

**T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MAKİNE ÖĞRENİMİ ALGORİTMALARI KULLANILARAK EEG
SİNYALLERİNDEN MATEMATİK OYUN PERFORMANS TAHMİNİ**

Pınar KILIÇ

**Danışman
Prof. Dr. Muhammet DEMİRBİLEK**

**II. Danışman
Dr. Öğr. Üyesi Durmuş KOÇ**

**YÜKSEK LİSANS TEZİ
EĞİTİM TEKNOLOJİLERİ ANABİLİM DALI
ISPARTA - 2024**



© 2024 [Pınar KILIÇ]

İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER.....	i
ÖZET	iv
ABSTRACT	vi
TEŞEKKÜR.....	viii
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ	x
SİMGELER VE KISALTMALAR DİZİNİ	xi
1. GİRİŞ.....	1
1.1. Problem Durumu	1
1.2. Araştırmanın Amacı.....	2
1.3. Araştırmanın Önemi	3
1.4. Özgün Değer	5
1.5. Sınırlılıklar.....	5
1.6. Varsayımlar	6
2. KAVRAMSAL ÇERÇEVE VE İLGİLİ ÇALIŞMALAR.....	8
2.1. Oyun	8
2.1.1. Oyun öğrenme ilişkisi.....	8
2.1.2. Dijital oyun	10
2.1.3. Dijital oyun tarihçesi.....	13
2.1.4. Eğitsel dijital oyun	16
2.1.5. Matematik eğitiminde dijital oyun	20
2.2. Beyin Bilgisayar Arayüzü (BBA)	23
2.2.1. Duygu ve duyuşsal hesaplama.....	25
2.3. EEG (Elektroensefalogram)	27
2.3.1. EEG kullanımı	30
2.3.2. Çalışmada kullanılan EEG cihazı (Emotive™ EPOCH)	36
2.3.3. EEG tabanlı eğitsel oyunlar	41
2.4. Yapay Zekâ.....	42
2.5. Veri Madenciliği	44
2.6. İlgili Alan Araştırmaları	47
2.6.1. Dijital oyunların eğitsel amaçlı kullanımı üzerinde gerçekleştirilen ..	47
2.6.2. Türkiye’de dijital oyunların eğitsel amaçlı olarak kullanımı üzerine gerçekleştirilen araştırmalar	49

2.6.3. Dijital matematik oyunlarının eğitsel amaçla kullanıldığı çalışmalar	51
2.6.4. EEG ile ilgili yapılmış çalışmalar	53
2.6.5. EEG ile ilgili eğitim alanında yapılan çalışmalar	55
2.6.6. Matematik eğitiminde EEG verilerinin analizi ile ilgili yapılan çalışmalar	56
3. YÖNTEM	58
3.1. Araştırma Modeli	58
3.2. Araştırmanın Çalışma Grubu ve Araştırma Ortamı	59
3.2.1. Çalışma grubu seçimi	59
3.2.2. Deney ortamı ve şartları	60
3.3. Veri Toplama Araçları	61
3.3.1. EEG cihazı ve özellikleri	61
3.3.2. Eğitsel dijital matematik oyunu: “Labirent”	61
3.3.3. Veri toplama süreci	67
3.4. Veri Analizi	69
3.4.1. Oyun performans puanının hesaplanması	69
3.4.2. EEG verilerinin analizi	70
3.4.2.1. Farklı katılımcılardan elde edilen verilerin birleştirilmesi	71
3.4.2.2. EEG verilerinin ön işleme	73
3.4.2.3. Kayıp değerlerin silinmesi	75
3.4.2.4. Normalizasyon	75
3.4.2.5. Aykırı verilerin kapsam dışı bırakılması (outliers detection)	76
3.4.2.6. Ayırt edici özneliliklerin seçilmesi	77
3.4.3. Oyun performansının tahminlenmesinde kullanılan algoritmalar ve algoritmaların modellenmesi	78
3.4.3.1. AdaBoost	78
3.4.3.2. Gradient Boosting (GB)	79
3.4.3.3. kNN (K-Nearest Neighbors- K-en yakın komşu)	79
3.4.3.4. NB (Naive Bayes)	80
3.4.3.5. RF (Random Forest-Rastgele Orman)	81
3.4.3.6. Karar Ağaçları (Decision Trees)	81
3.4.3.7. NN (Neural Networks- Sinir Ağları)	82
3.4.3.8. SGD (Stochastic Gradient Descent- Stokastik Gradyan İnişi)	82
3.4.3.9. SVM (Support Vector Machine- Destek vektör makinesi)	83
3.4.4. Performans değerlendirme kriterleri	84
3.4.4.1. Cross validation (k-kat çapraz doğrulama)	85
3.4.4.2. Karmaşıklık matrisi (Confusion matrix)	85

4. ARAŞTIRMA BULGULARI.....	88
4.1. Oyun Performansının Değerlendirmesinde Ayırt Edici Özniteliklerin Belirlenmesi	88
4.2. Oyun Performans Tahminlenmesinde Kullanılan Algoritmaların Değerlendirme Ölçüt Çıktıları.....	89
4.3. Algoritmaların Karmaşıklık Matrisi Çıktıları.....	90
5. TARTIŞMA VE SONUÇ	94
KAYNAKLAR	98
EKLER.....	121
Ek A. Gönüllü Katılım Formu	121
EK B. Katılım Sonrası Bilgilendirme Formu.....	122
Ek C. Etik Kurul Onayı.....	123
Ek D. Etik Kurul Onayı	124
ÖZGEÇMİŞ.....	125

ÖZET

Yüksek Lisans Tezi

MAKİNE ÖĞRENİMİ ALGORİTMALARI KULLANILARAK EEG SİNYALLERİNDEN MATEMATİK OYUN PERFORMANS TAHMİNİ

Pınar KILIÇ

Süleyman Demirel Üniversitesi
Fen Bilimleri Enstitüsü
Eğitim Teknolojileri Anabilim Dalı

Danışman: Prof. Dr. Muhammet DEMİRBİLEK

II. Danışman: Dr. Öğr. Üyesi Durmuş KOÇ

Çalışmada matematik öğretim programına yönelik tasarlanan dijital bir oyunun oynanması sırasında elde edilen EEG (Elektroensefalografi) verilerinin kullanılarak oyun performansının tahmin edilmesi amaçlanmıştır. Bu amaç doğrultusunda katılımcılara çalışma kapsamında geliştirilen eğitsel dijital bir matematik oyunu oynatılmış ve eş zamanlı olarak beyin sinyalleri kaydedilmiştir. Katılımcılar bilgisayar mühendisliği öğrencilerinden elverişli örnekleme yöntemiyle seçilen 18-25 arası gönüllü erkek deneklerdir. Katılımcılardan elde edilen veriler birleştirilmiş, oyun puanları hesaplanarak etiketlenmiş ve veri ön işleme sürecine geçilmiştir. Veri ön işleme sürecinde eksik veriler çıkarılmış, normalizasyon ve aykırı değerler tespiti işlemleri uygulanarak gürültü azaltılmıştır. Öznitelik seçim sürecinde X^2 (ki-kare) fonksiyonu kullanılarak en iyi ayırt edici öznitelikler belirlenmiştir. Oyun performansını en iyi ayırt eden öznitelikler sırasıyla POW.FC5.Gamma, POW.AF3.Gamma, EEG.O1, POW.P8.Gamma ve POW.AF3.BetaH olduğu tespit edilmiştir. Bu öznitelikler dikkat, görsel işleme ve uzamsal farkındalık gibi bilişsel süreçleri yansıtmakta olup oyun performansıyla doğrudan ilişkilidir. Çalışmada oyun performansının tahminlenmesinde k-En Yakın Komşu (kNN), Destek Vektör Makineleri (SVM), Rastgele Orman (RF), AdaBoost, Gradient Boosting, Sinir Ağları (NN) ve Stokastik Gradyan İnişi (SGD) gibi çeşitli makine öğrenmesi algoritmaları kullanılmıştır. Algoritmaların performansı, AUC (Eğri Altında Kalan Alan) değeri ile ölçülmüş ve Gradient Boosting algoritması % 87.7 ile en yüksek doğruluğa ulaşmıştır. Elde edilen bu bulgular sonucunda, EEG verilerinin en iyi ayırt edici öznitelikleri tespit edilmiş, bu özniteliklerin oyuncuların bilişsel süreçlerini, dikkat seviyelerini ve görsel-motor becerilerini doğrudan yansıttığı görülmüştür. Böylece eğitsel dijital oyunlarda öğrencilerin performansını daha doğru ve güvenilir bir şekilde değerlendirmeye yönelik yenilikçi bir yöntem sunulmuş ve eğitimde nörobilimsel verilerin kullanımına önemli katkılar sağlanmıştır.

Anahtar Kelimeler: Eđitsel dijital oyun, matematik eđitimi, makine ğrenmesi, EEG (elektroensefalografi), BBA (beyin bilgisayar arayüzü), yapay zekâ

2024, 125 sayfa



ABSTRACT

M.Sc. Thesis

MATH GAME PERFORMANCE PREDICTION FROM EEG SIGNALS USING MACHINE LEARNING ALGORITHMS

Pınar KILIÇ

**Süleyman Demirel University
Graduate School of Natural and Applied Sciences
Department of Educational Technologies**

Supervisor: Prof. Dr. Muhammet DEMİRBİLEK

Co Supervisor: Asst. Prof. Dr. Durmuş KOÇ

The study aimed to predict game performance by using EEG (Electroencephalography) data obtained while playing a digital game designed for the mathematics curriculum. For this purpose, an educational digital mathematics game developed within the scope of the study was played to the participants and their brain signals were recorded simultaneously. The participants are male volunteers between 18 and 25, selected by convenient sampling method from computer engineering students. The data obtained from the participants were combined, game scores were calculated and labeled, and the data pre-processing process began. During the data pre-processing process, missing data were removed and noise was reduced by applying normalization and outlier detection processes. In the feature selection process, the best discriminant features were determined by using the χ^2 (chi-square) function. The features that best differentiate game performance are POW.FC5.Gamma, POW.AF3.Gamma, EEG.O1, POW.P8.Gamma and POW.AF3.BetaH, respectively. These attributes reflect cognitive processes such as attention, visual processing and spatial awareness and are directly related to game performance. In the study, various machine learning algorithms such as k-Nearest Neighbors (kNN), Support Vector Machines (SVM), Random Forest (RF), AdaBoost, Gradient Boosting, Neural Networks (NN) and Stochastic Gradient Descent (SGD) were used to predict game performance. The performance of the algorithms was measured by the AUC (Area Under the Curve) value and the Gradient Boosting algorithm reached the highest accuracy with 87.7%. As a result of these findings, the best distinguishing features of the EEG data were identified and it was observed that these features directly reflected the cognitive processes, attention levels and visual-motor skills of the players. Thus, an innovative method has been presented to evaluate students' performance in educational digital games more accurately and reliably, and significant contributions have been made to the use of neuroscientific data in education.

Keywords: Educational digital game, mathematics education, machine learning, EEG (electroencephalography), BCI (brain computer interface), artificial intelligence

2024, 125 pages



TEŞEKKÜR

Bu tez çalışması için beni destekleyen, tecrübelerinden çokça faydalandığım, araştırmanın ilk gününden itibaren bana kılavuzluk eden karşılaştığım zorlukları aşmamda yardımcı olan beni her zaman destekleyen çalışmalarım sırasında katkılarını esirgemeyen çok değerli Danışman hocalarım Prof. Dr. Muhammet DEMİRBİLEK 'e ve Dr. Öğr. Üyesi Durmuş KOÇ 'a en içten dileklerimle teşekkürlerimi sunarım.

Hayatımın her alanında yanımda olan, moral, motivasyon, sonsuz sevgi ve desteğini her zaman hissettiğim değerli eşim Cengiz KILIÇ ve kızlarım Firdevs Meva ve Zümra Kılıç'a bu süreçte bana verdikleri destek ve güç için, sıkıntılarımnda her zaman yanımda oldukları için teşekkür ederim.

