha sonra, kuantum tabanlı algoritmalar olan QSVM ve VQC algoritmalarıyla gerçekleştirilen analizler yapılmış ve bu algoritmaların performansları klasik makine öğrenme algoritmalarıyla karşılaştırılmıştır. QSVM ve

VQC algoritmalarının, özellikle kullanılan veri setleri üzerinde sağladığı avantajlar ve klasik algoritmalarla karşılaştırıldığında gösterdiği üstünlükler üzerinde durulmuştur. Yapılan bu analizlerde farklı veri boyutları kullanılmış ve her bir öznelik sayısı için ayrı ayrı çalışmalar gerçekleştirilmiştir. Bu analizlerde, farklı veri boyutları üzerinde çalışılarak her bir öznelik sayısının sınıflandırma algoritmaları üzerindeki etkisi değerlendirilmiştir. Klasik makine öğrenme algoritmaları ile QSVM ve VQC gibi kuantum tabanlı algoritmalar arasındaki performans farkları, her bir veri boyutu için ayrı ayrı incelenmiştir.

Yapılan çalışmalarda, kuantum makine öğrenimi algoritmalarının önemli bir aşaması olan özellik haritaları kullanılarak verilerin kübit formuna dönüştürülmesi de araştırılmıştır. Özellik haritaları, verilerin kuantum bilgisayarlar veya simülatörlerinde işlenmesi için kullanılan bir ön işlem adımdır. Bu adım, verilerin doğru bir şekilde temsil edilmesini sağlamak ve kuantum sınıflandırıcıların performansını etkilemektedir. Aynı zamanda algoritmaların veriye nasıl yaklaştığını ve sonuçların ne kadar güvenilir olduğunu anlamak için önemlidir. Bu çalışmada, kullanılan özellik haritalarının özellikle QSVM algoritması üzerindeki etkinliği araştırılmıştır. Yapılan deneyler, özellik haritalarının QSVM algoritmasının sonuçlarında belirgin farklılıklar oluşturduğunu ortaya koymuştur. Bu bulgular doğrultusunda, özellik haritalarının otomatik olarak seçilmesi için meta-sezgisel optimizasyon tekniklerinden biri olan PSO algoritması kullanılarak bir optimizasyon süreci gerçekleştirilmiştir. Bu yaklaşımla, özellik haritalarının seçim sürecinde daha sistemli bir yöntem sunularak, kuantum makine öğrenimi algoritmalarının performansının artırılması hedeflenmiştir. Bu yöntem ile algoritmanın verimliliğinin artırılması, doğru ve güvenilir sonuçların elde edilmesi amaçlanmıştır. SVM ve PSO-QSVM algoritmalarıyla yapılan analizler, özellik haritalarının optimizasyon süreci ile seçilmesinin başarıyı artırdığını göstermektedir. PSO-QSVM algoritması kullanılarak elde edilen sonuçlar ışığında aynı yöntemin VQC algoritmasında da kullanımı incelenmiştir. VQC algoritmasında, özellik haritalarının ve parametrik kuantum devrelerinin seçimi aşamasında PSO algoritması uygulanmıştır. VQC algoritması, parametrik kuantum devrelerinin dönüş açılarının belirlenmesini sağlayan farklı bir optimizasyon algoritmasıyla desteklenmektedir. Bu yöntemlerin kombinasyonu, klasik yöntemlere göre önemli ölçüde daha iyi sonuçlar vermiştir.

Analizler, IBM kuantum laboratuvarı ve Jupyter ortamlarında gerçekleştirilmiştir. Qasm ve Statevector simülatörlerinin algoritmaların performansı üzerindeki etkileri incelendiğinde, algoritmaların çalışma sürelerindeki farklılıklar dikkat çekmiştir. Statevector simülatör ortamında gerçekleştirilen çalışmaların tamamlanma süresi, Qasm simülatör ortamına göre belirgin şekilde daha kısadır.

Gerçekleştirilen deneysel çalışmalar sonucunda, bu tezin literatüre yenilikçi katkıları şu şekilde sıralanabilir:

- Kuantum teknolojisi, hızla gelişen ve çeşitli alanlarda uygulanarak etkileri ve performansı araştırılan bir alandır. Kuantum teknolojinin avantajlarının makine öğrenimi yöntemleriyle birleştirilmesiyle, literatüre yenilikçi bir bakış açısı kazandırılması hedeflenmektedir. Yapılan araştırmalarda, kuantum makine öğrenme algoritmaları ile EEG sinyallerinden şizofreni teşhisi yapılmış bir çalışmaya rastlanılmamıştır. Bu sebeple EEG sinyallerinden hastalık tespiti için 16 kanaldan ve 84 bireyden elde edilen şizofreni veri seti kullanılmıştır. Yapılan deneysel çalışmada, şizofreni tespitinde QSVM algoritmasının klasik makine öğrenme yöntemlerinden daha yüksek performans elde edilmiştir.
- Kuantum makine öğrenmesi algoritmalarının önemli parametrelerinden biri olan özellik haritaları tez kapsamında detaylı bir şekilde incelenmiştir. Özellik haritalarının QSVM algoritmasının performansı üzerindeki etkisi hem *şizofreni* hem de *yalan tespit* veri seti üzerinde değerlendirilmiştir. Bu algoritmalarından yüksek performans elde edebilmek için uygulanan optimizasyon süreciyle QSVM ve VQC algoritmasında, klasik makine öğrenme algoritmalarına göre çok daha yüksek doğruluk oranları elde edilmiştir.
- Kuantum teknolojinin sınırlı kaldığı noktalardan biri, kuantum bilgisayarlara erişim süreçlerinde yaşanan bekleme süreleri ve herkese açık olarak kullanıma sunulan bilgisayarların kübit sayısının en fazla 7 kübit ile sınırlandırılmış olmasıdır. Çalışmalarda bu sebep ile simülasyon ortamları kullanılmıştır. Kullanılan simülatörlerin yapısal farklılıkları nedeniyle gerçekleştirilen analizlerde kullanılan kuantum algoritmalarının performanslarında değişiklikler gözlemlenmiştir.

Elde edilen tüm bulgular, gelecekteki araştırmalarda kuantum makine öğrenme algoritmalarının biyomedikal veri analizinde daha geniş bir şekilde kullanılmasını teşvik etmektedir. Yeni bir teknoloji olan QML algoritmaları ile yapılan çalışmalar, gerçek kuantum bilgisayarların kullanımıyla klasik algoritmaları geride bırakma potansiyeline sahip olduğunu net bir şekilde ortaya koymaktadır. Gelecek çalışmalarda gerçek IBM kuantum bilgisayarlarının daha aktif bir şekilde kullanılması ile analiz performanslarının artırılması hedeflenmektedir. Tez kapsamında yapılan çalışmaların kübit boyutu kısıtlılıkları ve simülasyon kullanımına rağmen literatüre katkı sağlayıcı düzeyde olduğu açıktır.

ÖNERİLER

Çeşitli EEG veri setlerine uygulanan klasik ve QSVM algoritmalarının uygulanması ile bu tez çalışması tamamlanmıştır. Bu çalışmalar yapılırken literatürde var olan birçok araştırma incelenmiştir. Yapılan analizler ve literatür taramaları ile tez kapsamında elde edilen sonuçlara ek olarak aşağıda sıralanan öneriler sunulmuştur.

- Kuantum ve klasik yaklaşımların, veriler arasındaki farklı ilişkilerden yararlanıp yararlanmadığını ve şizofreninin tespiti için hibrit bir yöntemin kullanılmasına ilgi olup olmadığını değerlendirmek için ek çalışmalar gerçekleştirilebilir.
- Nörofeedback uygulamaları gibi BBA uygulamalarında kuantum algoritmalarının kullanımı sağlanabilir.
- Farklı kuantum tabanlı sınıflandırma algoritmalarının EEG sinyallerinin sınıflandırılmasında performansı incelenebilir.
- Çeşitli kuantum tabanlı algoritmaların doğruluğunu ve yürütme sürelerini araştırmak için gerçek kuantum bilgisayarlar ve farklı simülatör ortamları kullanılarak algoritmaların hız ve çalışma zamanı açısından katkısı değerlendirilebilir.
- Kuantum tabanlı optimizasyon algoritmaları kullanılarak QSVM ve VQC algoritmalarının performansları incelenebilir.