Pınar KILIÇ

ISPARTA, 2024

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2. 1. Duygu tanımaya yönelik EEG tabanlı bir BBA sisteminin yapısı	26
Şekil 2. 2. Uluslararası kabul edilen 10-20 sistemi	31
Şekil 2. 3. Uluslararası 10-20 sistemine göre elektrot dizilimi	32
Şekil 2. 4. EEG Modül mimarisi Bölümü	34
Şekil 2. 5. EEG dalga türleri	35
Şekil 2. 6. Emotive™ EPOCH mobil EEG cihazı	37
Şekil 2. 7. Emotive™ EPOCH geliştirme aşamaları	38
Şekil 2. 8. Neural Impulse Actuator (NIA).....	39
Şekil 2. 9. Emotiv, NeuroSky, InteraXon, OpenBCI kullanım verileri	40
Şekil 2. 10. Veri madenciliği süreci	46
Şekil 2. 11. Son yirmi yılda beşer yıllık dönemler halinde eğitimde dijital oyunların kullanımı ile ilgili yapılan araştırma sayısı.....	47
Şekil 3. 1. Wordwall labirent oyunu ekran görüntüsü.....	64
Şekil 3. 2. Ham (raw) EEG verileri.....	71
Şekil 3. 3. K1 katılımcısına ait EEG verileri.....	72
Şekil 3. 4. Etiketlenmiş EEG başlığı verileri.....	72
Şekil 3. 5. EEG verilerinin ön işleme ve sınıflandırma süreci akış diyagramı ...	74
Şekil 3. 6. Kayıp değerlerden (After Outliers) sonra çıkarılan öznitelikler.....	76
Şekil 3. 7. Support Vector Machine (SVM) işleyiş simülasyon görüntüsü	84

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2. 1. Elektrotların adlandırılması	30
Çizelge 3. 1. Zaman, puan ve zamanın puana dönüştürülmüş hali	70
Çizelge 3. 2. Karmaşıklık Matris metrikleri	86
Çizelge 4. 1. Model tabanlı özellik puan bulguları	88
Çizelge 4. 2. Algoritmalara göre test verilerine uygulanan algoritma değerlendirme ölçütleri ve skor verileri.....	89
Çizelge 4. 3. kNN için Karmaşıklık Matrisi	90
Çizelge 4. 4. AdaBoost için Karmaşıklık Matrisi.....	91
Çizelge 4. 5. Tree için Karmaşıklık Matrisi.....	91
Çizelge 4. 6. SVM için Karmaşıklık Matrisi	91
Çizelge 4. 7. Naive Bayes için Karmaşıklık Matrisi	92
Çizelge 4. 8. Gradient Boosting için Karmaşıklık Matrisi	92
Çizelge 4. 9. Neural Network için Karmaşıklık Matrisi	92
Çizelge 4. 10. SGD için Karmaşıklık Matrisi	93
Çizelge 4. 11. Random Forest için Karmaşıklık Matrisi	93

SİMGELER VE KISALTMALAR DİZİNİ

ACC	Cilt iletkenliği
AI	Artificial Intellegence (Yapayzeka)
ANN	Artificial Neural Network (Yapay Sinir Ağları)
AUC	Eğri Altındaki Alan (Area Under the ROC Curve)
BBA	Beyin Bilgisayar Arayüzü
BCI	Brain Computer Interfaces
C	Merkez
CA	Classification Accuracy (Sınıflandırma Doğruluğu)
CART	Sınıflandırma ve Regresyon Ağacı Algoritması
CCA	Kanonik korelasyon analizi
CM	Confusion Matrix (Karmaşıklık Matrisi)
CMS	Ortak Mod Algılama Aktif Elektrotu
CT	Computed Tomography (Bilgisayarlı Tomografi)
DDA	Doğrusal Diskriminant Analizi
DFT	Discrete Fourier Transform (Ayrık Fourier Dönüşümü)
DRL	Referans Sağ Bacak
DWT	Ayrık Dalgacık Dönüşümü
EEG	Electroencephalogram (Elektroensefalogram)
EKG	Electrocardiogram (Elektrokardiyogram)
EMD	Electromechanical Dissociation (Elektromekanik Ayırışma)
EMG	Electromyography (Elektromiyografi)
ERP	Event-related potentials (Olay İlişkili Potansiyel)
F	Frontal
FATİH	Fırsatları Artırma ve Teknolojiyi İyileştirme Hareketi
FFT	Fast Fourier Transform (Hızlı Fourier Dönüşüm)
FMRI	Fonksiyonel Manyetik Rezonans Görüntüleme
FN	False Negatif (Yanlış Negatif)
FNIRS	Fonksiyonel Nörogörüntüleme Tekniği
FP	False Pozitif (Yanlış Pozitif)
Fp	Frontal kutup
GB	Gradient Boosting
GSR	Galvanic Skin Response (Galvanik Cilt Sensörü)
Hz	Hertz
IDC	International Data Corporation
IMU	Inertia Measurement Unit (Hareket Ölçümü Birimi)
KNN	K-Nearest Neighbors (K-En Yakın Komşu)
LSTM	Derin öğrenmesi algoritması
MATLAB	Matrix laboratory (Matris Laboratuvarı)
MEB	Millî Eğitim Bakanlığı
MEG	Manyetoensefalografi
MOOC	Katılımlı Açık Çevrim İçi Platformlar
MWL	Mental Workload (Zihinsel İş Yüğü)
NB	Naive Bayes
NCA	Neighborhood Components Analysis (Komşu Bileşenler Analizi)
NIA	Neural Impulse Actuator
NN	Neural Networks (Sinir Ağları)

O	Oksipital
P	Parietal
PCA	Principal Component Analiz (Temel bileşen analizi)
PET	Pozitron Emisyon Tomografisi
RBF	Radial Basis Fonction (Radyal Tabanlı Fonksiyon)
ReLU	Rectified Linear Unit Function (Düzeltilmiş Doğrusal Birim)
RF	Random Forest (Rastgele Orman)
ROC	Receiver Operating Characteristic (Alıcı işletim karakteristiği)
s	Saniye
SAS	Statistical Analysis System
SGD	Stochastic Gradient Descent
SPSS	Statistical Package for the Social Sciences
STEM	Science, Technology, Engineering, Mathematics
SVM	Support Vector Machine (Destek Vektör Makinaları Algoritması)
T	Temporal
TDK	Türk Dil Kurumu
TEEGT	Taşınabilir EEG Cihazı
TN	True Negatif (Doğru Negatif)
TP	Doğru Pozitif (True Pozitif)
TQWT	Tunable Q-Factor Wavelet Transform (Q Faktörlü Dalgacık)
URL	Uniform Resource Loader
vd.	Ve diğerleri
YSA	Yapay Sinir Ağları
WMS	Wechsler Bellek Ölçeği
δ	Delta Dalgası
θ	Teta Dalgası
α	Alfa Dalgası
β	Beta Dalgası
γ	Gama Dalgası
Σ	Toplama Fonksiyonu
f	Aktivasyon Fonksiyonu
ϵ	Epsilon
e	Euler Sayısı
π	Pi Sayısı
σ	Standart Sapma
μ	Verilerin Ortalaması

1. GİRİŞ

1.1. Problem Durumu

Günümüz eğitim sistemlerinde, teknolojinin hızla ilerlemesi ve dijital araçların yaygınlaşması, öğrenme süreçlerine yeni boyutlar kazandırmaktadır. Yapay zekâ (AI) ve mobil teknolojilerin eğitim alanına entegrasyonu, öğrencilerin öğrenme deneyimlerini zenginleştirirken, eğitimcilerin de öğrencilerin performansını daha objektif bir şekilde değerlendirmesine olanak tanımaktadır. Özellikle eğitsel dijital oyunlar, Z kuşağı öğrencilerinin ilgisini çekerken, bu oyunların öğrenme üzerindeki etkilerinin ölçülmesi önemli bir araştırma konusu haline gelmiştir (Şahin, 2021).

EEG (Elektroensefalografi) cihazlarının taşınabilir hale gelmesi, beyin sinyallerinin eğitim ortamında gerçek zamanlı olarak izlenmesini ve bu sinyallerin öğrenme süreçlerine olan etkisinin araştırılmasını mümkün kılmaktadır (Singh ve Sood, 2018). Beynin belirli durumlar karşısında yaydığı elektriksel sinyaller, öğrenci performansının objektif bir şekilde değerlendirilmesinde önemli bir veri kaynağı oluşturmaktadır. Bu bağlamda, EEG verileri kullanılarak öğrenci performansının tahmin edilmesi, geleneksel öznel değerlendirme yöntemlerine alternatif olarak daha güvenilir ve bilimsel bir yaklaşım sunmaktadır.

Bu araştırma, matematik öğretim programına yönelik geliştirilen eğitsel dijital bir oyun oynama sırasında katılımcılardan elde edilen EEG verileriyle, makine öğrenmesi algoritmaları kullanılarak oyun performansının tahmin edilmesini amaçlamaktadır. Bu yenilikçi yaklaşım, eğitimde nörobilimsel verilerin kullanımını artırmayı ve öğrenci performansının daha hassas bir şekilde değerlendirilmesini sağlamayı hedeflemektedir. Ancak, mevcut literatürde EEG sinyalleri ve yapay zekâ algoritmalarıyla akademik performansın tahmin edilmesine yönelik çalışmalar sınırlıdır. Bu durum, araştırmanın önemini ve alanyazına katkısını daha da artırmaktadır.

1.2. Araştırmanın Amacı

Beynin nasıl çalıştığı, sinir sistemi ile olan bağlantısını nasıl sağladığı, organlara komutları nasıl verdiği ve farklı durumlar karşısında verdiği tepkiler gibi henüz tam olarak çözümlenemeyen konular nörobilim alanına duyulan ilgiyi artırmaktadır. Bu durum beyin-bilgisayar arayüzü (BBA) teriminin sıklıkla karşımıza çıkmasına yol açmıştır. Beyin-bilgisayar arayüzü (BBA), beyinden alınan sinyallerin bir bilgisayar aracılığıyla komut olarak işlenmesini sağlayan bir iletişim kanalıdır (Almalı, 2023). Bu alandaki ilk araştırmalarda sadece, kaslarının hiçbir şekilde hareketini sağlayamayan hastalar için dış dünya ile iletişim fırsatı sağlayan beyin-bilgisayar arayüzleri, makine öğretimindeki son gelişmelerle birlikte tıp dışında özellikle eğitim alanında da kullanılabilir hale gelmiştir (Torres vd., 2020).

BBA görüntüleme sistemlerinde en yaygın kullanılan veri toplama aygıtları EEG cihazlarıdır. EEG cihazlarının ilk üretimlerinin boyut olarak büyük olması ve taşınmasında yaşanan güçlükler bu cihazların sınıf içi araştırmalardaki kullanımında sınırlılıklara sebep olmuştur (Millan vd., 2010; Sawangjai vd., 2020; Garcia-Monge vd., 2023) Günümüzde ise bu cihazlar taşınabilir hale gelmiştir. Emotiv, NeuroSky, Nihon Kohden, OpenBCI, MindWave ve MUSE gibi birçok farklı firma istenilen yere kolayca taşınabilen Taşınabilir EEG Teknolojisi (TEEGT) ile EEG cihazları geliştirmiştir (Sawangjai vd., 2020). TEEGT'nin farklı araştırmalarda kullanımının yaygınlaşması ile birlikte eğitim alanına nasıl transfer ve entegre edileceği konusu, araştırmacıların ve akademisyenlerin ilgisini çekmiş ve veri toplama aracı olarak TEEGT kullanılan araştırmaların sayısında sürekli artan bir değişim gözlemlenmiştir (Benitez vd., 2016; Torres vd., 2020; Raju vd., 2016) TEEGT'nin eğitim araştırmalarında kullanımının uygun bir araç olduğu araştırmacılar tarafından belirtilmiştir (Xu ve Zhong, 2018; Sawangjai vd., 2020). Ancak eğitim araştırmalarında TEEGT ile ilgili çalışmalardan elde edilen ampirik sonuçları daha iyi değerlendirmek için tecrübeli eğitimcilere ihtiyaç duyulmaktadır (Xu ve Zhong, 2018).

Eğitsel dijital oyunların öğrenme, yaratıcılık, dikkat ve motivasyon üzerindeki olumlu etkileri birçok çalışmada saptanmıştır. Araştırmacıların üzerinde durdukları diğer bir soru dijital oyun oynanması sırasında beyinde ne gibi değişimlerin gözlemlendiğidir (Sitzmann, 2011; Wouters ve Van Oostendorp 2013; Nolan ve McBride, 2014; Koça, 2015; Boyle vd., 2016; Yıldırım, 2016; Sánchez-Mena ve Martí-Parre, 2017; Hussein vd., 2019; Sarıçam, 2019; Varinlioğlu vd., 2019; Yaşar ve Alkan, 2019; Coleman ve Money, 2020; Özkan, 2021; Savaş vd., 2021; Gordillo vd., 2022; Yılmaz, 2022; Liu vd., 2022; López-Fernández vd., 2023). Bu doğrultuda çalışmada, öğrencilerin oyun oynama sürecindeki beyin sinyalleri analiz edilerek, hangi sinyallerin oyun performansını en iyi şekilde öngördüğünü belirlemek ve bu sinyalleri kullanarak oyun performansını tahmin etmek için en etkili makine öğrenmesi algoritmalarını tespit etmek hedeflenmiştir. Bu amaç doğrultusunda araştırmanın alt problemleri şunlardır:

- ✓ Eğitsel dijital matematik oyun performansının belirlenmesinde en yüksek etkiye sahip beyin sinyalleri hangileridir?
- ✓ Eğitsel dijital matematik oyun performansının tahminlenmesinde öğrenenlerin beyin sinyalleri etkili bir şekilde kullanılabilir mi?
- ✓ Eğitsel dijital matematik oyun performansının tahmin edilmesinde en yüksek başarıyı gösteren makine öğrenmesi algoritmaları nelerdir?

1.3. Araştırmanın Önemi

Bu araştırma, eğitim alanında EEG verilerinin kullanımı ile dijital oyun tabanlı öğrenme süreçlerinin objektif olarak değerlendirilmesi konusunda literatüre önemli bir katkı sunmaktadır. Geleneksel performans değerlendirme yöntemleri, çoğunlukla subjektif kararlara bağlı kalmakta ve bu durum, değerlendirme süreçlerinin objektif bir şekilde ilerlemesini zorlaştırmaktadır (Nolen-Hoeksema ve Morrow, 1991; Sitzmann, 2011). EEG verilerinin bir değerlendirme yöntemi olarak kullanılması, beyin aktivitesini doğrudan ölçmesi sebebiyle, öğrencilerin bilişsel ve duyuşsal durumlarını objektif bir şekilde değerlendirmesini sağlamaktadır (Zheng vd., 2015).

TEEGT'nin sınıf içi eğitim arařtırmalarında kullanımı literatürde giderek yoğunlařmakta ve bu teknolojinin sınıf içi arařtırmalarda saėladığı avantajlar farklı arařtırmacılar tarafından vurgulanmaktadır (Xu & Zhong, 2018; Garcia-Monge vd., 2023). Bununla birlikte, EEG verilerinin oyun performansını tahmin etmede kullanılmasıyla ilgili çalışmalar halen sınırlı düzeydedir (Torres vd., 2020). Literatürde eğitsel dijital oyunların da öğrenme süreçleri üzerindeki pozitif etkileri kanıtlanmıştır (Sitzmann, 2011; Wouters ve Van Oostendorp, 2013). Ancak, oyun oynama esnasında oyuncuların biliřsel süreçlerinde meydana gelen deėişimlerin daha iyi anlaşılabilmesi için nörobilimsel verilerin kullanılması daha faydalı olacaktır (Koç, 2015; Sawangjai vd., 2020). Bu arařtırmada oyun sırasında elde edilen EEG sinyallerinin, katılımcıların biliřsel durumları hakkında anlık ve doėru bilgiler saėlaması, bu tür biyometrik verilerin eğitimde kullanılabilirliğine dair yenilikçi bir bakış açısı ortaya koymaktadır. Eğitsel dijital oyun performansının nörobilimsel verilerle ilişkilendirilmesi, öğrencilerin öğrenme süreçlerine dair daha hassas ve özelleřtirilmiş deėerlendirmelere olanak tanımakta; böylece geleneksel anket ve öz-deėerlendirme yöntemlerinin ötesine geçmektedir.

Çalışma ayrıca, eğitim teknolojisi alanında geliştirilen oyunların, öğrencilerin biliřsel süreçleri üzerindeki etkisini derinlemesine incelemeye yönelik yöntemler sunarak öğretim tasarımı alanına katkı saėlamaktadır. Makine öğrenmesi algoritmaları, büyük veri kümeleri üzerinde çalışarak, dijital oyunların oynanması sırasında toplanan EEG verilerinden anlamlı sonuçlar çıkarabilme yeteneğine sahiptir (Benitez vd., 2016; Singh ve Sood, 2018). Bu arařtırma, makine öğrenmesi algoritmalarının eğitsel oyunlar bağlamında nasıl uygulanabileceğine dair önemli veriler sunmaktadır. Çalışmada kullanılan özellik çıkarma ve makine öğrenmesi algoritmaları, farklı yař grupları ve öğrenme düzeylerine uyarlanabilir yöntemler sunduėundan, gelecek arařtırmalar için önemli bir referans noktası oluřturmaktadır. Bu yönleriyle arařtırma, EEG ve diėer biyometrik ölçüm tekniklerinin, eğitim ortamlarında kullanılmasının potansiyel yararlarına dair geniş bir çerçeve çizmekte ve literatürde bu alanda yapılan sınırlı çalışmalara yenilikçi bir yaklařım eklemektedir.

1.4. Özgün Değer

Bu çalışmanın özgün değeri, EEG verileri gibi objektif biyometrik ölçümlerin kullanılarak eğitimde dijital oyun performansının tahmin edilmesinde yeni bir yaklaşım sunmasında yatmaktadır. Bu çalışmanın geleneksel değerlendirme yöntemlerinin kullanıldığı çalışmalardan farklı olan özelliği öğrenme süreçlerinin, öğrencilerin bilişsel tepkileri üzerinden doğrudan analiz edilmesine olanak tanımasıdır. Özellikle, öğrencilerin oyun oynarken gösterdiği bilişsel durumların ve dikkat yoğunluğunun nörobilimsel veriler aracılığıyla izlenmesi, eğitimde kişiselleştirilmiş geri bildirim sağlama ve öğrenme süreçlerini bireysel gereksinimlere göre uyarlama imkanı sunmaktadır. Bu bağlamda, çalışma, eğitimde EEG verilerinin kullanılabilirliğine dair önemli bir kanıt sunarak dijital oyun tabanlı öğrenme araştırmalarına özgün bir katkı sağlamaktadır. Ayrıca, kullanılan makine öğrenmesi algoritmalarının performanslarının karşılaştırılması, EEG destekli öğrenme analizlerinde hangi modellerin daha etkili olduğunu belirleyerek, ileride yapılacak çalışmalara ışık tutacaktır.

1.5. Sınırlılıklar

EEG cihazlarının kurulumu için elektrotların kafa üzerine doğru yerleştirilmesi ve sinyallerin kesintisiz elde edilmesi gerekmektedir. Mampusti (2011) saç uzunluğunun, kalınlığının ve yoğunluğunun EEG sinyallerini ve EEG kurulum süresini etkileyebileceğini ifade etmiştir. Bu çalışmada da kadın katılımcılardan saç uzunluğu ve yoğunluğu nedeniyle beyin sinyalleri elde edilememiştir. Katılımcıların yalnızca erkeklerden oluşması bu çalışmanın sınırlılıklarındadır.

Çalışmada katılımcıların matematik bilgilerinin birbirine benzer düzeyde olmasının sağlanması amacıyla katılımcıların 18 yaş üzerinde olması ve aynı öğrenim programında eğitim görmesi sağlanmıştır. Farklı yaş gruplarındaki bireylerden veri toplanamaması çalışmanın sınırlılıkları arasında yer almaktadır. Çalışmada taşınabilir EEG cihazı olarak Emotiv firmasının ürettiği 14 kanallı Emotiv Epoch tercih edilmiştir. Taşınabilir EEG cihazlarının kanal sayısı

taşınabilir olmayan cihazlara göre daha azdır. Farklı ve daha fazla kanaldan beyin sinyali toplanamaması araştırmanın sınırlılıklarından biridir.

EEG tabanlı duygu tanıma görevleri için, çok kanallı EEG verilerinde gürültüye neden olabilecek ve duygu tanıma sistemlerinin performansını düşürebilecek pek çok kanal sinyali bulunmaktadır (Zheng vd., 2015). Elektronik amplifikatör, güç hattı paraziti veya harici parazit yoluyla da gürültü gelebilmektedir (Lievesley vd., 2011). Gürültüye karşı yüksek hassasiyete sahip bu cihazlar, veri toplama sürecinde oluşabilecek gürültülü veri nedeniyle sinyal kalitesini bozabilmektedir. Gürültülü veri elde etme olasılığının yüksek olması bu çalışmanın sınırlılıklarından biridir. Çalışmada bu sınırlılık, gürültülü veriler içeren sinyallerin temizlenerek düzenlenmesi ile ortadan kaldırılmaya çalışılmıştır.

Elektrotların kafa derisine yerleştirilmesi dikkat dağıtıcı, zaman alıcı ve rahatsız edici olabilir. Bu süreç uzadıkça, sürekli olarak iyi bir sinyal kalitesi sağlanamayabilir (Debener ve Bleichner, 2019). Rahatsızlık hissi, katılımcının duygularını etkileyebilir ve bu durum sistematik hata oluşturabilir. Frontal korteks üzerindeki asimetric aktivitenin, duygular ve motivasyonla ilişkili olması bu etkinin bir kanıtı olarak ifade edilebilir (Harmon-Jones, 2003). Çalışmada EEG cihazının yerleştirilmesi süresi araştırmanın sınırlılıklarından biridir. Bu sınırlılığın araştırma verilerini etkileme durumlarının ortaya konulması ve gürültülü verilerin kapsam dışı bırakılması amacıyla çalışmada katılımcılara bu durum ile ilgili rahatsız olma durumları sorulmuştur. Katılımcıların büyük çoğunluğu Emotiv Epoch taşınabilir EEG cihazının kullanımının rahat olduğunu ve duygularını etkilemediğini belirtmişlerdir.

1.6. Varsayımlar

EEG cihazının, katılımcıların beyin aktivitelerini doğru bir şekilde kaydettiği ve bu sinyallerin, katılımcıların bilişsel ve duygusal durumlarını yansıtacak kadar güvenilir olduğu varsayılmaktadır.

Katılımcıların, eğitsel dijital oyunu oynarken yeterli motivasyon ve odaklanma gösterdikleri varsayılmaktadır. Katılımcıların, oyunu ciddiye aldıkları ve oyun sırasında beyin aktivitelerini etkileyebilecek dış faktörlerden (rahatsızlık, dikkat dağınıklığı vb.) etkilenmedikleri kabul edilmektedir.

Çalışmada elde edilen bulguların, benzer demografik özelliklere sahip öğrenci gruplarına genellenebilir olduğu varsayılmaktadır.



2. KAVRAMSAL ÇERÇEVE VE İLGİLİ ÇALIŞMALAR

2.1. Oyun

Türk Dil Kurumu (TDK)'na göre oyun; kabiliyet ve zekâ geliştirici, amaçlı kuralları olan, hoş vakit geçirmeye yarayan, eğlenceye dayanan her türlü yarışma olarak tanımlanmaktadır (TDK, 2023). Oyun; insan ve kültürden önce ortaya çıkmış, kurallara göre kurgulanmış, öngörülemeyen, herhangi bir yükümlülük içermeyen, süre ve yer sınırlamaları olan, etkileşimli, oynayanları cezbeden, bazen ölçülebilir bir sonucu olan, toplumun ruhsal ve maddesel özellikleri arasındaki dengeyi sağlayan gönüllü bir faaliyettir (Salen, 2003; Huizinga, 2015). İnsanlar eğlenmek, hoşça vakit geçirmek ve mutlu olmak için oyun oynayabilirler. Eğlence, insan uygarlığından itibaren başlayan bir olgudur ve bu olgu canlandırılmak istendiğinde akla ilk gelen hep oyun olmuştur (Yengin, 2012). Akın (2008), oyuna bilişsel açıdan bakmaktadır ve oyunu; duyu organlarında, sinir ve kaslarda, zihinsel seviyede oluşan, bazen de fiziksel deneyimlerle tekrarlanan, insanları mutlu eden bir aktivite olarak tanımlamaktadır.

İnsan sosyal bir canlı olup çocukların, gençlerin ve yaşlıların oyun oynama nedeni sosyal etkileşim ihtiyacından kaynaklanmaktadır (Sherry vd., 2003). Tuğrul'a (2014) göre oyun insanların çevreden ve birbirlerinden yararlanma fırsatıdır. İnsanlar; oyun içerisinde konuşarak, hareket ederek, yazarak, gözlem yaparak, duygusal tavırlar sergileyerek oyuna katılmakta ve oyun oynayan bireyler çevreden etkilenecek birbirlerine benzer davranışlar sergilemektedir. Bu bağlamda oyun; bireylerin sosyal çevreden gözlem yaparak bilgi, beceri, duygu, iletişim gibi zihinsel ve fiziksel birçok şeyi öğrenmelerine imkan sağlayabilen bir eğlence aracıdır.

2.1.1. Oyun öğrenme ilişkisi

Oyun; sadece bir kişi tarafından oynanabiliyorsa tek oyunculu, birden fazla kişi ile oynanabiliyorsa çok oyunculu oyun olarak adlandırılmaktadır. Birden fazla oyuncunun oynadığı oyunlarda bir topluluk bulunmaktadır ve kişi bu oyunla

birlikte o topluluğa da girmiş olmaktadır. Zamanla kişi o topluluğun üyesi haline gelmekte ve topluluğun adıyla anılmaya başlamaktadır (Naidoo, 2020). Aidiyet duygusunu ortaya çıkaran bu faktör, oyuna devamlılığı ve bağlılığı sağlamaktadır (Bergstrom, 2022). Bir gruba dahil olma, çevresellik, birlik ve beraberlik güdüsü öğrenme sürecini ve içeriklerini pekiştirmektedir (Forslund, 2018). Bu doğrultuda, oyunun getirdiği çevreselliğin öğrenmeyi olumlu etkileyebileceği düşünülebilir.

Öğrenme salt beyin etkinliği sonucu meydana gelmeyip, sosyal ve kültürel bağlantılar bütünüyle oluşmaktadır. İnsanların yaşamış olduğu tecrübeler ile öğrenme şekilleri arasında bir ilişki bulunmaktadır (Kolb, 1984). İnsanlar, yeni bilgilerini önceki tecrübeleriyle bağlantı kurarak oluşturmaktadır. Bu tür bir ilişki, bireylerin yeni bilgiyi anlamlandırmasını sağlamaktadır (Gee, 2003). Bu sebeple oyun, “oyun temelli öğrenme” terimi şeklinde öğretim yöntemlerinden biri olarak kullanılmaktadır. Oyun temelli öğrenmede, öğrenenler öğrendiklerini oyun sırasında daha rahat ifade edebilmekte, ne düşündüklerini başkalarıyla paylaşabilmekte ve öğrenirken daha cesaretli ve güvenli olabilmektedirler. Dolayısıyla oyun temelli öğrenme deneyimleri keyifli ve ilgi çekicidir (Zhang ve Shang, 2016). Bu özellikleri ile oyun hem araştırmacıların hem de öğretmenlerin ilgisini çekmiştir. Eğitsel oyunlarla ilgili yapılmış olan çalışmalar; eğitsel oyunların yaratıcılık, işbirlikçi öğrenme, problem çözme becerilerini geliştirme gibi faydalarına ilişkin çeşitli ampirik ve nitel kanıtlar sağlayabilmektedir (Barab vd., 2011). Öğrenenlerin birbiri ile bağlantılı bilgileri kullanarak kendi bilgisini oluşturma süreci için eğitsel oyunlarda özellikle örtülü bilgi çokça bulunmakta ve vurgulanmaktadır (Zhang ve Shang, 2016). Eğitsel oyunlar, öğrenme amaçlı ve eğitsel gereksinimler baz alınarak, kazanımları karşılayacak ve öğrenenlere çeşitli öğrenme deneyimleri sağlayacak şekilde tasarlanabilir.