KAYNAKLAR

- [1] L. S. Vidyaratne ve K. M. Iftekharuddin, "Real-Time Epileptic Seizure Detection Using EEG", IEEE Transactions on Neural Systems and Rehabilitation Engineering, c. 25, sy 11, ss. 2146-2156, Kas. 2017, doi: 10.1109/TNSRE.2017.2697920.
- [2] X. Shi, T. Wang, L. Wang, H. Liu, ve N. Yan, "Hybrid Convolutional Recurrent Neural Networks Outperform CNN and RNN in Task-state EEG Detection for Parkinson's Disease", Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC), Kas. 2019, ss. 939-944. doi: 10.1109/APSIPAASC47483.2019.9023190.
- [3] R. Sneddon, W. R. Shankle, J. Hara, A. Rodriquez, D. Hoffman, ve U. Saha, "EEG detection of early Alzheimer's disease using psychophysical tasks", Clin EEG Neurosci, c. 36, sy 3, ss. 141-150, Tem. 2005, doi: 10.1177/155005940503600304.
- [4] H. W. Loh, C. P. Ooi, E. Aydemir, T. Tuncer, S. Dogan, ve U. R. Acharya, "Decision support system for major depression detection using spectrogram and convolution neural network with EEG signals", Expert Systems, c. 39, sy 3, s. e12773, 2022, doi: 10.1111/exsy.12773.
- [5] R. Behzad ve A. Behzad, "The Role of EEG in the Diagnosis and Management of Patients with Sleep Disorders", Journal of Behavioral and Brain Science, c. 11, ss. 257-266, Oca. 2021, doi: 10.4236/jbbs.2021.1110021.
- [6] T. Tuncer, S. Dogan, ve A. Subasi, "EEG-based driving fatigue detection using multilevel feature extraction and iterative hybrid feature selection", Biomedical Signal Processing and Control, c. 68, s. 102591, Tem. 2021, doi: 10.1016/j.bspc.2021.102591.
- [7] T. B. Alakus, M. Gonen, ve I. Turkoglu, "Database for an emotion recognition system based on EEG signals and various computer games – GAMEEMO", Biomedical Signal Processing and Control, c. 60, s. 101951, Tem. 2020, doi: 10.1016/j.bspc.2020.101951.
- [8] V. Yargı ve S. Postalcioglu, "EEG İşareti Kullanılarak Bağımlılığa Yatkınlığın Makine Öğrenmesi Teknikleri ile Analizi", El-Cezeri Journal of Science and Engineering, c. 8, sy 1, Art. sy 1, Oca. 2021, doi: 10.31202/ecjse.787726.
- [9] V. Abootalebi, M. H. Moradi, ve M. A. Khalilzadeh, "A new approach for EEG feature extraction in P300-based lie detection", Computer Methods and Programs in Biomedicine, c. 94, sy 1, ss. 48-57, Nis. 2009, doi: 10.1016/j.cmpb.2008.10.001.
- [10] K. Cook, "A historical and practical survey of quantum computing using QISKIT", Senior Honors Theses and Projects, Oca. 2022, [Çevrimiçi]. Erişim adresi: <https://commons.emich.edu/honors/752>
- [11] S. Sharma, "QEML (Quantum Enhanced Machine Learning): Using Quantum Computing to Enhance ML Classifiers and Feature Spaces", 27 Nisan 2020, arXiv: arXiv:2002.10453. doi: 10.48550/arXiv.2002.10453.
- [12] A. Chalumuri, R. Kune, ve B. S. Manoj, "Training an Artificial Neural Network Using Qubits as Artificial Neurons: A Quantum Computing Approach", Procedia Computer Science, c. 171, ss. 568-575, Oca. 2020, doi: 10.1016/j.procs.2020.04.061.
- [13] "Supervised learning with quantum-enhanced feature spaces | Nature". Erişim: 15 Temmuz 2024. [Çevrimiçi]. Erişim adresi: <https://www.nature.com/articles/s41586-019-0980-2>
- [14] S. Lloyd, M. Mohseni, ve P. Rebentrost, "Quantum algorithms for supervised and unsupervised machine learning", 04 Kasım 2013, arXiv: arXiv:1307.0411. doi: 10.48550/arXiv.1307.0411.
- [15] I. Kerenidis, J. Landman, A. Luongo, ve A. Prakash, "q-means: A quantum algorithm for unsupervised machine learning", 11 Aralık 2018, arXiv: arXiv:1812.03584. doi: 10.48550/arXiv.1812.03584.
- [16] Y. Li, R.-G. Zhou, R. Xu, J. Luo, ve S.-X. Jiang, "A Quantum Mechanics-Based Framework for EEG Signal Feature Extraction and Classification", IEEE Transactions on Emerging Topics in Computing, c. 10, sy 1, ss. 211-222, Oca. 2022, doi: 10.1109/TETC.2020.3000734.

- [17] A. Blance ve M. Spannowsky, “Quantum machine learning for particle physics using a variational quantum classifier”, J. High Energ. Phys., c. 2021, sy 2, s. 212, Şub. 2021, doi: 10.1007/JHEP02(2021)212.
- [18] Z. Yu, “Analyzing SARS CoV-2 Patient Data Using Quantum Supervised Machine Learning”, 29 Ekim 2021, bioRxiv. doi: 10.1101/2021.10.26.466019.
- [19] S. Moradi, C. Brandner, C. Spielvogel, D. Krajnc, S. Hillmich, R. Wille, W. Drexler ve L. Papp, “Clinical data classification with noisy intermediate scale quantum computers”, Scientific Reports, c. 12, sy 1, Art. sy 1, Şub. 2022, doi: 10.1038/s41598-022-05971-9.
- [20] Y. Kumar, A. Koul, P. S. Sisodia, J. Shafi, K. Verma, M. Gheisari, M. B. Davoodi, “Heart Failure Detection Using Quantum-Enhanced Machine Learning and Traditional Machine Learning Techniques for Internet of Artificially Intelligent Medical Things”, Wireless Communications and Mobile Computing, c. 2021, s. e1616725, Ara. 2021, doi: 10.1155/2021/1616725.
- [21] H. Gupta, H. Varshney, T. K. Sharma, N. Pachauri, ve O. P. Verma, “Comparative performance analysis of quantum machine learning with deep learning for diabetes prediction”, Complex & Intelligent Systems, c. 8, sy 4, ss. 3073-3087, Ağu. 2022, doi: 10.1007/s40747-021-00398-7.
- [22] T. Shahwar, J. Zafar, A. Almogren, H. Zafar, A. Rehman, ve H. Hamam, “Automated Detection of Alzheimer’s via Hybrid Classical Quantum Neural Networks”, Electronics, c. 11, s. 721, Şub. 2022, doi: 10.3390/electronics11050721.
- [23] G. Cattani, A. Quemy, ve A. Andreev, “First steps towards quantum machine learning applied to the classification of event-related potentials”, 06 Şubat 2023, arXiv: arXiv:2302.02648. doi: 10.48550/arXiv.2302.02648.
- [24] Z. Ozpolat ve M. Karabatak, “Performance Evaluation of Quantum-Based Machine Learning Algorithms for Cardiac Arrhythmia Classification”, Diagnostics, c. 13, sy 6, Art. sy 6, Oca. 2023, doi: 10.3390/diagnostics13061099.
- [25] S. Kafian, M. Yaghoobi, ve I. Attari, “P65: Speech Recognition Based on Bbrain Signals by the Quantum Support Vector Machine for Inflammatory Patient ALS”, The Neuroscience Journal of Shefaye Khatam, c. 6, sy 2, ss. 96-96, Nis. 2018.
- [26] A. Andreev ve G. Cattani, “Quantum Support Vector Machine Applied to the Classification of EEG Signals with Riemannian Geometry”, GIPSA-lab ; IBM, 1, Oca. 2023. Erişim: 20 Eylül 2023. [Çevrimiçi]. Erişim adresi: <https://hal.science/hal-03939121>
- [27] A. Padha ve A. Sahoo, “Quantum Enhanced Machine Learning for Unobtrusive Stress Monitoring”, Proceedings of the 2022 Fourteenth International Conference on Contemporary Computing, Association for Computing Machinery, Eki. 2022, ss. 476-483. doi: 10.1145/3549206.3549288.
- [28] A. Valavanidis, “Quantum Computing. A revolutionary computing capability to sift through huge numbers of possibilities and extract potential solutions to complex problems”, c. 1, ss. 1-25, Oca. 2024.
- [29] G. L. Holmes ve R. Khazipov, “Basic Neurophysiology and the Cortical Basis of EEG”, The Clinical Neurophysiology Primer, Humana Press, 2007, ss. 19-33. doi: 10.1007/978-1-59745-271-7_2.
- [30] “Luigi Galvani | Italian Physicist & Discoverer of Animal Electricity | Britannica”. Erişim: 22 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://www.britannica.com/biography/Luigi-Galvani>
- [31] W. Ormerod, “Richard Caton (1842-1926): pioneer electrophysiologist and cardiologist”, J Med Biogr, c. 14, sy 1, ss. 30-35, Şub. 2006, doi: 10.1258/j.jmb.2006.04-22.
- [32] A. Coenen, E. Fine, ve O. Zayachkivska, “Adolf Beck: a forgotten pioneer in electroencephalography”, J Hist Neurosci, c. 23, sy 3, ss. 276-286, 2014, doi: 10.1080/0964704X.2013.867600.

- [33] J. L. Stone ve J. R. Hughes, "Early History of Electroencephalography and Establishment of the American Clinical Neurophysiology Society", *Journal of Clinical Neurophysiology*, c. 30, sy 1, ss. 28-44, Şub. 2013, doi: 10.1097/WNP.0b013e31827edb2d.
- [34] L. F. Haas, "Hans Berger (1873-1941), Richard Caton (1842-1926), and electroencephalography", *J Neurol Neurosurg Psychiatry*, c. 74, sy 1, s. 9, Oca. 2003, doi: 10.1136/jnnp.74.1.9.
- [35] A. M. Grass, "The electroencephalographic heritage until 1960", *Am J EEG Technol*, c. 24, sy 3, ss. 133-173, Eyl. 1984.
- [36] E. D. Adrian ve B. H. C. Matthews, "The interpretation of potential waves in the cortex", *J Physiol*, c. 81, sy 4, ss. 440-471, Tem. 1934.
- [37] P. F. Bladin, "W. Grey Walter, pioneer in the electroencephalogram, robotics, cybernetics, artificial intelligence", *Journal of Clinical Neuroscience*, c. 13, sy 2, ss. 170-177, Şub. 2006, doi: 10.1016/j.jocn.2005.04.010.
- [38] M. Avoli, "Herbert H. Jasper and the Basic Mechanisms of the Epilepsies", *Jasper's Basic Mechanisms of the Epilepsies*, National Center for Biotechnology Information (US), 2012. Erişim: 22 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <http://www.ncbi.nlm.nih.gov/books/NBK98150/>
- [39] "Report of the committee on methods of clinical examination in electroencephalography: 1957", *Electroencephalography and Clinical Neurophysiology*, c. 10, sy 2, ss. 370-375, May. 1958, doi: 10.1016/0013-4694(58)90053-1.
- [40] J. J. Lynch ve D. A. Paskewitz, "On the mechanisms of the feedback control of human brain wave activity", *Journal of Nervous and Mental Disease*, c. 153, sy 3, ss. 205-217, 1971, doi: 10.1097/00005053-197109000-00005.
- [41] F. Vogel, "The genetic basis of the normal human electroencephalogram (EEG)", *Humangenetik*, c. 10, sy 2, ss. 91-114, Mar. 1970, doi: 10.1007/BF00295509.
- [42] B. Hjorth, "EEG analysis based on time domain properties", *Electroencephalography and Clinical Neurophysiology*, c. 29, sy 3, ss. 306-310, Eyl. 1970, doi: 10.1016/0013-4694(70)90143-4.
- [43] I. Petersén ve O. Eeg-Olofsson, "The Development of the Electroencephalogram in Normal Children from the Age of 1 Through 15 Years – Non-paroxysmal activity", *Neuropädiatrie*, c. 2, sy 3, ss. 247-304, Şub. 1971, doi: 10.1055/s-0028-1091786.
- [44] L. Nirenberg, J. Hanley, ve E. Stear, "A New Approach to Prosthetic Control: EEG Motor Signal Tracking With an Adaptively Designed Phase-Locked Loop", *Biomedical Engineering, IEEE Transactions on*, c. BME-18, ss. 389-398, Ara. 1971, doi: 10.1109/TBME.1971.4502880.
- [45] M. B. Sterman ve L. Friar, "Suppression of seizures in an epileptic following sensorimotor EEG feedback training", *Electroencephalography and Clinical Neurophysiology*, c. 33, sy 1, ss. 89-95, Tem. 1972, doi: 10.1016/0013-4694(72)90028-4.
- [46] J. M. Grossberg, "Brain wave feedback experiments and the concept of mental mechanisms", *Journal of Behavior Therapy and Experimental Psychiatry*, c. 3, sy 4, ss. 245-251, Ara. 1972, doi: 10.1016/0005-7916(72)90043-2.
- [47] A. Isaksson, A. Wennberg, ve L. H. Zetterberg, "Computer analysis of EEG signals with parametric models", *Proceedings of the IEEE*, c. 69, sy 4, ss. 451-461, Nis. 1981, doi: 10.1109/PROC.1981.11988.
- [48] J. Gotman, "Automatic recognition of epileptic seizures in the EEG", *Electroencephalography and Clinical Neurophysiology*, c. 54, sy 5, ss. 530-540, Kas. 1982, doi: 10.1016/0013-4694(82)90038-4.
- [49] L. A. Farwell ve E. Donchin, "Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials", *Electroencephalogr Clin Neurophysiol*, c. 70, sy 6, ss. 510-523, Ara. 1988, doi: 10.1016/0013-4694(88)90149-6.