Zhang ve Shang (2011), öğrencilerin yeni bir bilgi veya beceriyi kazanma yeteneğinin ve isteğinin gelecekteki başarılarının göstergesi olabileceğini ifade etmiştir. Öğrencilerin öğretmenlerden geri bildirim ve takdir alma şekliyle karşılaştırıldığında, akranlar arasındaki paylaşım ve iletişim, öğrencilere yapmak istediklerini yapma ve söylemek istediklerini söyleme konusunda daha fazla

özgürlük tanımaktadır. Öğrenciler, çalışmalarını ve başarılarını başkalarına sunma sürecinden keyif almaktadır. Oyunlarda anında verilen geri bildirimlerin heyecana sebep olması öğrencilerin katılımını ve aktifliğini arttırmaktadır (Zhang ve Shang, 2011).

Konsantrasyon ve içsel motivasyonunu sağlamış, hedefe kilitlenmiş insanların yaptıkları bir işe odaklandıklarında, diğer hiçbir şeyin önemi yokmuş gibi hissetmeleri “akış teorisi” olarak tanımlanmaktadır (Abuhamdeh ve Csikszentmihalyi, 2012). Öğrenenlerin oyun oynama sırasında yaşadıkları heyecan nedeniyle öğrenenler, kendilerini oyuna derinden kaptırmaktadırlar. Bu esnada gelişen kendini kaptırma durumundan öğrenme amaçlı olarak yararlanılması oyunun güçlü yanlarından birini oluşturmaktadır (Zhang ve Shang, 2011).

Öğrenmeye aktif katılım süresinin artması ve oyuna kendini kaptırma hali, öğrenmenin verimliliğini artırabilir. Bu tür bir katılım, öğrencilerin oyuna daha fazla odaklanmalarını sağlayarak öğrenmeyi destekler. Araştırmalar, oyunların öğrenme, yaratıcılık, motivasyon, ilgi ve dikkat üzerindeki olumlu etkilerini açıkça ortaya koymuştur (Sitzmann 2011; Wouters ve Van Oostendorp, 2013; Nolan ve McBride, 2014; Koça, 2015; Boyle vd., 2016; Yıldırım, 2016; Sánchez-Mena ve Martí-Parre, 2017; Hussein vd., 2019; Sarıçam, 2019; Varınlıoğlu vd., 2019; Yaşar ve Alkan, 2019; Coleman ve Money, 2020; Özkan, 2021; Savaş vd., 2021; Gordillo vd., 2022; Yılmaz vd., 2022; Liu vd., 2022; López-Fernández vd., 2023). Bu çalışmalar, oyunların öğrenme süreçlerine olumlu katkı sağladığını ve bu katkının birçok farklı boyutta gözlemlenebildiğini göstermektedir.

2.1.2. Dijital oyun

Yabancı literatürde “video oyunları” şeklinde kullanılan bu terim, yerli kaynaklarda “dijital oyun” olarak isimlendirilmiştir (Halaçoğlu, 2020). Dijital oyun, bir senaryoya dayanan görsel-işitsel bazen dokunsal bir ekipman sayesinde oynanılan bir oyun türüdür (Esposito, 2005). Bu oyunlar, sadece birer oyun olmanın ötesinde, aynı zamanda kültür, sanat, anlatı formu ve eğitim aracı olarak

da değerdendirilebilmektedir (Frasca, 2004). Sarpkaya (2021) ise dijital oyunları; aynı anda video, dijital ve oyun kavramlarını içeren, kendine özgü uygulama ve içerikleri olan, dijital ve video temelli olmasıyla teknolojik, oyun olması sebebiyle kültürel bir yönü olan, teknolojik araçlarla herkes tarafından oynanabilen oyun türü olarak ifade etmiştir.

Dijital oyunlar, oyunun internet bağlantısı olan ya da olmayan bilgisayar, tablet, akıllı telefon, konsol gibi araçlar sayesinde dijital ortama entegre edilmesiyle ortaya çıkmıştır. Dijital oyunların içerik olarak aksiyon-macera, platform, dövüş, hızlı bulmaca, strateji, müzik, nişancı, simülasyon, rol yapma, spor, çevrimiçi çok oyunculu (MMO) gibi türleri bulunmaktadır (Adams, 2010; Rogers, 2010). Yengin (2012) 'e göre dijital oyun çeşitleri; atari oyunları, bilgisayar oyunları, konsol oyunları, mobil oyunlar ve diğer çeşitleri de içine almaktadır. Oyun için bir alan gerekli olup bu ortamlar; video tabanlı, PC tabanlı ve taşınabilir oyunlar şeklinde sınıflandırılmaktadır (Varinlioğlu vd., 2019). Gürcan (2008)' e göre ise dijital oyunlar; konsol oyunları, online oyunlar ve bilgisayar oyunları olarak sınıflandırılmaktadır. "Video Oyunu", "Mobil Oyun" ve "Bilgisayar Oyunu" terimleri birbirlerinin yerine transfer edilebilir kavramlar olup oyunun görüntülendiği (televizyon, monitör, LCD gibi bir ekran) aygıta göre farklı isimlendirildiği görülmektedir. Ayrıca oyunların oynanabilmesi için kullanılan ağıtların (denetleyici, joystick, klavye veya tuş takımı) oyuna ve donanım durumuna göre değiştiği görülmektedir (Kirriemuir, 2002).

Genel olarak dijital oyunlar; eğlendirici, eğitici, hoş vakit geçirme ve rahatlamayı sağlayan yeni nesil oyunlardır. Annetta (2008), yetişkinlerin dijital oyunları keyifli boş vakit geçirmek ve alıştırma yapmak için oynadığını, çocukların ise yetişkinlerden daha farklı nedenlerle dijital oyunları oynadığını ifade etmiştir. Griffiths (2002), dijital oyunların demografik özelliklere (yaş, cinsiyet, etnik köken, eğitim durumu vb.) bakılmaksızın hemen herkesin ilgisini çektiğini belirtmiştir. Prensky (2001), dijital oyun oynayanların seçimlerinde cinsiyet, yaş, rekabet ve oyuna yönelik önceki bilgilerin etken olduğunu ifade etmiştir. Koç (2022) ise dijital oyun oynayanların demografik, sosyal, kültürel durumları ve yaş sınırlaması oyun tercihini etkilediğini belirtmiştir. Bireyin sosyal etkileşimde

bulunduđu gruba g re tercih ettiđi dijital oyun  eşidi deđiřebilir. Dijital oyunlar, oyunu oynayan toplulukla iletiřim kurmayı sađlamaktadır (Subrahmanyam ve Greenfield, 1994). Grup olarak oynanan ve birden fazla oyuncu i eren oyunlar, genelde grubun birbirleriyle etkileřimi sonucunda belirledikleri bir oyuna y nelebilmektedir. Ayrıca kadınlar ve erkeklerin; sosyal ve duygusal a ıdan farklı olması, eđlenceli buldukları alanların deđiřkenlik g stermesi nedeniyle farklı oyunları tercih ettikleri d ř n lebilir.

Oyuncuların kendilerine  zg  karakterleri, ilgi alanları, oyuna ayırabildikleri s re, oyunu ne ama  i in oynadıkları da tercih ettiđi oyun t r n  deđiřtirebilir. Bertens vd. (2017), oyun geliřtiricilerin g n m zde oyuncu davranıřını dođru bir řekilde tahmin edebilen ve devasa veri k melerine  l eklenebilen g venilir modellerden faydalanabildikleri i in oyuncular hakkında  ok sayıda bilgiye sahip olarak oyun tasarlayabildiklerini belirtmiřtir. Dijital oyunlar bilgiyi; g r nt , video, grafik ve ses gibi farklı medya bi imleriyle sunduđu i in bilgi, canlı hale gelmekte ve bu sayede oyuncuların dijital oyun s recindeki deneyimleri somutlařmaktadır (Karahisar, 2013). Sanal d nyayla etkileřim, oyuncuların sanal d nyaya n fuz edebileceđini ve ondan geri bildirim alabileceđini g stermektedir ve bu  zellikleri, dijital oyunları internet  ađında etkin hale getirmektedir (Zhang ve Shang, 2016).

Dijital oyunlar; beř duyu organımızı etkilemekle birlikte en  ok g rme, dokunma, iřitme duyularımızda etkileřim ve deđiřimlere sebep olabilmektedir. Bunun dıřında dijital oyunlar, bařarı iřteđi (rekabet), sosyal etkileřim (iletiřim kurma, ekibe ait olma hissi, diđer oyunculara yardım etme iřteđi) gibi his ve isteklere neden olmakta ve oyuncuların oyun karakter performansını optimize etmek i in temel kuralları ve sistemi analiz edebilme imk nı oyunlara olan ilgiyi artırmaktadır (Yee, 2006). Ayrıca oyuncuların oyunlara olan ilgi d zeylerini artıran farklı etkenler de bulunmaktadır. Bunlar oyuncuların oyuna dalarak g nl k hayatın problemlerinden ka ması, kolay eriřimle her yerden oyun oynayabilmesi, oyunun ucuz veya  cretsiz olması gibi etkenler olabilmekte ve bu řekilde oyuncuların motivasyonu ve oyun iřteđinin devamı sađlanabilmektedir (Kuss ve Griffiths, 2012). Sonu  olarak iyi tasarlanmış dijital oyunlar, oyuna

devam etmek için içsel bir motivasyon oluşturarak akış, katılım ve neşe duyguları yaratmakta ve bu oyunu oynama isteğinde süreklilik oluşturabilmektedir (Maksatbekova, 2019).

Zhang ve Shang (2016) dijital oyunlarda oyuncuların, gerçek ve sanal dünyadaki avatarları seçmelerinin bazı oyuncuların gerçek dünyadaki kimlikleri ile oyunda oynadıkları sanal karakterler arasında köprü kurulmasına yardımcı olduğunu ve bu durum neticesinde dijital oyunların oyuncuların gerçek dünyayı nasıl okuduklarını, gördüklerini ve düşündüklerini etkileyerek çeşitli deneyimler kazandırdığını ifade etmiştir.

Günümüzde ludoloji (oyunbilim) araştırmalar artmakta ve geleneksel oyunlar yerini dijital oyunlara bırakmaktadır (Yengin, 2012). Dijital oyunlarla büyüyen çocuklar, kendi etki alanlarında lider oldukları için kültürel kabul durumlarını büyük ölçüde artırmaktadır (Beggs vd., 2009). Dijital oyunlar, oyun topluluğuna katılım için bir motivasyon faktörü haline gelecek olan öz kimliğin gerçekleştirilmesine de yardımcı olmaktadır (Zhang ve Shang, 2016). Son yıllarda ise çocuklar ve gençler okulda veya okul dışındaki kodlama kurslarında dijital veya mobil oyun geliştirmeyi öğrenmekte ve kendi oyunlarını geliştirip oyun platformlarında varlık göstermektedir. Artık çocukların sadece dijital oyun oynayan bireyler olmaktan çıkarak kendi oyunlarını geliştiren bireyler olmaları, oyun tasarımcısı olma yolunda erken yaşlarda deneyim kazanmalarını sağlamaktadır. Bu durum, onların yaratıcılıklarını geliştirirken aynı zamanda teknolojiye olan ilgilerini artırmakta ve gelecekteki kariyer seçeneklerini genişletmektedir. Oyun geliştirme süreci, çocukların problem çözme, eleştirel düşünme ve proje yönetimi gibi becerilerini de pekiştirerek onları dijital dünyanın aktif birer üreticisi haline getirmektedir.

2.1.3. Dijital oyun tarihçesi

1947 yılında “Cathode Ray Tube Amusement Device (Katod Işın Tüplü Eğlence Cihazı)”, II. Dünya Savaşı’nın radar göstergelerinden esinlenerek icat edilen ve ilk elektronik oyundur (Üstün vd., 2022). İlk PC oyunları, 1950 yılı ve sonrasında

piyasaya sürülmeye başlanmıştır. 1958 yılında piyasaya çıkan “Tennis for Two” (İki Kişilik Tenis) adlı analog bilgisayar oyunu, dünya çapındaki ilk interaktif bilgisayar oyunu olarak değerlendirilmektedir (Karahisar, 2013). Dillon (2011), 1952 yılında “Noughts and Crosses” adlı oyunun bilgisayarda programlanan ilk gerçek oyun olduğunu ifade etmiştir. 1962 yılında ortaya çıkan “Spacewar” ise ticari ve toplumsal etki yaratan ilk bilgisayar oyunu olarak öne çıkmaktadır (Dijital Oyun Sektörü Raporu, 2016). Bu oyun, aynı anda birden fazla bilgisayara yüklenen ilk etkileşimli oyundur (TÜBİTAK, 2022).

1965’te Dartmouth öğrencileri, ilk dijital futbol oyununu çıkardıktan sonra dijital oyunlar, araştırmacıların ilgisini çekmeyi başarmıştır. 1968 yılında piyasaya çıkarılan “Brown Box” adlı ilk oyun konsolu ile birlikte ise bilgisayar oyun fiyatları ucuzlayarak daha ulaşılabilir bir seviyeye düşmüştür (Kızılkaya, 2010). 1971 yılında ilk ticari dijital oyun “Computer Space” piyasaya sürülmüştür (Esposito, 2005). 1972 yılında ABD’li ilk oyun şirketi Atari, çok geniş bir kullanıcı kitlesine hitap eden “Pong” adlı oyunu piyasaya sürmüştür (Karahisar, 2013). “Pong” iki boyutlu bir masa tenisi oyunu olup kısa sürede popülerlik kazanmıştır. Video oyun konsolları çıkana kadar en baskın platformlar atari salonları iken Ralph Baer ve arkadaşları tarafından 1972 yılında ilk video oyun konsolu olan “Magnavox Odyssey” icat edilmesi ile birlikte oyun oynanan ortam popülerliğinde değişiklikler meydana gelmiştir (TÜBİTAK, 2022). 1978 yılında Japon oyun firması Taito’nun piyasaya sürdüğü “Space Invaders” isimli oyunun getirdiği başarı oyun endüstrisine yeni bir soluk getirmiştir (Fritsch, 2013).

1980 yılında Namco tarafından geliştirilen “Pac-Man” dijital oyunu ile birlikte oyunların renkli hale gelmesi ve duyguları etkileyen bir diğer unsur olan müziğin oyunlarda kullanılması oyunlara olan ilgiyi arttırmıştır. Bu oyun, renk ve müziğiyle kadınların da dijital oyunlara ilgisini artırarak dijital oyun pazarının genişlemesini sağlamıştır (Kızılkaya, 2010). 1982 yılında ilk kez kişisel ve gelmiş geçmiş en çok satan bilgisayar olan Commodore 64 çıkmıştır (Yengin, 2012). 1989’da Nintendo, “Gameboy” isimli oyunu piyasaya sürmüş ve “Mario Bros” oyunu donanımın içine yüklenmiştir (Merdin, 2020). 1990’lı yıllarda çok daha hızlı ve çeşitli oyunlar piyasada yerini almıştır. “Wolfenstein”, 1992 yılında

piyasaya ıkan ilk  boyutlu oyun olmuştur. Bu yıllarda ıkan “Doom” oyunu ise bilgisayar satışlarını fevkalade artırmıştır (Karahisar, 2013). 1994 yılında Sony, “Playstation” isimli konsol oyununu Japonya’ da ilk kez piyasaya sürmüştür (O’Hagan ve Mangiron, 2013). Daha sonra Sony, 2016’da 4K video uyumu olan ilk konsol oyunu PlayStation 4 Pro’yu satışa sunarak ürüne ilgiyi artırmıştır. 2017 yılında Nintendo firması “Switch” isimli oyun konsolunu satışa sunulmuştur. 2017’de Microsoft ilk kez 2001 yılında ıkan Xbox ‘ın 4K destekli yeni konsolu “Xbox One X” isimli konsolu sektöre kazandırmıştır (TÜBİTAK, 2022). Bu doğrultuda dijital oyun sektörü gelişimi araştırmacılar tarafından dönemlere ayrılmış ve aşağıda listelenmiştir (Esposito, 2005):

- ✓ 1971-1978: İlk yıllar/öncüler,
- ✓ 1978-1983: Altın çağ/tür gelişimi,
- ✓ 1983-1994: Teknolojinin hızlı gelişimi/güçlü fikirler,
- ✓ 1994-Günümüz: CD-ROM, 3D, PlayStation, PC, büyük prodüksiyonlar, çevrimiçi oyunlar.

Cep telefonu teknolojisi ile gelişen mobil oyunların yolculuğu, Nokia cep telefonlarında yer alan “Snake (Yılan)” oyunu ile başlamış ve günümüzde çok heyecan verici bir hale gelmiştir. 2008 yılında Android Market’in kullanıma sunulmasıyla cep telefonlarına bir platform vasıtasıyla ilk yüklenebilen mobil oyun “Sneezies” geliştirilmiştir. 2009 yılında sosyal ağlarda “The Sims”, “Zynga”, “Farmville” gibi oyunlar büyük ilgi görmüştür. “Battle Royale” gibi oyunlar bu yıllarda popüler olmuştur. 2016 yılında AR teknolojisinin (Augmented Reality-Artırılmış Gerçeklik) teknolojisinin akıllı telefonlarda kullanılmasıyla, ilk başarılı AR destekli mobil oyun olan “Pokemon Go” piyasaya çıkarılmıştır. 2016 yılında üretilen “PUBG”, 2017 yılında Google Play Store ve App Store gibi mobil platformlardan indirilerek oynanılabilir duruma gelmiştir. 2022 yılında, Apple Store’da, “Subway Surfer”, 57 milyon kez indirilmiş ve bu sayıyla en çok indirilen oyun olmuştur. Gelir büyüklüğü açısından ise, Apple Store’da Çinli “Tencent” adlı oyun şirketi ilk iki sırayı birden almış ve sadece ilk sıradaki “Arena of Valor” oyunu 1,8 milyar dolar gelire ulaşmıştır. (Mobil Oyun Sektörü Raporu, 2022).

1980'li yıllarda İngiltere'de ve Amerika'da başlayan dijital oyun sektörü, tüm dünyada olduğu gibi Türkiye'de de milyonların ilgisini çeken bir sektör haline gelmiştir. Bilgisayarların yaygınlaşması, veri depolama teknolojilerindeki gelişmeler, internet bağlantı hızının artması, sosyal medya kullanımının yaygınlaşması, akıllı telefon ve tabletlerin kullanımının artması gibi faktörler dijital oyun sektörünün günden güne ilerlemesini sağlamıştır (Karahisar, 2013). Dijital oyunlara erişimin günümüzde kolaylaşması sonucunda bu oyunlar günlük hayatımızın bir parçası haline gelmiştir.

2.1.4. Eğitsel dijital oyun

Son zamanlarda okullarda kullanılan akıllı tahta, tablet, simülasyon, sanal laboratuvar, MOOC (Katılımlı açık çevrim içi platformlar) gibi dijital teknolojiler Birleşmiş Milletler'in sürdürülebilir kalkınma 2030 gündeminde yer alan herkes için kaliteli, kapsayıcı ve eşitlikçi eğitim hedefine ulaşmada önemli araçlar olarak ortaya çıkarak eğitimde değişimlere yol açmıştır (Haleem vd., 2022). Bu dijital teknolojilerin eğitim ve öğretime uyarlanması çok hızlı gerçekleşebilmekle beraber dijital teknolojiler mevcut eğitim yaklaşımlarını da etkisi altına almıştır. Hızlı internet, yüksek bant genişlikleri ve sanal hizmetler kullanılarak mevcut eğitim yaklaşımları e-öğrenmeye doğru ilerlemektedir (Martin vd., 2011).

Etkileşimli tahtalar, mobil cihazlar, tablet ve bilgisayarlar gibi teknolojik araçların kullanılmasıyla oyun ve öğrenmeyi bir araya getiren bir kavram olan "Eğitsel Dijital Oyun" kavramı ortaya çıkmıştır. Dijital oyunlara getirilen eğitsel boyut ile birlikte eğitsel dijital oyunun bilişsel, sosyal ve duyuşsal hedeflerinin olması sağlanmıştır. Eğitsel dijital oyun, hedef davranışların örtük veya açık şekilde dijital oyunlara yerleştirilmesiyle bireyin öğrenmesine ve yeteneklerini geliştirmesine olanak sunmuştur.

Bu durum dijital oyunların eğitime entegrasyonunu hızlandırmış, eğitim teknolojilerinin eğitim alanındaki varlığını daha da güçlendirmiş ve buna bağlı olarak dijital oyunların eğitim ve öğretimde yaygınlaşmasını sağlamıştır (Trust, 2018). Teknolojik öğrenme araçlarıyla "Nesnelerin İnterneti"nin genç beyinleri

eğitmenin en uygun maliyetli yöntemlerden biri olduğu kanıtlanmıştır (Haleem vd., 2022). Eğitsel dijital oyunlar, bireylere etkin ve dinamik öğrenme ortamları sunduğundan geleneksel yöntemlere göre daha etkili olarak kabul edilmekte ve bu nedenle dijital oyun tabanlı öğrenme günümüzde popülerlik kazanmaktadır (Çağıltay, 2007; Sălceanu, 2014). Eğitsel dijital oyunların içeriğinde her oyunda olduğu gibi eğlence yer almaktadır. Bu nedenle oyuna ilgi duyan fakat derslere aynı düzeyde ilgi duymayan öğrencileri eğitsel dijital oyunlara yönlendirmek bu öğrenciler için daha cazip olan alternatif bir öğretim yöntemi olacaktır.

Bloom (1968), uygun koşullar sağlandığında herkesin öğrenebileceği bir öğrenme yönteminin olduğunu belirtmiştir. Kolb (1984), kişilerin günlük hayatta sergiledikleri davranışların öğrenme esnasında da aynı şekilde gerçekleştiğini ifade etmektedir. Bu nedenle Gözalan ve Koçak (2014), tek bir öğretim yönteminin tüm eğitim durumlarına ya da her bireyin gereksinimlerine tam anlamıyla uygun olamayacağını, farklı dinamiklerle desteklenmesi gerektiğini savunmuştur. Bu araştırmalar, öğretim yöntemlerini görsel, işitsel ve dikkat çekici etkinliklerle çeşitlendirmenin veya fiziksel aktivite ile oynanan dijital oyunların eğitimde kullanılmasının fark yaratabileceğini öne sürmektedir. Bu bağlamda, öğrenenlerin deneyim kazanmaları için çoklu ortamlar sağlamasının yanı sıra etkileşim kurma ve bilgiyi yeniden yapılandırma fırsatı sunma yeteneği ile eğitsel oyunlar, öğrenme süreçlerinin daha etkin ve kalıcı bir şekilde gerçekleştirilmesinde önemli bir araç olarak öne çıkmaktadır (Zhang ve Shang, 2016).

Eğitsel dijital oyunların disiplinlerarası bir aktivite aracı olması sayesinde fen, teknoloji, mühendislik ve matematik (sırasıyla Science, Technology, Engineering, and Mathematics kısaca STEM) alanlarında öğrenme çıktıları üzerinde olumlu etkiler görmüştür (Zahed vd., 2019). Oyunun kendi içinde birçok farklı disiplin barındırması sebebiyle, ilgili tüm ana dalların katılımı zorunlu hale gelmektedir (Dijital Oyun Çalıştay Raporu, 2022). Matematik, fen bilimleri, yabancı dil gibi ayrımlı disiplin alanlarındaki oyunlar öğrenci motivasyonunu arttırılabilmektedir ve öğrenilen bilgileri kalıcı hale getirip özellikle ilköğretim çağındaki öğrencilerin temel matematik, okuma ve dil kabiliyetlerini

ilerletmelerine katkı sağlayabilmektedir (Dijital Oyun Raporu, 2017). Ayrıca dijital oyunların farklı zekâ türlerine hitap etmesi öğrenmeyi hızlandırmaktadır (Tuğçe ve Yeşiltaş, 2018). Griffiths (2002)'e göre dijital oyunlar, çocukları öğrenme deneyimine çekmekte, uzamsal görselleştirme yeteneği geliştirmekte ve mekânsal beceriyi arttırmaktadır. Bozkurt (2014), dijital oyunların öğrenmede, dikkat ve görsellik anlamında değişimlere neden olduğunu ifade etmektedir. Bu sebeple eğitimde dijital oyunların kullanılması birçok fayda sağlamakta ve özellikle öğrencilerin derse karşı ilgilerini arttırmaktadır (Gündüzalp, 2021).

Eğitsel dijital oyunların, öğrenciye kısa sürede geribildirim verip yanlış öğrenme kaygısı yaşatmaması da önemlidir. Eğitsel dijital oyunlar, sunduğu ortamlar nedeniyle yaparak ve yaşayarak öğrenmeye katkı sağlamakta ve öğrenmede kalıcılığı yakalamakta fayda sağlamaktadır (Trust, 2018). Günümüzde öğrenenler defter, kitap, kalem gibi geleneksel yöntemlerle çalışmak yerine içsel motivasyonu artıran dijital oyunlar aracılığıyla konuyu tekrarlamayı ve pekiştirme yapmayı daha çok tercih etmektedirler. Ayrıca bazı eğitsel dijital oyunlarda çevrimiçi tartışma platformları da yer almaktadır. Bu tür platformlar sayesinde oyuncular, birbiriyle iletişime geçerek bilgi paylaşımı yapabilmekte ve dışsal motivasyon kaynaklarını kullanarak öğrenme gerçekleştirebilmektedir (Sung ve Hwang, 2013). Aynı zamanda bu eğitici platformlar; puan alma, sıralamaya girebilme, rozet kazanma, avatar oluşturma, sanal eşyalar ve koleksiyonlar edinme, seviye atlama, otomatik doğru-yanlış dönüt verebilme gibi özellikleriyle öğrenmeyi hızlı, keyifli ve heyecanlı hale getirebilmektedir.