- [50] M. Seeck, L. Koessler, T. Bast, F. Leijten, C. Michel, C. Baumgartner, B. He, S. Beniczky, "The standardized EEG electrode array of the IFCN", *Clinical Neurophysiology*, c. 128, sy 10, ss. 2070-2077, Eki. 2017, doi: 10.1016/j.clinph.2017.06.254.
- [51] J. S. Kumar ve P. Bhuvaneswari, "Analysis of Electroencephalography (EEG) Signals and Its Categorization—A Study", *Procedia Engineering*, c. 38, ss. 2525-2536, Oca. 2012, doi: 10.1016/j.proeng.2012.06.298.
- [52] D. K. Wong, "Multichannel classification of brain -wave representations of language by perceptron-based models and independent component analysis", Ph.D. Erişim: 25 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://www.proquest.com/docview/305123250/abstract/4AD12C11B5EF4EBDPQ/1>
- [53] R. Abiri, S. Borhani, E. Sellers, Y. Jiang, ve X. Zhao, "A comprehensive review of EEG-based brain-computer interface paradigms", *Journal of Neural Engineering*, c. 16, Kas. 2018, doi: 10.1088/1741-2552/aaf12e.
- [54] R. Bousseta, I. El Ouakouak, M. Gharbi, ve F. Regragui, "EEG Based Brain Computer Interface for Controlling a Robot Arm Movement Through Thought", *IRBM*, c. 39, sy 2, ss. 129-135, Nis. 2018, doi: 10.1016/j.irbm.2018.02.001.
- [55] I. Iturrate, J. Antelis, A. Kübler, ve J. Minguez, "A Noninvasive Brain-Actuated Wheelchair Based on a P300 Neurophysiological Protocol and Automated Navigation", *Robotics, IEEE Transactions on*, c. 25, ss. 614-627, Tem. 2009, doi: 10.1109/TRO.2009.2020347.
- [56] G. E. Fabiani, D. J. McFarland, J. R. Wolpaw, ve G. Pfurtscheller, "Conversion of EEG activity into cursor movement by a brain-computer interface (BCI)", *IEEE Trans. Neural Syst. Rehabil. Eng.*, c. 12, sy 3, ss. 331-338, Eyl. 2004, doi: 10.1109/TNSRE.2004.834627.
- [57] Y. Yu, Y. Liu, E. Yin, J. Jiang, Z. Zhou, ve D. Hu, "An Asynchronous Hybrid Spelling Approach Based on EEG–EOG Signals for Chinese Character Input", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, c. 27, sy 6, ss. 1292-1302, Haz. 2019, doi: 10.1109/TNSRE.2019.2914916.
- [58] M. Poulos, T. Felekis, ve A. Evangelou, "Is it possible to extract a fingerprint for early breast cancer via EEG analysis?", *Medical Hypotheses*, c. 78, sy 6, ss. 711-716, Haz. 2012, doi: 10.1016/j.mehy.2012.02.016.
- [59] S. Little, A. Pogosyan, S. N. BEng (Hons), B Zavala, L. Zrinzo, M. Hariz, T. Foltynie, P. Limousin, K. Ashkan, J. FitzGerald, A. L. Green, T. Z. Aziz, P. Brown, "Adaptive deep brain stimulation in advanced Parkinson disease", *Annals of Neurology*, c. 74, sy 3, ss. 449-457, 2013, doi: 10.1002/ana.23951.
- [60] A. Fernández-Caballero, E. Navarro, P. Fenandez-Sotoz, P. Gonzalez, J.J. Ricarte, J. M. Latorre, R. Rodriguez-Jimenez, "Human-Avatar Symbiosis for the Treatment of Auditory Verbal Hallucinations in Schizophrenia through Virtual/Augmented Reality and Brain-Computer Interfaces", *Front Neuroinform*, c. 11, s. 64, 2017, doi: 10.3389/fninf.2017.00064.
- [61] L. E. H. van Dokkum, T. Ward, ve I. Laffont, "Brain computer interfaces for neurorehabilitation – its current status as a rehabilitation strategy post-stroke", *Annals of Physical and Rehabilitation Medicine*, c. 58, sy 1, ss. 3-8, Şub. 2015, doi: 10.1016/j.rehab.2014.09.016.
- [62] H. Marzbani, H. R. Marateb, ve M. Mansourian, "Neurofeedback: A Comprehensive Review on System Design, Methodology and Clinical Applications", *Basic Clin Neurosci*, c. 7, sy 2, ss. 143-158, Nis. 2016, doi: 10.15412/J.BCN.03070208.
- [63] T. Fuchs, N. Birbaumer, W. Lutzenberger, J. H. Gruzelier, ve J. Kaiser, "Neurofeedback Treatment for Attention-Deficit/Hyperactivity Disorder in Children: A Comparison with Methylphenidate", *Appl Psychophysiol Biofeedback*, c. 28, sy 1, ss. 1-12, Mar. 2003, doi: 10.1023/A:1022353731579.
- [64] C. A. Tozzo, L. F. Elfner, ve J. G. May, "EEG biofeedback and relaxation training in the control of epileptic seizures", *International Journal of Psychophysiology*, c. 6, sy 3, ss. 185-194, Ağu. 1988, doi: 10.1016/0167-8760(88)90004-9.

- [65] T. Horrell vd., "Neurofeedback Effects on Evoked and Induced EEG Gamma Band Reactivity to Drug-related Cues in Cocaine Addiction", *J Neurother*, c. 14, sy 3, ss. 195-216, Tem. 2010, doi: 10.1080/10874208.2010.501498.
- [66] G. Zhao, Y. Ge, B. Shen, X. Wei, ve H. Wang, "Emotion Analysis for Personality Inference from EEG Signals", *IEEE Transactions on Affective Computing*, c. 9, sy 3, ss. 362-371, Tem. 2018, doi: 10.1109/TAFFC.2017.2786207.
- [67] P. Aspinall, P. Mavros, R. Coyne, ve J. Roe, "The urban brain: analysing outdoor physical activity with mobile EEG", *Br J Sports Med*, c. 49, sy 4, ss. 272-276, Şub. 2015, doi: 10.1136/bjsports-2012-091877.
- [68] J.-L. Hsu, Y.-L. Zhen, T.-C. Lin, ve Y.-S. Chiu, "Affective content analysis of music emotion through EEG", *Multimedia Systems*, c. 24, sy 2, ss. 195-210, Mar. 2018, doi: 10.1007/s00530-017-0542-0.
- [69] G. Pfurtscheller vd., "Walking from thought", *Brain Res*, c. 1071, sy 1, ss. 145-152, Şub. 2006, doi: 10.1016/j.brainres.2005.11.083.
- [70] R. Leeb ve G. Pfurtscheller, "Walking through a virtual city by thought", *Conf Proc IEEE Eng Med Biol Soc*, c. 2004, ss. 4503-4506, 2004, doi: 10.1109/IEMBS.2004.1404251.
- [71] R. Ajmeria vd., "A Critical Survey of EEG-Based BCI Systems for Applications in Industrial Internet of Things", *IEEE Communications Surveys & Tutorials*, c. 25, sy 1, ss. 184-212, 2023, doi: 10.1109/COMST.2022.3232576.
- [72] M. F. Mridha, S. C. Das, M. M. Kabir, A. A. Lima, M. R. Islam, ve Y. Watanobe, "Brain-Computer Interface: Advancement and Challenges", *Sensors*, c. 21, sy 17, Art. sy 17, Oca. 2021, doi: 10.3390/s21175746.
- [73] G. Bin, X. Gao, Y. Wang, B. Hong, ve S. Gao, "VEP-based brain-computer interfaces: time, frequency, and code modulations", *IEEE Computational Intelligence Magazine*, c. 4, sy 4, ss. 22-26, Kas. 2009, doi: 10.1109/MCI.2009.934562.
- [74] R. Fazel-Rezai, B. Z. Allison, C. Guger, E. W. Sellers, S. C. Kleih, ve A. Kübler, "P300 brain computer interface: current challenges and emerging trends", *Front. Neuroeng.*, c. 5, Tem. 2012, doi: 10.3389/fneng.2012.00014.
- [75] S. P. Heinrich, "Some thoughts on the interpretation of steady-state evoked potentials", *Doc Ophthalmol*, c. 120, sy 3, ss. 205-214, Haz. 2010, doi: 10.1007/s10633-010-9212-7.
- [76] M. D. Golub, S. M. Chase, A. P. Batista, ve B. M. Yu, "Brain-computer interfaces for dissecting cognitive processes underlying sensorimotor control", *Current Opinion in Neurobiology*, c. 37, ss. 53-58, Nis. 2016, doi: 10.1016/j.conb.2015.12.005.
- [77] H. Gevensleben vd., "Neurofeedback of slow cortical potentials: neural mechanisms and feasibility of a placebo-controlled design in healthy adults", *Front Hum Neurosci*, c. 8, s. 990, Ara. 2014, doi: 10.3389/fnhum.2014.00990.
- [78] L. Albera vd., "ICA-based EEG denoising: a comparative analysis of fifteen methods", *Bulletin of the Polish Academy of Sciences: Technical Sciences*, c. 60, sy 3 Special issue on Data Mining in Bioengineering, ss. 407-418, Eki. 2012, doi: 10.2478/v10175-012-0052-3.
- [79] A. Kawala-Sterniuk vd., "Comparison of Smoothing Filters in Analysis of EEG Data for the Medical Diagnostics Purposes", *Sensors (Basel)*, c. 20, sy 3, s. 807, Şub. 2020, doi: 10.3390/s20030807.
- [80] K. A. Ludwig, R. M. Miriani, N. B. Langhals, M. D. Joseph, D. J. Anderson, ve D. R. Kipke, "Using a Common Average Reference to Improve Cortical Neuron Recordings From Microelectrode Arrays", *J Neurophysiol*, c. 101, sy 3, ss. 1679-1689, Mar. 2009, doi: 10.1152/jn.90989.2008.
- [81] V. H. Nascimento ve M. T. M. Silva, "Chapter 12 - Adaptive Filters", *Academic Press Library in Signal Processing, Volume 1*, vol. 1. , Elsevier, 2014, ss. 619-761. doi: 10.1016/B978-0-12-396502-8.00012-7.

- [82] A.-O. Boudraa, J.-C. Cexus, ve Z. Saidi, “EMD-Based Signal Noise Reduction”, *Signal Processing*, c. 1, Oca. 2005.
- [83] W. Clercq, A. Vergult, B. Vanrumste, W. Paesschen, ve S. Huffel, “Canonical Correlation Analysis Applied to Remove Muscle Artifacts From the Electroencephalogram”, *IEEE transactions on bio-medical engineering*, c. 53, ss. 2583-7, Oca. 2007, doi: 10.1109/TBME.2006.879459.
- [84] N. Elsayed ve M. Bayoumi, “Brain Computer Interface: EEG Signal Preprocessing Issues and Solution”, *International Journal of Computer Applications*, c. 169, Tem. 2017, doi: 10.5120/ijca2017914621.
- [85] E. P. Torres, E. A. Torres, M. Hernández-Álvarez, ve S. G. Yoo, “EEG-Based BCI Emotion Recognition: A Survey”, *Sensors*, c. 20, sy 18, Art. sy 18, Oca. 2020, doi: 10.3390/s20185083.
- [86] S. Gostilovich, A. Kotliar Shapirov, A. Znobishchev, A.-H. Phan, ve A. Cichocki, “Biomarkers of professional cybersportsmen: Event related potentials and cognitive tests study”, *PLoS One*, c. 18, sy 8, s. e0289293, Ağu. 2023, doi: 10.1371/journal.pone.0289293.
- [87] I. T. Jolliffe ve J. Cadima, “Principal component analysis: a review and recent developments”, *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, c. 374, sy 2065, s. 20150202, Nis. 2016, doi: 10.1098/rsta.2015.0202.
- [88] G. T. Reddy vd., “Analysis of Dimensionality Reduction Techniques on Big Data”, *IEEE Access*, c. 8, ss. 54776-54788, 2020, doi: 10.1109/ACCESS.2020.2980942.
- [89] S. Nobukawa, T. Yamanishi, H. Nishimura, Y. Wada, M. Kikuchi, ve T. Takahashi, “Atypical temporal-scale-specific fractal changes in Alzheimer’s disease EEG and their relevance to cognitive decline”, *Cogn Neurodyn*, c. 13, sy 1, ss. 1-11, Şub. 2019, doi: 10.1007/s11571-018-9509-x.
- [90] A. S. Al-Fahoum ve A. A. Al-Fraihat, “Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains”, *ISRN Neurosci*, c. 2014, s. 730218, Şub. 2014, doi: 10.1155/2014/730218.
- [91] N. K. Kit, H. U. Amin, K. H. Ng, J. Price, ve A. R. Subhani, “EEG Feature Extraction based on Fast Fourier Transform and Wavelet Analysis for Classification of Mental Stress Levels using Machine Learning”, *Adv. sci. technol. eng. syst. j.*, c. 8, sy 6, ss. 46-56, Kas. 2023, doi: 10.25046/aj080606.
- [92] N. P. Singh, A. K. Gautam, ve T. Sharan, “13 - An insight into the hardware and software aspects of a BCI system with focus on ultra-low power bulk driven OTA and Gm-C based filter design, and a detailed review of the recent AI/ML techniques”, 2022, ss. 283-315. doi: 10.1016/B978-0-323-91197-9.00015-1.
- [93] S. Afrakhteh ve M. R. Mosavi, “Chapter 2 - Applying an efficient evolutionary algorithm for EEG signal feature selection and classification in decision-based systems”, *Energy Efficiency of Medical Devices and Healthcare Applications*, A. Mohamed, Ed., Academic Press, 2020, ss. 25-52. doi: 10.1016/B978-0-12-819045-6.00002-9.
- [94] V. Lawhern, W. D. Hairston, K. McDowell, M. Westerfield, ve K. Robbins, “Detection and classification of subject-generated artifacts in EEG signals using autoregressive models”, *Journal of Neuroscience Methods*, c. 208, sy 2, ss. 181-189, Tem. 2012, doi: 10.1016/j.jneumeth.2012.05.017.
- [95] O. Salem, A. Naseem, ve A. Mehaoua, “Epileptic seizure detection from EEG signal using Discrete Wavelet Transform and Ant Colony classifier”, *IEEE International Conference on Communications (ICC)*, Sydney, NSW: IEEE, Haz. 2014, ss. 3529-3534. doi: 10.1109/ICC.2014.6883868.
- [96] “Machine Learning - an overview | ScienceDirect Topics”. Erişim: 17 Temmuz 2024. [Çevrimiçi]. Erişim adresi: <https://www.sciencedirect.com/topics/computer-science/machine-learning>

- [97] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions", SN COMPUT. SCI., c. 2, sy 3, s. 160, Mar. 2021, doi: 10.1007/s42979-021-00592-x.
- [98] L. Budach vd., "The Effects of Data Quality on Machine Learning Performance", arXiv.org. Eriřim: 17 Temmuz 2024. [Çevrimiçi]. Eriřim adresi: <https://arxiv.org/abs/2207.14529v4>
- [99] S. Mahato ve S. Paul, "Classification of Depression Patients and Normal Subjects Based on Electroencephalogram (EEG) Signal Using Alpha Power and Theta Asymmetry", Journal of Medical Systems, c. 44, sy 1, s. 28, Ara. 2019, doi: 10.1007/s10916-019-1486-z.
- [100] Y. SONG ve Y. LU, "Decision tree methods: applications for classification and prediction", Shanghai Arch Psychiatry, c. 27, sy 2, ss. 130-135, Nis. 2015, doi: 10.11919/j.issn.1002-0829.215044.
- [101] J. Han, M. Kamber, ve J. Pei, Data Mining: Concepts and Techniques. Elsevier, 2011.
- [102] G. Biau ve E. Scornet, "A random forest guided tour", TEST, c. 25, sy 2, ss. 197-227, Haz. 2016, doi: 10.1007/s11749-016-0481-7.
- [103] G. Aksoy, "Ağırlıklı Bayes sınıflandırıcıda ağırlıkların optimizasyonu / Optimization of the weights of weighted naïve Bayesian classifier", 2018, Eriřim: 05 Haziran 2024. [Çevrimiçi]. Eriřim adresi: <https://openaccess.firat.edu.tr/xmlui/handle/11508/18444>
- [104] V. N. Vapnik, The Nature of Statistical Learning Theory. New York, NY: Springer, 2000. doi: 10.1007/978-1-4757-3264-1.
- [105] K. C. Chua, V. Chandran, U. R. Acharya, ve C. M. Lim, "Application of Higher Order Spectra to Identify Epileptic EEG", Journal of Medical Systems, c. 35, sy 6, ss. 1563-1571, Ara. 2011, doi: 10.1007/s10916-010-9433-z.
- [106] S. Almufti, A. Shaban, R. Ali, ve J. Fuente, "Overview of Metaheuristic Algorithms", Polaris Global Journal of Scholarly Research and Trends, c. 2, ss. 10-32, Nis. 2023, doi: 10.58429/pgjsrt.v2n2a144.
- [107] R. Poli, J. Kennedy, ve T. Blackwell, "Particle swarm optimization", Swarm Intell, c. 1, sy 1, ss. 33-57, Haz. 2007, doi: 10.1007/s11721-007-0002-0.
- [108] J. Kennedy ve R. Eberhart, "Particle swarm optimization", Proceedings of ICNN'95 - International Conference on Neural Networks, Kas. 1995, ss. 1942-1948 c.4. doi: 10.1109/ICNN.1995.488968.
- [109] R. Gupta, G. Singh, ve A. Kaur, "Assessment of performance metrics for fusion network", Kuwait Journal of Science, c. 48, sy 3, Art. sy 3, Haz. 2021, doi: 10.48129/kjs.v48i3.9751.
- [110] M. Y. Özsağlam ve M. Çunkaş, "Optimizasyon problemlerinin çözümü için parçaçık sürü optimizasyonu algoritması", Politeknik Dergisi, c. 11, sy 4, Art. sy 4, 2008.
- [111] D. M. W. Powers, "Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation", 10 Ekim 2020, arXiv: arXiv:2010.16061. doi: 10.48550/arXiv.2010.16061.
- [112] A. Drago, "Einstein's 1905 'Revolutionary' Paper on Quanta as a Manifest and Detailed Example of a 'Principle Theory'", Advances in Historical Studies, c. 3, sy 3, Art. sy 3, Haz. 2014, doi: 10.4236/ahs.2014.33013.
- [113] W. Heisenberg, "Über den anschaulichen Inhalt der quantentheoretischen Kinematik und Mechanik", Z. Physik, c. 43, sy 3, ss. 172-198, Mar. 1927, doi: 10.1007/BF01397280.
- [114] A. Einstein, B. Podolsky, ve N. Rosen, "Can Quantum-Mechanical Description of Physical Reality Be Considered Complete?", Phys. Rev., c. 47, sy 10, ss. 777-780, May. 1935, doi: 10.1103/PhysRev.47.777.
- [115] D. Bohm, "A Suggested Interpretation of the Quantum Theory in Terms of 'Hidden' Variables. I", Phys. Rev., c. 85, sy 2, ss. 166-179, Oca. 1952, doi: 10.1103/PhysRev.85.166.