Dış motivasyon kaynakları, hedefler ve psikolojik değişkenler, öğrenme motivasyonunu etkilemekte ve öğrenme, bu motivasyon güçlü olduğunda daha etkili gerçekleşmektedir (Prensky, 2002). İçsel motivasyonun öğrenme üzerindeki etkisi büyük olduğundan, dijital oyunlarla eğitim bu motivasyonu artırmak için önemli bir araçtır (Maksatbekova, 2019). Ayrıca başkaları tarafından görülebilmek ve başarının takdir edilmesi, birçok öğrenen için motivasyon kaynağıdır (Dicheva vd., 2015). Sınıf içinde veya başka ortamlarda kendini gösteremeyen öğrenenler için eğitsel dijital oyun platformları faydalı

ortamlar olabilmektedir. Johnson ve Mayer (2010), dijital eğitsel oyun ortamlarının öğrenenlerin, farklı disiplinler hakkındaki önyargılarını ve algılarını değiştirmek için alternatif fırsatlar sunduğunu ve öğrenenlerin benlik algısına olumlu katkılar sağladığını belirtmiştir.

Dijital oyunlar, kimlikler etrafında inşa edilmiş son derece eğlenceli ve etkileşimli bir teknoloji olup benlik algısı, hedef belirleme ve bireysel farklılıklar gibi kişiye özgü niteliklerin incelenmesinde bu oyunlardan yararlanılmaktadır (Griffiths, 2002). Ayrıca bu oyunları oynamak, kişisel farkındalığı geliştirmenin ve kimliği şekillendirmenin etkili bir yollarından biridir (Zhang ve Shang, 2016). Zhang ve Shang (2016) dijital oyunların, insanlara sanal dünyada yeni bir kimlik (projektif kimlik) geliştirme olanağı sağladığını ve bu süreçte oyuncuların geçmiş deneyimlerini yansıtarak bireysel beklenti ve duygularını sanal bir kimliğe dönüştürebildiğini belirtmiştir (Zhang ve Shang, 2016). Bu doğrultuda dijital oyunların öğrencilere hedef belirleme, hedef provası ve geri bildirim sağlama, pekiştirme ve davranış değişikliği kayıtlarını tutma konularında yardımcı olabileceği düşünülebilir.

Teknolojide yaşanan gelişmelerle birlikte dördüncü sanayi devrimi olarak bahsedilen “Endüstri 4.0” anlayışına paralel olarak tüm alanlarda dijital dönüşümler gerçekleşmiştir. Eğitim alanında da dört ana dönüşüm yaşanmıştır (Öztemel, 2018). 21. yy. becerilerine sahip, teknolojiyi kullanabilen, geleceğe hazır olan öğrenciler yetiştirmek “Eğitim 4.0” kapsamındadır. “Eğitim 4.0” uyarlanabilir çerçevesi, akıllı cihazlarla elde edilen bilgilerin faydalarını, fizyolojik verilerin biyolojik geri bildirimini (biofeedback), öğrencinin kendi kendini düzenleyen öğrenmesini, öğretim etkinliğini ve sağlığını geliştirmek için AI (Yapay Zekâ/Artificial Intelligence) algoritmalarını birleştirmektedir (Shiohira, 2021). Eğitim 4.0 sürecinde yapay zekanın avantajlarından yararlanmak, öğrencinin refah ve sağlığını iyileştirme, öğrencinin başarısı için stratejik öneme sahip öğeleri tanıma ve risk altındaki öğrencileri için erken uyarıda bulunmayı mümkün kılmaktadır. Ancak geleneksel eğitim bu gereklilikleri karşılamakta yetersiz kalmakta ve akademi ile endüstri gereklilikleri arasında büyüyen bir tutarsızlık oluşmaktadır (Ciolacu vd., 2020).

2.1.5. Matematik eğitiminde dijital oyun

Matematik; analitik düşünme becerisi gerektiren, semboller içeren, ardışık soyutlama ve genellemelerden oluşan, birbiriyle ilişki bir sistemdir (Australian Council for Educational Research, 1972; Baykul, 2009). Matematik doğruyu bilme ve anlama merakından ortaya çıkan düşünsel bir faaliyettir (Altun, 2006). Matematiksel düşünme için matematik öğrenmek zorunludur (Stacey ve Pierce, 2006). Beyin aktivitelerinin yoğun kullanıldığı bir disiplin olan matematik, öğrencilerin "düşünme yeteneğini" geliştirmek için en iyi içeriktir. Ancak mevcut öğretim sisteminde öğrencilerin fikirleri, matematik ders kitaplarına ve sınıf öğretim modellerine bağlı olduğu için düşüncelerinin sınırlandırılarak gelişmemesine ve zaman kaybına neden olmaktadır (Mali ve Huaxi, 2019). Hazır bilgiyi alıp kendi içinde hiç çaba göstermeden kabullenen bir öğrenenin olduğu ve bu şekilde sadece kalem ve defterle yapılan geleneksel bir matematik eğitimi, öğrenenler için sıkıcı olabilmekte; ders içi motivasyon ve katılım eksikliği oluşturabilmektedir (Zheng vd., 2022). Ayrıca matematik dersinin soyut doğası, bazı öğrencilerin algılaması için zorluk oluşturabilmektedir. Kurallı, uzun süren işlemler öğrencilerin matematiğe karşı korku geliştirip matematikten uzak durmalarına neden olabilmektedir. Bu nedenle yeni nesil teknolojilerin kullanılması, bilginin yönetilmesini sağlaması ve görselleştirme olanakları nedeniyle önemlidir (Morrison, 2002).

Günümüzde eğitim ve öğretim sorunlarının çözümünde, yeni teknolojilerin kullanılması kaçınılmaz hale gelmiştir (Çankaya ve Karamete, 2008). Yeni nesil teknolojilerin oyun tabanlı öğrenme ile bütünleştirilmesi ve öğretime katılması, öğrenciler açısından avantajlı olabilmektedir. Oyun tabanlı öğrenme, matematik dersi açısından önyargıları kırmakta etkili bir yöntemdir (Ahmad vd., 2010). Öğrencilerin matematik dersine karşı kaygılarının olabildiğince düşük ve tutumlarının olumlu, motivasyonlarının yüksek, derse olan ilgilerinin sürdürülebilir olmasını sağlamak amacıyla 2005 yılından itibaren Türkiye’de uygulamaya konmuş olan yapılandırmacı yaklaşım ve öğrenci merkezli aktif öğrenme modelleri okullarda uygulanmakta ve eğitim sisteminde yer bulmaktadır (MEB, 2016). FATİH projesi başta olmak üzere, Türkiye’de son

yıllarda eğitime yönelik teknoloji kullanımı önemsenmekte ve bu alanda birçok yatırım yapılmaktadır. Fakat teknoloji, sadece akıllı tahtalar ve tabletlerin sınıflarda kullanılması anlamına gelmemektedir, aynı zamanda bu teknolojinin içeriğini dolduracak olan yeni yazılımlar gerekmektedir (Keleş, 2018). Günümüzde eğitim-öğretim alanında faaliyet gösteren birçok yayın evinin geliştirdiği uygulamalar mevcuttur. Bu yayınevlerinin dijital kütüphanelerini, akıllı tahtaya uyumlu hale getirdikleri ve çevrim dışı olarak derslerde çokça kullanıldıkları görülmektedir. Ayrıca yayın evleri haricinde online, üyelik gerektiren, oyun içeren, ücretli veya ücretsiz ders müfredatlarına uygun birçok eğitim içerikli web sitesi ve Z kitap gibi dijital materyaller mevcuttur. Eğitim alanında faaliyet gösteren şirketlerden bazıları dijital eğitsel web sitelerinde ders anlatım videoları, online test ve deneme sınavları ve eğitsel dijital oyunlar barındırmaktadır. Ayrıca bu şirketlerden bazıları bir öğretmenin yaptığı birçok iş ve görevi yapay zekaya yaptırarak çağa uyum sağlama halindedir.

Derslerde öğretmenlerin kullandığı matematik dili bazı öğrencilere soyut ve sıkıcı gelebilmektedir. Ayrıca matematik dilinin öğrenilmesi zor veya zaman alıcı olabilmektedir. Bu durumlarda akrandan öğrenme devreye girebilmektedir. Bazı öğrenciler, matematik problemlerini öğretmenlerden veya yetişkinlerden daha farklı çözebilmektedir; bu da akranın yaptığı çözümün yine akranı tarafından daha iyi anlaşılmasını sağlar. Akranlar arasında kurulan bu bağ, bilginin daha kısa sürede edinilmesini ve kalıcı olmasını sağlamaktadır (Kim vd., 2014). Dijital matematik oyunlarında oluşturulan akranlar arası gruplar, grup içi ve akrandan öğrenme faktörünü geliştirip öğrenmeye olumlu katkıda bulunabilmektedir. Gruba bağlılık ve grup ruhu, karşı grupla olan rekabet, matematik öğrenmeye yardımcı olan bir itici güç oluşturabilir. Bunlara ek olarak dijital oyunların kullanılması, öğrenci için matematiği daha zevkli ve ilgi çekici hale getirmektedir (Ahmad vd., 2010).

Dijital oyunlar, günümüzde mobil cihazlar ve internete aşina olan Z kuşağı için ders işleme yöntemi olarak oldukça uygun bir araçtır. Eğitsel dijital matematik oyunları, birden fazla duyuyu harekete geçirdiği için çoklu zekâ kuramına uygundur. Bu sayede matematik öğretiminde kalıcılık sağlanabilir ve pekiştirme

çok yönlü olduğu için öğrencilerin öğrendiklerini unutmaları, önceki derslerde ne işlendiğini hatırlayamamaları gibi bilgi eksikliklerinden kaynaklanan öğrenme sorunları azaltılabilir. İlgi arttıkça gözlem ve derse katılım süresi artabilir ve dikkatsizlikten kaynaklanan hatalar en aza indirgenebilir; böylece yanlış öğrenmelerin neden olduğu zincirleme etkiler de azalabilir. Matematik kaygı düzeyi yüksek olan öğrenciler dersteki kazanımlara dikkat gösteremedikleri için öğrenme gerçekleşmeyebilir. Ders içinde dijital oyun kullanımı ders atmosferini değiştirerek kaygı düzeyini düşürebilir, ayrıca oyun sırasında gerçekleşen puan alımı, seviye atlama gibi bileşenler matematiğe yönelik hiç kaygı taşımayan bir öğrenciye bile düşük düzey kaygı oluşturarak öğrencinin katılımı sağlanabilir. Ayrıca sınav odaklı bir eğitim benimsenmesi öğretmen ve öğrenci üzerinde stres ve baskı oluşturmaktadır (Kirkpatrick ve Zang, 2011). Bu nedenle, dersle ilgili kaygı düzeyini azaltmak için yeni yöntemler benimsenmelidir. Dijital oyunlarla öğretim bu yöntemlerden biri olarak öne çıkmaktadır. Dijital oyunlar, öğrenenin kendi öğrenmesinin sorumluluğunu taşımasını sağlayacak en iyi yoldur (Rieber, 1996). Ayrıca dijital matematik oyunları hem ders içi hem de ders dışı bir öğrenme alternatifi olarak değerlendirilebilir. Çolakoğlu ve Korkusuz (2022), eğitsel dijital oyunlar ile ilgili en çok araştırma yapılan disiplinin matematik olduğu belirlenmiştir. Bu durum, matematik dersinde yaşanabilme ihtimali yüksek olan öğrenme güçlüklerine çözüm bulabilmek için eğitsel dijital oyunlar aracılığı ile öğrenenlerin bilgiye eğlenerek doğrudan kendisinin ulaşmasını sağlayabileceğini göstermektedir (Karamete ve Çankaya, 2008).

Beyin aktivitelerinin çok kullanıldığı matematiksel düşünmenin nörofizyolojik temellerini araştıran çalışmalarda, matematik becerileri ön plana çıkmaktadır. Bazı çalışmalar, aritmetik stratejilerin elektroensefalografi (EEG) korelasyonlarına odaklanmıştır (Grabner ve De Smedt, 2012). Yüksek öğrenimdeki başarı, dikkat ve çalışma hafızası kapasitesi gibi beyin fonksiyonlarıyla ve aynı zamanda matematiksel düşünme gibi bilişsel fenomenlerle ilgili olabilecek önceden geliştirilmiş matematik becerilerine dayanmaktadır. Bu kapsamda araştırmalar yapmakta olan Steiner ve Martynova (2022), matematik yeterliliğinin değerlendirilmesinde EEG elde edilen beyin sinyalleri ile matematik yeterliliğinin ilişkili olduğuna dair bir çalışmada

matematiksel düşünmenin sinirsel temellerine de ışık tutabileceğini belirtmişlerdir.

2.2. Beyin Bilgisayar Arayüzü (BBA)

Uluslararası alanyazında Brain-Computer Interfaces (BCI) şeklinde kısaltılan bu terim, Türkçe literatürde Beyin-Bilgisayar Arayüzü (BBA) olarak ifade edilmektedir. Beyin; hala üzerinde çalışılan, sinir sisteminin merkezi olan, organları komutlandırarak birçok görevi yerine getiren bir derin sinir ağı olarak görülebilir (Sejnowski, 2018). Beyin bilgisayar arayüzü, beyin ile dışarıdan etkileşime girip iletişim kanalı oluşturan, beyin sinyallerini mesaj ya da komutlara dönüştürebilen, korteksten gelen elektrik sinyallerini işleyerek beyin aktivitelerini kontrol ve analiz eden harici bir sistemdir (Parki, 2013; Acı vd., 2019; Büyükgöze, 2021; Almalı, 2023). BBA, insan beyninin nöral faaliyetleri hakkındaki bilgilerin kodunu çözerek, periferik sinirlere ve kaslara bağlı olmaksızın gözlenen öznenin niyetini veya zihnini cihazın kontrol komutuna çevirerek beyni doğrudan harici bir cihaza bağlayan ve bilginin aktarılmasını sağlayan teknolojidir (Rebsamen vd., 2010; Koo vd., 2014).

BBA' nın beyin sinyallerini yakalama, alınan sinyalleri işleme, sınıflandırma gibi işlevleri bulunmaktadır. Analiz aşamasında ise veri madenciliği yöntemleri ve derin öğrenme teknikleri kullanılarak beyin sinyallerinden anlamlı bilgiler açığa çıkarılmaktadır. Ayrıca BBA sistemleri elde edilen sinyallerin analiz sürecinde gerekli matematiksel yöntemlerin geliştirilmesi için eşsiz bir araştırma alanı sunmaktadır (Donoghue, 2002; Bell vd., 2004; Xiao vd., 2009; Song ve Lee, 2018; Büyükgöze, 2019a). Abbass vd. (2016), BBA ile Yapay Sinir Ağları (YSA) arasında organik bir ilişki olduğunu ve YSA'nın BBA tabanlı sınıflandırma sayesinde kontrolör konumunda olduğunu ifade etmiştir. YSA ise insan sinir sisteminden ilham alıp bilgi ileten yapay nöronlara sahip olan, beynin işleyişini baz alarak kendi kendine öğrenebilen bir bilgi işleme sistemidir (Guo vd., 2010). Son yıllarda ise elektroensefalogram (EEG), beyin aktivitesini somut uygulamalara dönüştürmek için elektroensefalografik aktivite ölçüm teknolojisini hesaplamalı geliştirmeye birleştiren bir BBA sistem türü olarak ifade edilmektedir

(Caesarendra vd., 2015; Kannadasan vd., 2024). Bu sistem EEG ile ölçümlerin non-invaziv gerçekleştirilmesi ve düşük maliyetli olması nedeniyle veri toplama aracı olarak sıklıkla kullanılan bir BBA çeşididir (Guo vd., 2021).

Beyin sinyallerinin çok zayıf olması nedeniyle sinyallerin özelliklerini çıkarmak için EEG sinyallerine yükselticiler ile bazı uzaysal ve spektral filtreler uygulanması gerekmektedir. Tespit edilen EEG sinyalleri, frekansların değişmesiyle oluşmaktadır. Örneğin istemli düşünceler sırasında, sinyallerin frekansları değişmekte ve hareket sırasında beyin aktivitesinin senkronizasyonu/desenkronizasyonu gerçekleşmektedir (Abiyev vd., 2016). Bu nedenle BBA'da kullanılan nöral veya fizyolojik sinyaller, denekler arasında yüksek değişkenlik göstermektedir (Kang vd., 2016).

Geçmişte nörobilim, psikolojik araştırmalar, rehabilitasyon vb. tıbbi uygulamalara odaklanan BBA teknolojisi; bilim insanlarının merakı ve yeni teknolojiler geliştirmeleri sayesinde günümüzde iletişim, eğlence, dijital oyunlar, yeni nesil araçlar (drone vb.) gibi çok çeşitli alanlarda tercih edilip geleceğin teknolojileri arasında yer almaktadır (Victoria vd., 2010; Kang vd., 2016; Benitez vd., 2016). Bazı araştırmacılar, EEG tabanlı BBA cihazlarının diğer alanların yanı sıra, öğretme-öğrenme senaryolarında ve işyerlerinde performansı optimize etmek gibi çeşitli amaçlarla kullanılabileceğini belirtmektedir (Konar, 2015). EEG cihazını kullanabilen eğitimli eleman sayısındaki eksiklik bu teknolojinin eğitim alanında yeterince yaygın kullanılamamasına neden olmaktadır (Hu vd., 2018). Günümüzde kullanıcılara ait beyin sinyallerinin makine öğrenmesi yöntemleri ile yapay zekaya öğretilmesi ve anlık olarak işlenmesi sayesinde fiziksel komutlarla çalışan aygıtların (fiziksel aygıtlar, protezler vb.) bu alanda kullanılabileceğini göstermektedir. Dünyanın her yerinde oyunlara ilgi duyan, zaman ve paralarını oyun oynamak için harcayan çok sayıda dijital oyuncu bulunmaktadır. Dijital oyun endüstrisinin büyüklüğü, oyun uygulamalarının Google Play Store ve Apple Store'dan indirilme sayısından anlaşılabilir. Ayrıca oyun oynayan bireylere ait verilerin ve oyun süreçlerinin analiz edilmesi de gün geçtikçe önem kazanacaktır (Anwar vd., 2016).

2.2.1. Duygu ve duyuşsal hesaplama


İnsanların zihninden geçen düşüncelerin ve duyguların bir insan tarafından sezilebilmesi çok zor olabilmektedir. İnsanların duygularını anlamadaki karmaşıklık ve insan duygularının çok değerli olması, araştırmacıları duyguları hesaplamaya yönlendirmiş, duyuşsal hesaplama kavramı ortaya çıkmıştır (Koç, 2022). Duyuşsal hesaplama insan faktörüyle yapılamadığı için yapay zeka ve makine öğrenimi gibi teknolojik kavramlar karşımıza çıkmaktadır. Duygu durumlarının beyinde üretilen elektriksel aktiviteyle ilişkili olduğu, son yıllarda yapılan çalışmalarda gözlemlenmektedir (Bekkedal, 2011; Tandle vd., 2018). EEG sinyalleri mükemmel zamansal çözünürlüğe sahiptir ve nöronal aktivitenin doğrudan ölçümüdür (Torres vd., 2020). Nöronal aktivitenin ölçülebilir olması ise duygu durumlarının EEG sinyalleri veya farklı BBA sistemleri sayesinde hesaplanabilir hale gelmesini sağlamıştır. Bu bağlamda EEG sinyallerini kullanarak gerçekleştirilen duygu tanıma çalışmalarının güvenilir ve kullanışlı bir teknik olan BBA araştırmalarında güncel bir odak noktası haline gelebileceği düşünülebilir.

Duyuşsal hesaplamanın temel unsurlarından biri, duygusal durumları davranışsal ve fizyolojik tepkilerden tahmin eden otomatik duygu tanıma yeteneğidir (Calvo ve D'Mello, 2010). Otomatik duygu tanıma, duygusal hesaplamanın çalışma alanlarından biridir ve bu alan duyguların hesaplamalı modelleri ile bilgisayarların duygusal zekasını geliştirmeyi amaçlamaktadır (Picard, 2000).

EEG sinyalleri, simüle edilemeyen ve sahtesi yapılamayan güvenilir bilgilerdir. EEG'nin kodunu çözmek ve bu sinyalleri belirli bir duyguyla ilişkilendirmek oldukça zordur. Duygusal durumların spesifik beyin yapılarıyla basit bir haritalaması yoktur çünkü farklı duygular, aynı beyin bölgelerini harekete geçirebilir ya da tam tersi, tek bir duygu birçok beyin bölgesini harekete geçirebilmektedir. (Torres vd., 2020). Duyguların deneyimlere bağlı olduğu bilinmekle beraber, bir etkenin beklenen duyguyu ortaya çıkarıp çıkarmadığı kesin olarak öngörülemez. Bu öngörülemez durum ise yapay zeka algoritmaları

ile mimiklerin tanınmasının kullanımıyla ortaya çıkan tüm olası yüz deformasyonlarının (ağız, alın, kaş, göz kapakları) dikkate alınabileceği şekilde önceden tanımlanmış belirli bir parametrik model ile günümüzde kullanılabilir hale gelmiştir (Savran vd., 2006; Karaboyacı, 2009). Bu alandaki araştırmalar, duygular ile elektroensefalografik (EEG) değişimler arasındaki ilişkiyi çözen sistemler için girdi görevi gören beyin sinyallerini yakalamak için uygun fiyatlı cihazların bulunması sayesinde hızla gelişmektedir (Torres vd., 2020). Otomatik EEG tabanlı duygu tanıma, insanların çevreleriyle ilişkilerini zenginleştirmeye yardımcı olacak ve insan etkileşimi için tasarlanan yapay zeka varlıklarında, önemli bir rol oynayacaktır (Goenaga vd., 2020).

Şekil 2.1.'de görüldüğü üzere duyuşsal hesaplama ve duygu tanımda BBA sisteminin kullanılışında sırasıyla; sinyal elde etme, ön işleme, özellik çıkarma, özellik seçimi, sınıflandırma ve performans değerlendirme adımları işe koşulmaktadır.



Şekil 2. 1. Duygu tanıma yönelik EEG tabanlı bir BBA sisteminin yapısı (Torres vd., 2020)

Birbirinden farklı BBA tabanlı sistemler, duyguları ortaya çıkarmak için birbirinden farklı deneysel yöntemler ve yaklaşımlar kullanmaktadır. Bu nedenle bu sonuçları doğrudan karşılaştırmak her zaman doğru sonuç vermeyebilir. EEG sinyallerini tespit etmek için gerekli protokoller, veri kümeleri, özelliklerin çıkarılması, özelliklerin seçilmesi, sınıflandırma algoritmalarının kullanılması

genel olarak her uygulamada farklı ayarlar gerektirdiğinden ideal yöntem, sistemlerin benzer koşullar altında test edilmesidir (Torres vd., 2020).

Genetik ve fiziksel açıdan, erkek ve kadınların farklı olduğu bir gerçektir. Bazı araştırmalarda ortalama erkek beyninin kadın beyninden yaklaşık %10 daha ağır olduğu belirtilirken, kadın beynindeki bazı alanların erkeklerden daha fazla nöron içerdiği belirtilmektedir (Zaidi, 2010; Marner vd., 2003). Ayrıca bazı araştırmacılar, kadınların erkeklere göre daha yoğun bir korpus kallozuma sahip olduğunu ve bu durumun, kadınların erkeklere göre karakteristik açıdan daha duygusal davranışları ortaya çıkardığını iddia etmektedir (Safri vd., 2018). Ancak bu çalışmada kadın denek kullanılmadığından kadın ve erkek duygu durumlarıyla ilgili herhangi bir karşılaştırma yapılmamıştır.

İnsan duygularının tespiti ve takibi; multimedya ürünlerindeki katılım ve dikkat ölçümlerinden duyguya duyarlı etkileşimli oyunlara, daha insan benzeri etkileşimlere sahip gelişmiş multimedya arayüzlerinden duygusal bilişime, duyguya duyarlı otomatik eğitim sistemlerinden araştırmaya kadar birçok potansiyel uygulamaya sahiptir (Savran vd., 2006). EEG tabanlı duygu tespit çalışmaları, savunma, havacılık, tıp gibi çok çeşitli alanlarda kullanılmaktadır (Bano vd., 2022)

2.3. EEG (Elektroensefalogram)

İnsan merkezi sinir sisteminde beyin ve omurilik; çevresel sinir sisteminde, sinirler ve duyu nöronları yer almaktadır (Kandel vd., 2000). Merkezi sinir sistemi ana elemanı olan beyin, farklı noktalarda ölçülebilen elektrik sinyalleri üretmektedir (Alonso vd., 2011). Üretilen sinyallerden bazıları, beyin korku, üzüntü, heyecan, sevinç gibi olaylarda maruz kaldığı durumu yansıtan beyin aktiviteleridir (Sakalle vd., 2022). Beyin sinyalleri elektroensefalogram (EEG) isimli cihazla kaydedilebilmektedir. EEG; çeşitli aktiviteler sırasında beyin serebral korteks bölümünde üretilen, kafa derisinin dış yüzeyinden yüksek zamansal ve uzaysal çözünürlükle kaydedilen elektrik sinyallerinin görüntülenmesini sağlayan bir yöntemdir (Hızar, 2023; Yücel ve Çubuk, 2014). EEG, beyindeki bilişsel değişiklikler sonucunda ortaya çıkan elektrik sinyalini

kaydederek beyin aktivitelerini deęerlendirmeyi saęlamaktadır (Park vd., 2013). EEG sinyalleri, beyin aktivitesinin arařtırılmasında önemli rol oynamaktadır, ayrıca davranıř ve biliřle yakından iliřkili büyük ölçeklerde sinaptik eylem tahminleri saęlamaktadır (Nunez ve Srinivasan, 2006; Ngo vd., 2021).

Liverpool'da öğretim görevlisi Richard Caton (1842–1926), hayvanlar üzerinde yaptıęı deneylerde, beynin dıř yüzeyinde iki ayrı noktaya elektrot yerleřtirmiř ve deęiřken yönlerde zayıf akımların geçtięini gözlemlemiřtir. Böylece ilk EEG sinyallerinin varlıęı 1875'te, Caton tarafından keřfedilmiřtir. Ancak EEG, 1929'da Alman Psikiyatrist Hans Berger tarafından icat edilmiřtir. Berger, insan beynine elektrot baęlayarak EEG sinyallerini kaydeden ilk bilim insanıdır (Sur ve Sinha, 2009; Ay, 2023). EEG ile ilgili yapılan ilk çalıřmalar labaratuvarda gerçekleřmiřtir. Bu alanda teknolojinin geliřmesi, EEG cihazlarının minyatürleřmesini ve tařınabilirlięini saęlamıřtır. Bu nedenle EEG sistemleri, laboratuvar dıřında da kullanılabilmıřtir. Bazı çalıřmalar, açık havada serbest yürüyüř sırasında bile elde edilen sinyal kalitesinin tek denemeli EEG analizi için yeterli olduęunu göstermiřtir (Debener, 2012).