- [116] J. Singh ve M. Singh, "Evolution in Quantum Computing", içinde 2016 International Conference System Modeling & Advancement in Research Trends (SMART), Kas. 2016, ss. 267-270. doi: 10.1109/SYSMART.2016.7894533.
- [117] P. Yam, "Bringing Schrödinger's Cat to Life", Scientific American, c. 276, sy 6, ss. 124-129, 1997.
- [118] R. Rolleigh, "The Double Slit Experiment and Quantum Mechanics".
- [119] S. Hamil U. Galiev, "Nonlinear Quantum Waves in the Light of Recent Slit Experiments", Evolution of Extreme Waves and Resonances, 1. bs, CRC Press, 2020, ss. 423-463. doi: 10.1201/9781003038504-18.
- [120] "Quantum Superposition - an overview | ScienceDirect Topics". Erişim: 10 Haziran 2024. [Çevrimiçi]. Erişim adresi: <https://www.sciencedirect.com/topics/engineering/quantum-superposition>
- [121] Z.-S. Yuan, X.-H. Bao, C.-Y. Lu, J. Zhang, C.-Z. Peng, ve J.-W. Pan, "Entangled photons and quantum communication", Physics Reports, c. 497, sy 1, ss. 1-40, Ara. 2010, doi: 10.1016/j.physrep.2010.07.004.
- [122] M. Horodecki, P. Horodecki, ve R. Horodecki, "Mixed-State Entanglement and Quantum Communication", Quantum Information: An Introduction to Basic Theoretical Concepts and Experiments, Springer, 2001, ss. 151-195. doi: 10.1007/3-540-44678-8_5.
- [123] R. B. Griffiths, "Hilbert Space Quantum Mechanics".
- [124] M. Loaiza, "A Short Introduction to Hilbert Space Theory", J. Phys.: Conf. Ser., c. 839, s. 012002, May. 2017, doi: 10.1088/1742-6596/839/1/012002.
- [125] H. Yetiş ve M. Karaköse, "Kuantum Uyarlamalı Genetik Algoritmalar için Çözüm Kalitesini Artıracak Yeni Bir Yaklaşım", Fırat Üniversitesi Mühendislik Bilimleri Dergisi, c. 33, sy 1, Art. sy 1, Şub. 2021, doi: 10.35234/fumbd.749192.
- [126] S. Lloyd, , & IVQ Computation, "Quantum information science", Notas de Aula, Curso Quantum-Mechanics, 2009.
- [127] N. S. Yanofsky, "An Introduction to Quantum Computing", 01 Ağustos 2007, arXiv: arXiv:0708.0261. doi: 10.48550/arXiv.0708.0261.
- [128] P. K. Roy, Quantum Logic Gates. 2020.
- [129] M. Schuld, I. Sinayskiy, ve F. Petruccione, "An introduction to quantum machine learning", Contemporary Physics, c. 56, sy 2, ss. 172-185, Nis. 2015, doi: 10.1080/00107514.2014.964942.
- [130] A. Zeguendry, Z. Jarir, ve M. Quafafou, "Quantum Machine Learning: A Review and Case Studies", Entropy, c. 25, sy 2, Art. sy 2, Şub. 2023, doi: 10.3390/e25020287.
- [131] J. Biamonte, P. Wittek, N. Pancotti, P. Rebentrost, N. Wiebe, ve S. Lloyd, "Quantum machine learning", Nature, c. 549, sy 7671, ss. 195-202, Eyl. 2017, doi: 10.1038/nature23474.
- [132] C. Ciliberto vd., "Quantum machine learning: a classical perspective", Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, c. 474, sy 2209, s. 20170551, Oca. 2018, doi: 10.1098/rspa.2017.0551.
- [133] A. Basheer, A. Afham, ve S. K. Goyal, "Quantum \$k\$-nearest neighbors algorithm", 17 Haziran 2021, arXiv: arXiv:2003.09187. Erişim: 15 Temmuz 2024. [Çevrimiçi]. Erişim adresi: <http://arxiv.org/abs/2003.09187>
- [134] A. A. Ezhov ve D. Ventura, "Quantum Neural Networks", içinde Future Directions for Intelligent Systems and Information Sciences, c. 45, N. Kasabov, Ed., içinde Studies in Fuzziness and Soft Computing, vol. 45., Heidelberg: Physica-Verlag HD, 2000, ss. 213-235. doi: 10.1007/978-3-7908-1856-7_11.

- [135] S. Altares-López, A. Ribeiro, ve J. J. García-Ripoll, “Automatic design of quantum feature maps”, *Quantum Sci. Technol.*, c. 6, sy 4, s. 045015, Eki. 2021, doi: 10.1088/2058-9565/ac1ab1.
- [136] S. Agnihotri, “Quantum Machine Learning 102 — QSVM Using Qiskit”, Medium. Erişim: 26 Eylül 2023. [Çevrimiçi]. Erişim adresi: <https://shubham-agnihotri.medium.com/quantum-machine-learning-102-qsvm-using-qiskit-731956231a54>
- [137] H.-J. Kim, G.-J. Song, K.-B. Jang, ve H.-J. Seo, “Cryptanalysis of Caesar using Quantum Support Vector Machine”, *IEEE International Conference on Consumer Electronics-Asia (ICCE-Asia)*, Kas. 2021, ss. 1-5. doi: 10.1109/ICCE-Asia53811.2021.9641932.
- [138] “ZZFeatureMap - Qiskit 0.44.1 documentation”. Erişim: 26 Eylül 2023. [Çevrimiçi]. Erişim adresi: <https://qiskit.org/documentation/stubs/qiskit.circuit.library.ZZFeatureMap.html>
- [139] “ZFeatureMap - Qiskit 0.44.1 documentation”. Erişim: 26 Eylül 2023. [Çevrimiçi]. Erişim adresi: <https://qiskit.org/documentation/stubs/qiskit.circuit.library.ZFeatureMap.html>
- [140] “PauliFeatureMap”, IBM Quantum Documentation. Erişim: 26 Eylül 2023. [Çevrimiçi]. Erişim adresi: <https://docs.quantum-computing.ibm.com/api/qiskit/qiskit.circuit.library.PauliFeatureMap>
- [141] A. Daspal “OptiPauli: An algorithm to find a near-optimal Pauli Feature Map for Quantum Support Vector Classifiers”, *IEEE International Conference on Quantum Computing and Engineering (QCE)* pp. 828-830, Eylül 2022, doi: 10.1109/QCE53715.2022.00133IEEE.
- [142] D. Anguita, S. Ridella, F. Rivieccio, ve R. Zunino, “Quantum optimization for training support vector machines”, *Neural Networks*, c. 16, sy 5, ss. 763-770, Haz. 2003, doi: 10.1016/S0893-6080(03)00087-X.
- [143] D. Maheshwari, D. Sierra-Sosa, ve B. Garcia-Zapirain, “Variational Quantum Classifier for Binary Classification: Real vs Synthetic Dataset”, *IEEE Access*, c. 10, ss. 3705-3715, 2022, doi: 10.1109/ACCESS.2021.3139323.
- [144] M. Schuld, A. Bocharov, K. M. Svore, ve N. Wiebe, “Circuit-centric quantum classifiers”, *Phys. Rev. A*, c. 101, sy 3, s. 032308, Mar. 2020, doi: 10.1103/PhysRevA.101.032308.
- [145] P. A. Estévez vd., “Polysomnographic pattern recognition for automated classification of sleep-waking states in infants”, *Med. Biol. Eng. Comput.*, c. 40, sy 1, ss. 105-113, Oca. 2002, doi: 10.1007/BF02347703.
- [146] M. V. M. Yeo, X. Li, K. Shen, ve E. P. V. Wilder-Smith, “Can SVM be used for automatic EEG detection of drowsiness during car driving?”, *Safety Science*, c. 47, sy 1, ss. 115-124, Oca. 2009, doi: 10.1016/j.ssci.2008.01.007.
- [147] H. Jebelli, S. Hwang, ve S. Lee, “EEG-based workers’ stress recognition at construction sites”, *Automation in Construction*, c. 93, ss. 315-324, Eyl. 2018, doi: 10.1016/j.autcon.2018.05.027.
- [148] A. Huerga, U. Aguilera, A. Almeida, ve A. B. Lago, “A Quantum Computing Approach to Human Behavior Prediction”, *7th International Conference on Smart and Sustainable Technologies (SpliTech)*, Tem. 2022, ss. 1-5. doi: 10.23919/SpliTech55088.2022.9854257.
- [149] O. Roesler, “EEG Eye State”. 2013. doi: 10.24432/C57G7J Erişim Tarihi:11.05.2023.
- [150] O. Rosler ve D. Suendermann, “A First Step towards Eye State Prediction Using EEG” Erişim Tarihi:12.05.2023.
- [151] M. Sahu, N. K. Nagwani, S. Verma, ve S. Shirke, “An Incremental Feature Reordering (IFR) Algorithm to Classify Eye State Identification Using EEG”, *Information Systems Design and Intelligent Applications*, New Delhi: Springer India, 2015, ss. 803-811. doi: 10.1007/978-81-322-2250-7_80.
- [152] T. Wang, S.-U. Guan, K. L. Man, ve T. O. Ting, “EEG Eye State Identification Using Incremental Attribute Learning with Time-Series Classification”, *Mathematical Problems in Engineering*, c. 2014, s. e365101, Nis. 2014, doi: 10.1155/2014/365101.

- [153] A. Al-Taei, "Ensemble Classifier for Eye State Classification using EEG Signals", 25 Eylül 2017, arXiv: arXiv:1709.08590. doi: 10.48550/arXiv.1709.08590.
- [154] M. Koklu ve K. Sabancı, "The Classification of Eye State by Using kNN and MLP Classification Models According to the EEG Signals", *International Journal of Intelligent Systems and Applications in Engineering*, c. 3, sy 4, Art. sy 4, Ara. 2015, doi: 10.18201/ijisae.75836.
- [155] S. Ketu ve P. K. Mishra, "Hybrid classification model for eye state detection using electroencephalogram signals", *Cogn Neurodyn*, c. 16, sy 1, ss. 73-90, Şub. 2022, doi: 10.1007/s11571-021-09678-x.
- [156] J. L. Sobell, M. J. Mikesell, ve C. T. McMurray, "Genetics and etiopathophysiology of schizophrenia", *Mayo Clin Proc*, c. 77, sy 10, ss. 1068-1082, Eki. 2002, doi: 10.4065/77.10.1068.
- [157] J. Vilain vd., "Environmental risk factors for schizophrenia: a review", *Encephale*, c. 39, sy 1, ss. 19-28, Şub. 2013, doi: 10.1016/j.encep.2011.12.007.
- [158] N. C. Andreasen, "Schizophrenia: the fundamental questions", *Brain Research Reviews*, c. 31, sy 2, ss. 106-112, Mar. 2000, doi: 10.1016/S0165-0173(99)00027-2.
- [159] T. M. Laursen, M. Nordentoft, ve P. B. Mortensen, "Excess early mortality in schizophrenia", *Annu Rev Clin Psychol*, c. 10, ss. 425-448, 2014, doi: 10.1146/annurev-clinpsy-032813-153657.
- [160] B. A. Palmer, V. S. Pankratz, ve J. M. Bostwick, "The Lifetime Risk of Suicide in Schizophrenia: A Reexamination", *Archives of General Psychiatry*, c. 62, sy 3, ss. 247-253, Mar. 2005, doi: 10.1001/archpsyc.62.3.247.
- [161] B. Ay vd., "Automated Depression Detection Using Deep Representation and Sequence Learning with EEG Signals", *Journal of Medical Systems*, c. 43, sy 7, s. 205, May. 2019, doi: 10.1007/s10916-019-1345-y.
- [162] D. P. Subha, P. K. Joseph, R. Acharya U, ve C. M. Lim, "EEG Signal Analysis: A Survey", *Journal of Medical Systems*, c. 34, sy 2, ss. 195-212, Nis. 2010, doi: 10.1007/s10916-008-9231-z.
- [163] Y. Gujju, A. Matsuo, ve R. Raymond, "Quantum Machine Learning on Near-Term Quantum Devices: Current State of Supervised and Unsupervised Techniques for Real-World Applications", 03 Temmuz 2023, arXiv: arXiv:2307.00908.
- [164] R. Buettner, D. Beil, S. Scholtz, ve A. Djemai, "Development of a Machine Learning Based Algorithm To Accurately Detect Schizophrenia based on One-minute EEG Recordings", *Hawaii International Conference on System Sciences*, 2020. doi: 10.24251/HICSS.2020.393.
- [165] J. Johannesen, J. Bi, R. Jiang, J. Kenney, ve C.-M. Chen, "Machine learning identification of EEG features predicting working memory performance in schizophrenia and healthy adults", *Neuropsychiatric Electrophysiology*, c. 2, Ara. 2016, doi: 10.1186/s40810-016-0017-0.
- [166] J. Ruiz de Miras, A. J. Ibáñez-Molina, M. F. Soriano, ve S. Iglesias-Parro, "Schizophrenia classification using machine learning on resting state EEG signal", *Biomedical Signal Processing and Control*, c. 79, s. 104233, Oca. 2023, doi: 10.1016/j.bspc.2022.104233.
- [167] K. Das ve R. B. Pachori, "Schizophrenia detection technique using multivariate iterative filtering and multichannel EEG signals", *Biomedical Signal Processing and Control*, c. 67, s. 102525, May. 2021, doi: 10.1016/j.bspc.2021.102525.
- [168] M. Sharma ve U. R. Acharya, "Automated detection of schizophrenia using optimal wavelet-based $\|x\|_1$ norm features extracted from single-channel EEG", *Cognitive Neurodynamics*, c. 15, sy 4, ss. 661-674, Ağu. 2021, doi: 10.1007/s11571-020-09655-w.
- [169] L. Zhang, "EEG Signals Classification Using Machine Learning for The Identification and Diagnosis of Schizophrenia", *41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Tem. 2019, ss. 4521-4524. doi: 10.1109/EMBC.2019.8857946.

- [170] S. K. Tikka vd., "Artificial intelligence-based classification of schizophrenia: A high density electroencephalographic and support vector machine study", *Indian J Psychiatry*, c. 62, sy 3, ss. 273-282, 2020, doi: 10.4103/psychiatry.IndianJPsychiatry_91_20.
- [171] R. Sharma, S. Tripathi, ve K. K. Sekhon, "Detection of Schizophrenia using Machine Learning", 3rd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE), May. 2023, ss. 505-512. doi: 10.1109/ICACITE57410.2023.10183069.
- [172] M. A. Vázquez, A. Maghsoudi, ve I. P. Mariño, "An Interpretable Machine Learning Method for the Detection of Schizophrenia Using EEG Signals", *Front Syst Neurosci*, c. 15, s. 652662, 2021, doi: 10.3389/fnsys.2021.652662.
- [173] M. Shim, H.-J. Hwang, D.-W. Kim, S.-H. Lee, ve C.-H. Im, "Machine-learning-based diagnosis of schizophrenia using combined sensor-level and source-level EEG features", *Schizophrenia Research*, c. 176, sy 2, ss. 314-319, Eki. 2016, doi: 10.1016/j.schres.2016.05.007.
- [174] C. A. T. Naira ve C. J. L. D. Alamo, "Classification of People who Suffer Schizophrenia and Healthy People by EEG Signals using Deep Learning", *International Journal of Advanced Computer Science and Applications (IJACSA)*, c. 10, sy 10, Art. sy 10, 31 2019, doi: 10.14569/IJACSA.2019.0101067.
- [175] A. Nikhil Chandran, K. Sreekumar, ve D. P. Subha, "EEG-Based Automated Detection of Schizophrenia Using Long Short-Term Memory (LSTM) Network", *Advances in Machine Learning and Computational Intelligence*, Springer, 2021, ss. 229-236. doi: 10.1007/978-981-15-5243-4_19.
- [176] G. Sharma ve A. M. Joshi, "SzHNN: A Novel and Scalable Deep Convolution Hybrid Neural Network Framework for Schizophrenia Detection Using Multichannel EEG", *IEEE Transactions on Instrumentation and Measurement*, c. 71, ss. 1-9, 2022, doi: 10.1109/TIM.2022.3212040.
- [177] S. L. Oh, J. Vicnesh, E. J. Ciaccio, R. Yuvaraj, ve U. R. Acharya, "Deep Convolutional Neural Network Model for Automated Diagnosis of Schizophrenia Using EEG Signals", *Applied Sciences*, c. 9, sy 14, Art. sy 14, Oca. 2019, doi: 10.3390/app9142870.
- [178] S. K. Khare, V. Bajaj, ve U. R. Acharya, "SPWVD-CNN for Automated Detection of Schizophrenia Patients Using EEG Signals", *IEEE Transactions on Instrumentation and Measurement*, c. 70, ss. 1-9, 2021, doi: 10.1109/TIM.2021.3070608.
- [179] C. A. Ellis, A. Sattiraju, R. Miller, ve V. Calhoun, "Examining Effects of Schizophrenia on EEG with Explainable Deep Learning Models", 29 Mayıs 2022, bioRxiv. doi: 10.1101/2022.05.26.493659.
- [180] J. Sun vd., "A hybrid deep neural network for classification of schizophrenia using EEG Data", *Sci Rep*, c. 11, sy 1, Art. sy 1, Şub. 2021, doi: 10.1038/s41598-021-83350-6.
- [181] A. Shalbaf, S. Bagherzadeh, ve A. Maghsoudi, "Transfer learning with deep convolutional neural network for automated detection of schizophrenia from EEG signals", *Phys Eng Sci Med*, c. 43, sy 4, ss. 1229-1239, Ara. 2020, doi: 10.1007/s13246-020-00925-9.
- [182] Z. Aslan ve M. Akin, "A deep learning approach in automated detection of schizophrenia using scalogram images of EEG signals", *Phys Eng Sci Med*, c. 45, sy 1, ss. 83-96, Mar. 2022, doi: 10.1007/s13246-021-01083-2.
- [183] "EEG Database - Schizophrenia". Erişim: 15 Temmuz 2023. [Çevrimiçi]. Erişim adresi: http://brain.bio.msu.ru/eeg_schizophrenia.htm
- [184] S. V. Borisov, A. Ya. Kaplan, N. L. Gorbachevskaya, ve I. A. Kozlova, "Analysis of EEG Structural Synchrony in Adolescents with Schizophrenic Disorders", *Hum Physiol*, c. 31, sy 3, ss. 255-261, May. 2005, doi: 10.1007/s10747-005-0042-z.
- [185] M. Hamada, B. B. Zaidan, ve A. A. Zaidan, "A Systematic Review for Human EEG Brain Signals Based Emotion Classification, Feature Extraction, Brain Condition, Group


- Comparison”, *Journal of Medical Systems*, c. 42, sy 9, s. 162, Tem. 2018, doi: 10.1007/s10916-018-1020-8.
- [186] A. Piryatinska, B. Darkhovsky, ve A. Kaplan, “Binary classification of multichannel-EEG records based on the ϵ -complexity of continuous vector functions”, *Computer Methods and Programs in Biomedicine*, c. 152, ss. 131-139, Ara. 2017, doi: 10.1016/j.cmpb.2017.09.001.
- [187] V. Bougou, I. Mporas, P. Schirmer, ve T. Ganchev, “Evaluation of EEG Connectivity Network Measures based Features in Schizophrenia Classification”, *International Conference on Biomedical Innovations and Applications (BIA)*, Kas. 2019, ss. 1-4. doi: 10.1109/BIA48344.2019.8967453.
- [188] C.-R. Phang, C.-M. Ting, F. Noman, ve H. Ombao, “Classification of EEG-Based Brain Connectivity Networks in Schizophrenia Using a Multi-Domain Connectome Convolutional Neural Network”, *IEEE Journal of Biomedical and Health Informatics*, c. 24, sy 5, ss. 1333-1343, May. 2020, doi: 10.1109/JBHI.2019.2941222.
- [189] K. Singh, S. Singh, ve J. Malhotra, “Spectral features based convolutional neural network for accurate and prompt identification of schizophrenic patients”, *Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine*, c. 235, sy 2, ss. 167-184, Şub. 2021, doi: 10.1177/0954411920966937.
- [190] C.-R. Phang, F. Noman, H. Hussain, C.-M. Ting, ve H. Ombao, “A Multi-Domain Connectome Convolutional Neural Network for Identifying Schizophrenia From EEG Connectivity Patterns”, *IEEE Journal of Biomedical and Health Informatics*, c. 24, sy 5, ss. 1333-1343, May. 2020, doi: 10.1109/JBHI.2019.2941222.
- [191] Z. Aslan ve M. Akin, “Automatic Detection of Schizophrenia by Applying Deep Learning over Spectrogram Images of EEG Signals”, *Traitement du Signal*, c. 37, ss. 235-244, Nis. 2020, doi: 10.18280/ts.370209.
- [192] Kandala. N. V. P. S. Rajesh ve T. Sunil Kumar, “Schizophrenia Detection in Adolescents from EEG Signals using Symmetrically weighted Local Binary Patterns”, *43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Kas. 2021, ss. 963-966. doi: 10.1109/EMBC46164.2021.9630232.
- [193] A. Khodabakhsh, H. Arabi, ve H. Zaidi, “U-Net Based Estimation of Functional Connectivity from Time Series Multi-Channel EEG from Schizophrenia Patients”, *IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC)*, Eki. 2021, ss. 1-4. doi: 10.1109/NSS/MIC44867.2021.9875427.
- [194] R. Supakar, P. Satvaya, ve P. Chakrabarti, “A deep learning based model using RNN-LSTM for the Detection of Schizophrenia from EEG data”, *Computers in Biology and Medicine*, c. 151, s. 106225, Ara. 2022, doi: 10.1016/j.combiomed.2022.106225.
- [195] J. Xin vd., “Hybrid High-order Brain Functional Networks for Schizophrenia-Aided Diagnosis”, *Cognitive Computation*, c. 14, sy 4, ss. 1303-1315, Tem. 2022, doi: 10.1007/s12559-022-10014-6.
- [196] N. J. Sairamya, M. S. P. Subathra, ve S. Thomas George, “Automatic identification of schizophrenia using EEG signals based on discrete wavelet transform and RLNDiP technique with ANN”, *Expert Systems with Applications*, c. 192, s. 116230, Nis. 2022, doi: 10.1016/j.eswa.2021.116230.
- [197] A. Zülfikar ve A. Mehmet, “Empirical mode decomposition and convolutional neural network-based approach for diagnosing psychotic disorders from eeg signals”, *Applied Intelligence*, c. 52, sy 11, ss. 12103-12115, Eyl. 2022, doi: 10.1007/s10489-022-03252-6.
- [198] N. Sobahi, B. Ari, H. Cakar, O. F. Alcin, ve A. Sengur, “A New Signal to Image Mapping Procedure and Convolutional Neural Networks for Efficient Schizophrenia Detection in EEG Recordings”, *IEEE Sensors Journal*, c. 22, sy 8, ss. 7913-7919, Nis. 2022, doi: 10.1109/JSEN.2022.3151465.
- [199] C. L. Alves, A. M. Pineda, K. Roster, C. Thielemann, ve F. A. Rodrigues, “EEG functional connectivity and deep learning for automatic diagnosis of brain disorders: Alzheimer’s

- disease and schizophrenia”, *Journal of Physics: Complexity*, c. 3, sy 2, s. 025001, Nis. 2022, doi: 10.1088/2632-072X/ac5f8d.
- [200] T. S. Kumar, K. N. V. P. S. Rajesh, S. Maheswari, V. Kanhangad, ve U. R. Acharya, “Automated Schizophrenia detection using local descriptors with EEG signals”, *Engineering Applications of Artificial Intelligence*, c. 117, s. 105602, Oca. 2023, doi: 10.1016/j.engappai.2022.105602.
- [201] K. Balasubramanian, K. Ramya, ve K. Gayathri Devi, “Optimized adaptive neuro-fuzzy inference system based on hybrid grey wolf-bat algorithm for schizophrenia recognition from EEG signals”, *Cognitive Neurodynamics*, c. 17, sy 1, ss. 133-151, Şub. 2023, doi: 10.1007/s11571-022-09817-y.
- [202] D. Grubin ve L. Madsen, “Lie detection and the polygraph: A historical review”, *The Journal of Forensic Psychiatry & Psychology*, c. 16, sy 2, ss. 357-369, Haz. 2005, doi: 10.1080/14789940412331337353.
- [203] “The Truth About Lie Detectors (aka Polygraph Tests)”, <https://www.apa.org>. Erişim: 20 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://www.apa.org/topics/cognitive-neuroscience/polygraph>
- [204] A. Vrij, P. A. Granhag, T. Ashkenazi, G. Ganis, S. Leal, ve R. P. Fisher, “Verbal Lie Detection: Its Past, Present and Future”, *Brain Sciences*, c. 12, sy 12, Art. sy 12, Ara. 2022, doi: 10.3390/brainsci12121644.
- [205] A. Vrij ve S. Mann, “Criteria-Based Content Analysis: An empirical test of its underlying processes”, *Psychology, Crime & Law*, Ağu. 2006, doi: 10.1080/10683160500129007.
- [206] K. Subramaniam, H. Kothare, D. Mizuiri, S. S. Nagarajan, ve J. F. Houde, “Reality Monitoring and Feedback Control of Speech Production Are Related Through Self-Agency”, *Front. Hum. Neurosci.*, c. 12, Mar. 2018, doi: 10.3389/fnhum.2018.00082.
- [207] Y. Gancedo, F. Fariña, D. Seijo, M. Vilarinho, ve R. Arce, “Reality Monitoring: A Meta-analytical Review for Forensic Practice”, *Psy. intervention*, c. 13, sy 2, ss. 99-110, Tem. 2021, doi: 10.5093/ejpalc2021a10.
- [208] D. M. com\$Department of English vd., “Statement Analysis of Deception Detection”, *Open Access Library Journal*, c. 02, sy 10, Art. sy 10, 2015, doi: 10.4236/oalib.1101975.
- [209] J. P. Rosenfeld, V. T. Nasman, R. Whalen, B. Cantwell, ve L. Mazzeri, “Late Vertex Positivity in Event-Related Potentials as a Guilty Knowledge Indicator: A New Method of Lie Detection”, *International Journal of Neuroscience*, c. 34, sy 1-2, ss. 125-129, Oca. 1987, doi: 10.3109/00207458708985947.
- [210] L. A. Farwell, “Brain fingerprinting: a comprehensive tutorial review of detection of concealed information with event-related brain potentials”, *Cogn Neurodyn*, c. 6, sy 2, ss. 115-154, Nis. 2012, doi: 10.1007/s11571-012-9192-2.
- [211] M. Karnati, A. Seal, A. Yazidi, ve O. Krejcar, “LieNet: A deep convolution neural Network framework for detecting deception”, *LieNet: A deep convolution neural Network framework for detecting deception*, 2022, doi: 10.1109/TCDS.2021.3086011.
- [212] S. Anwar, T. Batool, ve M. Majid, “Event Related Potential (ERP) based Lie Detection using a Wearable EEG headset”, içinde 2019 16th International Bhurban Conference on Applied Sciences and Technology (IBCAST), Oca. 2019, ss. 543-547. doi: 10.1109/IBCAST.2019.8667131.
- [213] H. Javaid, A. Dilawari, U. G. Khan, ve B. Wajid, “EEG Guided Multimodal Lie Detection with Audio-Visual Cues”, içinde 2022 2nd International Conference on Artificial Intelligence (ICAI), Mar. 2022, ss. 71-78. doi: 10.1109/ICAI55435.2022.9773469.
- [214] M. Aslan, M. Baykara, ve T. B. Alakuş, “LSTMNCP: lie detection from EEG signals with novel hybrid deep learning method”, *Multimed Tools Appl*, c. 83, sy 11, ss. 31655-31671, Mar. 2024, doi: 10.1007/s11042-023-16847-z.
- [215] J. Gao vd., “A Novel Approach for Lie Detection Based on F-Score and Extreme Learning Machine”, *PLOS ONE*, c. 8, sy 6, s. e64704, Haz. 2013, doi: 10.1371/journal.pone.0064704.


- [216] D. R. Edla, S. Dodia, A. Bablani, ve V. Kuppili, “An Efficient Deep Learning Paradigm for Deceit Identification Test on EEG Signals”, *ACM Trans. Manage. Inf. Syst.*, c. 12, sy 3, s. 25:1-25:20, Haz. 2021, doi: 10.1145/3458791.
- [217] J. Gao, L. Lu, Y. Yang, G. Yu, L. Na, ve N. Rao, “A novel concealed information test method based on independent component analysis and support vector machine”, *Clin EEG Neurosci*, c. 43, sy 1, ss. 54-63, Oca. 2012, doi: 10.1177/1550059411428715.
- [218] E. D. Farahani ve M. H. Moradi, “Multimodal detection of concealed information using Genetic-SVM classifier with strict validation structure”, *Informatics in Medicine Unlocked*, c. 9, ss. 58-67, Oca. 2017, doi: 10.1016/j.imu.2017.05.004.
- [219] A. AlArfaj ve H. Ahmed, “A Deep Learning Model for EEG-Based Lie Detection Test Using Spatial and Temporal Aspects”, *CMC*, c. 73, sy 3, ss. 5655-5669, 2022, doi: 10.32604/cmc.2022.031135.
- [220] M. Aslan, M. Baykara, ve T. B. Alakuş, “LieWaves”, c. 1, Ara. 2023, doi: 10.17632/5gzxb2bzs2.1.
- [221] M. Aslan, M. Baykara, and T. B. Alakus, “LieWaves: dataset for lie detection based on EEG signals and wavelets,” *Medical & Biological Engineering & Computing*, vol. 62, pp. 1571-1588, 2024, <https://doi.org/10.1007/s11517-024-03021-2>.
- [222] “TwoLocal”, IBM Quantum Documentation. Erişim: 17 Temmuz 2024. [Çevrimiçi]. Erişim adresi: <https://docs.quantum.ibm.com/api/qiskit/qiskit.circuit.library.TwoLocal>
- [223] W. Li ve D.-L. Deng, “Recent advances for quantum classifiers”, *Sci. China Phys. Mech. Astron.*, c. 65, sy 2, s. 220301, Ara. 2021, doi: 10.1007/s11433-021-1793-6.

EKLER


EK- 1: PSO-QSVM ALGORİTMASINDA KULLANILAN ÖZELLİK HARİTALARI (RASTGELE BÖLÜMLEME)




Şekil E1.1. 3 kübit tek tekrar için ‘ZZY’, ‘XI’ özellik haritası




Şekil E1.2. 3 kübit tek tekrar için oluşturulan ‘YYY’, ‘YX’ özellik haritası




Şekil E1.3. 3 kübit tek tekrar için oluşturulan ‘XZY’, ‘XXX’ özellik haritası




Şekil E1.4. 3 kübit tek tekrar için oluşturulan ‘YY’, ‘IX’ özellik haritası




Şekil E1.5. 3 kübit tek tekrar için oluşturulan 'YX' özellik haritası




Şekil E1.6. 3 kübit tek tekrar için oluşturulan 'Z','YZ' özellik haritası




Şekil E1.7. 3 kübit tek tekrar için oluşturulan 'ZY','X','YZ' özellik haritası




Şekil E1.8. 3 kübit tek tekrar için oluşturulan 'XI','ZX' özellik haritası




Şekil E1.9. 3 kübit tek tekrar için oluşturulan 'XZ','YYZ' özellik haritası




Şekil E1.10. 3 kübit tek tekrar için oluşturulan 'YYY', 'X', 'XXZ' özellik haritası




Şekil E1.11. 3 kübit tek tekrar için oluşturulan 'YY' özellik haritası




Şekil E1.12. 3 kübit tek tekrar için oluşturulan 'XYX', 'YI' özellik haritası




Şekil E1.13. 3 kübit tek tekrar için oluşturulan 'XY', 'XXY' özellik haritası




Şekil E1.14. 3 kübit tek tekrar için oluşturulan 'ZY', 'XX', 'XXX' özellik haritası




Şekil E1.15. 3 kübit tek tekrar için oluşturulan 'ZX', 'ZY' özellik haritası




Şekil E1.16. 3 kübit tek tekrar için oluşturulan 'Z', 'XYY', 'ZZ' özellik haritası




Şekil E1.17. 3 kübit tek tekrar için oluşturulan 'YY', 'XZX', 'ZZ' özellik haritası



Şekil E1.18. 3 kübit tek tekrar için oluşturulan 'XYZ', 'IY' özellik haritası




Şekil E1.19. 3 kübit tek tekrar için oluşturulan 'YI', 'YYY' özellik haritası




Şekil E1.20. 3 kübit tek tekrar için oluşturulan 'Y', 'Y' özellik haritası


EK- 2: PSO-QSVM ALGORİTMASINDA KULLANILAN ÖZELLİK HARİTALARI (K KATLI ÇAPRAZ DOĞRULAMA)




Şekil E2.1. 3 kübit tek tekrar için oluşturulan 'IY', 'XXX', 'XXZ' özellik haritası




Şekil E2.2. 3 kübit tek tekrar için oluşturulan 'XZZ', 'X' özellik haritası




Şekil E2.3. 3 kübit tek tekrar için oluşturulan 'IZ', 'X' özellik haritası




Şekil E2.4. 3 kübit tek tekrar için oluşturulan 'YZZ', 'Z', 'ZZZ' özellik haritası




Şekil E2.5. 3 kübit tek tekrar için oluşturulan ‘YZ’, ‘X’, ‘IZ’ özellik haritası




Şekil E2.6. 3 kübit tek tekrar için oluşturulan ‘IY’, ‘XYZ’ özellik haritası




Şekil E2.7. 3 kübit tek tekrar için oluşturulan ‘YZ’, ‘ZX’ özellik haritası




Şekil E2.8. 3 kübit tek tekrar için oluşturulan ‘ZX’, ‘IY’ özellik haritası




Şekil E2.9. 3 kübit tek tekrar için oluşturulan ‘XXY’, ‘ZZ’, ‘YI’ özellik haritası




Şekil E2.10. 3 kübit tek tekrar için oluşturulan 'XY' özellik haritası




Şekil E2.11. 3 kübit tek tekrar için oluşturulan 'ZZ', 'XI' özellik haritası




Şekil E2.12. 3 kübit tek tekrar için oluşturulan 'ZZZ', 'ZZZ', 'ZZZ' özellik haritası




Şekil E2.13. 3 kübit tek tekrar için oluşturulan 'IY', 'X' özellik haritası




Şekil E2.14. 3 kübit tek tekrar için oluşturulan ‘Y’, ‘XX’ özellik haritası




Şekil E2.15. 3 kübit tek tekrar için oluşturulan ‘XI’, ‘Y’ özellik haritası



Şekil E2.16. 3 kübit tek tekrar için oluşturulan ‘YI’, ‘YZ’ özellik haritası




Şekil E2.17. 3 kübit tek tekrar için oluşturulan ‘ZI’, ‘YZY’ özellik haritası




Şekil E2.18. 3 kübit tek tekrar için oluşturulan ‘YZ’, ‘X’ özellik haritası


EK- 3: VQC ALGORİTMASINDA KULLANILAN ÖZELLİK HARİTALARI (KATLI ÇAPRAZ DOĞRULAMA)




Şekil E3.1. 3 kübit tek tekrar için oluşturulan ‘X’, ‘Y’ özellik haritası



Şekil E3.2. 3 kübit tek tekrar için oluşturulan ‘X’, ‘XYX’ özellik haritası




Şekil E3.3. 3 kübit tek tekrar için oluşturulan ‘ZI’ özellik haritası




Şekil E3.4. 3 kübit tek tekrar için oluşturulan ‘Y’, ‘YY’, ‘YY’ özellik haritası

EK- 4: VQC ALGORİTMASINDA KULLANILAN PARAMETRİK KUANTUM DEVRELERİ (K KATLI ÇAPRAZ DOĞRULAMA)


Aşağıdaki tüm şekiller VQC algoritmasında kullanılan kuantum parametrik devrelerinin 3 kubit ve tek tekrardan oluşan durumları için verilmiştir. Tablo E4.1’de tüm şekillere ait kubit sayısı ve devre tekrar sayısı analiz sonucunda elde edilen verilere göre sunulmuştur.




Şekil E4.1. AF4 kanalı için ["rz","ry"], "cy" kuantum parametrik devresi




Şekil E4.2. AF4 kanalı için ["rx"], "cy" kuantum parametrik devresi




Şekil E4.3. AF4 kanalı için ["rx"], "cx" kuantum parametrik devresi




Şekil E4.4. AF4 kanalı için ["rx"], "cz" kuantum parametrik devresi




Şekil E4.5. AF3 kanalı için ["rx","ry"], "cx" kuantum parametrik devresi



Şekil E4.6. AF3 kanalı için ["ry"], "cx" kuantum parametrik devresi



Şekil E4.7. AF3 kanalı için ["ry","rz"], "cz" kuantum parametrik devresi



Şekil E4.8. AF3 kanalı için ["rx","rz"], "cy" kuantum parametrik devresi

Tablo E4.1. VQC algoritmasında kullanılan kuantum parametrik devrelerinin dönüş açıları

Şekil No	Kübit Sayısı	Parametrik Kuantum Devreleri	Tekrar Sayısı	Dönüş Açıları
E4.1	3	["rz","ry"], "cy"	2	[0.687 1.126 2.059 0.004 0.019 1.101 2.208 1.505 1.688 1.993 1.837 1.795 1.266 1.579 1.569 1.072 0.690 1.044]
E4.2	4	["rx"], "cy"	2	[1.513 2.668 0.924 0.730 1.911 -1.372 0.435 0.558 1.172 0.584 0.288 0.088]
E4.3	5	["rx"], "cx"	1	[-2.725 0.320 1.234 0.903 2.217 2.000 1.260 1.107 0.684 0.354]
E4.4	6	["rx"], "cz"	2	[3.014 1.250 1.667 -1.083 0.266 1.346 1.736 2.464 0.928 0.588 -0.120 0.376 1.592 -0.021 0.290 -0.284 0.009 0.761]
E4.5	3	["rx","ry"], "cx"	2	[1.473 1.908 0.152 1.129 2.349 0.422 1.160 1.611 0.554 -0.157 1.445 1.207 0.062 1.779 -0.036 1.335 1.854 -0.142]
E4.6	4	["ry"], "cx"	2	[1.387e+00 -7.174e-01 1.729e+00 8.746e-01 -4.805e-01 -1.773e-03 -4.584e-01 -3.164e-01 1.970e+00 2.333e+00 9.757e-01 4.791e-01]
E4.7	5	["ry","rz"], "cz"	2	[0.979 2.499 0.973 1.143 0.426 2.500 0.164 2.050 -0.488 1.739 0.514 0.244 -0.363 -0.317 -0.598 -0.786 -0.031 1.301 1.189 0.017 -0.152 0.315 2.148 -0.074 0.429 0.327 0.083]
E4.8	6	["rx","rz"], "cy"	1	[1.066 0.934 0.203 1.963 1.340 1.544 0.5551 0.839 2.076 0.849 0.877 0.321 1.275 0.155 2.112 0.319 1.356 -0.146 1.788 1.120 -0.412 1.2455 0.371 0.688]

ÖZGEÇMİŞ

Gamzepelin AKSOY

[illegible]

[illegible]

[REDACTED]

[REDACTED] [REDACTED]

[REDACTED]

AKADEMİK FAALİYETLER

Makaleler:

1. G. Aksoy, G. Cattan, S. Chakraborty, ve M. Karabatak, “Quantum Machine-Based Decision Support System for the Detection of Schizophrenia from EEG Records”, *J Med Syst*, c. 48, sy 1, s. 29, Mar. 2024, doi: 10.1007/s10916-024-02048-0.
2. T. G. Üregen, G. Aksoy, ve A. Koca, “Faz Değiştiren Madde Olarak Nano Katkılı Stearik Asit ve Palmitik Asidin Termofiziksel Özelliklerinin İncelenmesi”, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, c. 31, sy 2, Art. sy 2, Eyl. 2019, doi: 10.35234/fumbd.529987

Bildiriler:

1. G. Aksoy ve M. Karabatak, "Comparison of QSVM with Other Machine Learning Algorithms on EEG Signals", içinde *2023 11th International Symposium on Digital Forensics and Security (ISDFS)*, May. 2023, ss. 1-5. doi: 10.1109/ISDFS58141.2023.10131123.
2. G. Aksoy, P. Ataş, ve M. Karabatak, "Investigation of Shopping Habits Using Data Mining Classification Algorithms", içinde *2019 1st International Informatics and Software Engineering Conference (UBMYK)*, Kas. 2019, ss. 1-5. doi: 10.1109/UBMYK48245.2019.8965647.
3. G. Aksoy ve M. Karabatak, "Performance Comparison of New Fast Weighted Naïve Bayes Classifier with Other Bayes Classifiers", içinde *2019 7th International Symposium on Digital Forensics and Security (ISDFS)*, Haz. 2019, ss. 1-5. doi: 10.1109/ISDFS.2019.8757558.