BBA üzerine yapılan çalıřmalarda EEG, zihinsel ve bedensel süreçler arasındaki iliřkileri incelemek için kullanılan bir tür psikofizyolojik ölçüm yöntemi olarak görölmektedir (Sawangjai vd., 2019). EEG çoęunlukla epilepsi hastalıęında, uyku bozukluklarında, dikkat eksiklięi ve hiperaktivite bozukluęunda, bilinç ve algı bozukluęunda, unutkanlık ve bunamada, koma ve beyin ölümu gibi tıbbi arařtırmalarda kullanılmaktadır. Ancak günümüzde EEG'nin kullanım alanı oldukça geniřlemiř ve bilgisayar arayüzü tasarımı, bilgisayar oyunu geliřtirme ve nöropazarlama gibi alanlarda da yaygınlařmıřtır (Xu ve Zhong, 2018).

EEG sinyallerinin eęitimde kullanımı ve analizi, öğrencilerdeki kiřisel biliřsel özelliklerin deęerlendirilmesi ve tahmin edilmesi için teřvik edici bir araç sunabilmektedir. Bu sayede öğrenme çıktıları hakkında niceliksel bir içgörü elde edilebilmektedir. Moreno vd. (2021), yüksek ve düşük frekanslı EEG bantları analiz edilerek öğrenme sırasında öğrencilerde devam eden biliřsel süreçler hakkında bilgi elde edilebileceęini belirtmiřtir. EEG frekans bantları Delta, Teta,

Alfa, Beta, Yüksek Beta, Gama olarak sınıflandırılmaktadır. Yüksek frekanslı bantlar; uyanıklığı, aktif düşünmeyi, dikkati ve çoklu duyusal işlem durumlarını (Gutierrez ve Moreno, 2016), düşük frekanslı bantlar ise gevşeme, uyuşukluk ve zihinsel yorgunluk durumlarını yansıtabilmektedir (Krishnan ve Yaacob, 2019). EEG kayıtları, tüm kortikal yüzeyden milisaniye ölçeğinde nöral elektriksel aktiviteyi yakalamaktadır (Savran vd., 2006). EEG sistemlerinin en büyük avantajlarından biri çok hızlı ölçüm alabilmeleridir (Koç, 2022). EEG sinyallerini ayırt etmek için en yaygın sınıflandırıcı, Yapay Sinir Ağlarıdır (YSA). YSA, biyolojik sinir sistemlerinden ilham alan bir bilgi işleme sistemidir ve özel bir donanım sayesinde hesaplamaları çok yüksek bir hızda gerçekleştirebilmektedir (Guo vd., 2010). YSA, insan beyni ve onun işleyişini temel alarak kendi kendine öğrenebilen bir sistemdir ve insan beyni gibi YSA da birlikte çalışarak bilgi paylaşan nöronlara sahiptir. YSA; sinyal işleme, örüntü tanıma, veri analizi ve tespit süreçlerinde, biyomedikal alanlarda oldukça popülerdir (Guo vd., 2010). EEG; uygulamalarında ağrı ve acı çekilmeyen, her yaştan bireye uygulanabilen, diğer yöntemlere göre daha güvenilir olduğu belirtilen bir cihaz olarak kabul edilmektedir (Cernea vd., 2011; Badcock vd., 2013; Kuber ve Wright, 2013; Holewa ve Nawrocka, 2014; Zheng ve Guo, 2015; Benitez vd., 2016; Torres vd., 2020) En ufak bir uyarana tepki verdiği için EEG verilerinin değiştirilmesi güçtür ve EEG ile bireylerin dikkatini ölçmek üzere yapılan bazı araştırmalar sonucunda, EEG cihazlarının katılımcılar için geçerli ve rahat olduğu kanıtlanmıştır (Alakuş ve Türkoğlu, 2019; Xu ve Zhong, 2018). EEG, özellikle tıbbi uygulama ve dijital oyun içeren birçok araştırmada denetleyici olarak kullanılmıştır (Hu vd., 2018). Geçmiş eğitim araştırmalarında EEG ile gerçekleştirilen araştırmalarda beyin aktivite deneylerinin çok fazla hazırlık gerektirmesi, EEG kullanabilen ve EEG verilerinden anlam çıkarabilen araştırmacı sayısının az olması, EEG cihazlarının büyük yapıda olması, sınıf atmosferinde kullanılmasında güçlükler yaşanmasına sebep olması gibi nedenlerle EEG cihazları ile araştırmalar sınıf ortamında çok fazla gerçekleştirilememiştir (Hu vd., 2018; Xu ve Zhong, 2018). Ancak günümüzde teknolojinin hızlı ilerleme kaydetmesiyle EEG, zamanla daha portatif ve minyatür hale gelmiş ve kısa süren bir ön hazırlıkla beyin sinyaller verileri toplamak mümkün olmuştur (Xu ve Zhong, 2018).

Günümüzde bağlantı türü, yazılım çeşidi ve elektrot sayısı gibi farklılıklar taşıyan EEG cihazları piyasaya çıkmıştır. Eğitim araştırmalarında ise sınıf ortamında katılımcılara rahatlık sağlaması ve hareketlilik ile sinyalin bozulmaması gibi olumlu özellikleri nedeniyle genellikle taşınabilir EEG cihazlarının kullanımının tercih edildiği görülmektedir. TEEGT; çeşitli davranışlar ve zihinsel süreçlerle ilişkili nöral bağıntıları izlemek isteyen araştırmacılara kablosuz, ergonomik, düşük maliyetli bir EEG izleme sunmaktadır (Luo ve Sullivan, 2010). Son yıllarda EEG ile gerçekleştirilen çalışmalarda ise yaygın olarak Emotive™ EPOCH ve NeuroSky MindWave Mobile giyilebilir ve taşınabilir EEG cihazları ile beyin sinyalleri toplanmış ve analiz edilmiştir.


2.3.1. EEG kullanımı

EEG kullanımı sırasında; elektrotlar kafa üzerinde belirlenmiş konumlara, mekanik ve elektriksel kontaktlarla yerleştirilmekte ve kafa derisindeki elektrik voltajları ölçülmektedir (Nacke vd., 2011). Beyin sinyalleri, kafa derisine yerleştirilen bu elektrotlar vasıtasıyla alınmaktadır (Koç, 2022). Ara elektrotlarda iki harf kombinasyonu bulunmaktadır. Çizelge 2.1.'de sunulduğu üzere harfler, elektrotun bulunduğu beyin kısımlarını ifade etmektedir. Şekil 2.1.'de görüldüğü üzere çift sayılı elektrotlar (2,4,6,8) kafatasının sağ tarafına ve tek sayılı elektrotlar (1,3,5,7) kafatasının sol tarafına yerleştirilmektedir (Öztürk, 2016).

Çizelge 2. 1. Elektrotların adlandırılması (Öztürk, 2016)

Elektrot Adlandırma	Elektrotun Beyinde Bağlı Bulunduğu Kısımlar
Fp	Frontal Kutup
F	Frontal (Ön Lob)
C	Central (Merkez)
FC	Frontal ve Merkez Elektrotlar Arası
PO	Parietal ve Oksipital Elektrotlar Arası
Fz	Frontal Lob Merkezi
T	Temporal (Şakak Lobu)
P	Parietal (Yan Lob)
O	Oksipital (Arka Lob)
A	Kulak Elektrodu

Elektrotlar yerleşim düzenlerine göre bir harf ve bir rakam ile birlikte isimlendirilmektedir. Uluslararası EEG ve Klinik Nörofizyoloji derneklerinin önerdiği 10-20 sistemine göre elektrotların kafa derisine yerleştirilme düzeni Şekil 2.2'deki gibidir.



Şekil 2. 2. Uluslararası kabul edilen 10-20 sistemi (Keleş, 2023)


Kafanın ön kısmı Nasion, arka kısmı Inion olarak da adlandırılır. Cz ise tam ortayı göstermektedir (Keleş, 2023). Daha ayrıntılı bir dizilim Şekil 2.3' te verilmiştir.

(Köksal, 2023). Non-invaziv yöntemlerde ise nöronal aktivite tarafından üretilen elektrik potansiyelinin değişimini ölçmek için kafa derisine birkaç elektrot yerleştirilmektedir. Bu elektrotlar kullanıcının kafa derisine ağrısız bir şekilde yerleştirilebildiği için BBA geliştirmede daha çok tercih edilmektedir (Benitez, 2016). Non-invaziv sistemler, BBA'nü kullandığından uygulanması daha kolaydır ve dünyada en yaygın kullanılan sistemlerdir (Wang ve Wang, 2021). Her iki tekniğin de avantajları ve dezavantajları bulunmaktadır ve her ikisi de beyin aktivitesi hakkında değerli bilgiler vermektedir (Alakuş ve Türkoğlu, 2019). EEG, genellikle non-invavif bir teknik olarak kabul edilmektedir. Normalde beyin sinyalleri, kafa tası üzerinden elektrotlar aracılığıyla toplanmaktadır, ancak bazı durumlarda beyin aktivitesi, amaliyatla yerleştirilen elektrotlarla beynin içinden izlenmektedir (Koç, 2022).

Diğer beyin araştırma yöntemleriyle (Manyetoensefalografi-MEG, Fonksiyonel Manyetik Rezonans Görüntüleme-fMIR, Yakın Kızılötesi Spektroskopi-NIRS, Pozitron Emisyon Tomografisi-PET vb.) karşılaştırıldığında EEG yöntemi beyin aktivitesinin gerçek zamanlı olarak değerlendirilmesine olanak tanımakta ve çeşitli çevresel koşullar altında nispeten düşük uygulama maliyetleri ile sağlamaktadır (Holewa ve Nawrocka, 2014).

EEG sinyallerinin genliği; yaş, cinsiyet, deneklerin gün içinde uyanıklığındaki değişiklikleri yanında alkol ve kafein gibi diğer faktörlere bağlı olarak büyük ölçüde değişebilmektedir. Böylelikle, bu değişkenliğin üstesinden gelmek için ölçülen değerlerin normalleştirilmesi gerekmektedir. Normalleşmeye yönelik yaklaşımlar çalışmanın analiz kısmında açıklanmıştır.

EEG cihazı ön yükselteç bölümü, mikro işlem bölümü, veri depolama bölümü ve veri iletim bölümünden oluşmaktadır. EEG sistem parçaları ise elektrot, preamplifikatör, ana işlemci, veri iletimi ve veri kaydetme kısmından sorumlu donanım parçalarından oluşmaktadır. Bu sisteme ait parçalar Şekil 2.4'te gösterilmiş ve beyin dalgalarıyla ilgili genel bilgiler Çizelge 2.2.'de verilmiştir (Park vd., 2013).




Şekil 2. 4. EEG Modül mimarisi bölümü (Park vd., 2013)

Biyosinyal işlemenin kapsadığı konu yelpazesi oldukça geniştir. Sandham ve Hamilton (2006), biysinyal işlemenin konu yelpazesini aşağıdaki ana alanlara ayırmıştır;

1. Fizyolojik sinyallerin kaynağı ve doğası (EKG, EEG, EMG, ERP),
2. Sinyaller ve sistemler (Doğrusal sistem teorisi; Laplace, Fourier ve Z-Skor Dönüşümleri; Sinyal Dönüşümü, DFT ve FFT),
3. Sinyal işleme (Analog Filtreler, Dijital Filtreler, FIR Tasarımı),
4. Gelişmiş sinyal işleme (Adaptif Teknikler; Zaman-Frekans ve Dalgacık Analizi, Bulanık Mantık, Yapay Sinir Ağları),
5. Tıbbi görüntülerin kaynağı ve doğası (CT, MRI, Ultrason),
6. Görüntü işleme (Geliştirme, Geri Yükleme, Sıkıştırma, Segmentasyon),
7. Biyosinyal işleme (EKG Analizi, EEG analizi, MRI segmentasyonu vb.).

EEG sinyalleri frekans birimi Hertz (Hz) ile ifade edilmektedir. Durağan EEG sinyalleri genellikle 0-100 Hz frekans aralığındadır (Verma ve Mangaraj, 2010). Sinyallerin isimleri ve frekans aralıkları delta (1-3 Hz), teta (4-7 Hz), alfa (8-13 Hz), beta (14-30 Hz) ve gama (31-50 Hz) frekans bandındaki salınımlardan oluşmaktadır (Kumar vd., 2016). Şekil 2.5'te EEG dalga türleri verilmiştir (Chatterjee vd., 2019).



Şekil 2. 5. EEG dalga türleri (Chatterjee vd., 2019)

Çizelge 2.2. Beyin dalgalarıyla ilgili genel bilgiler (Hall ve Hall, 2020; Saymaz, 2020; Kumar ve Bhuvaneswari, 2012)

Beyin Dalga İsmi	Frekans Aralığı (Hz)	Hangi Durumlarda Gözlemlendiği	Beyinde Gözlemlendiği Bölgeler	Sembolü
Alfa	8-13	Uyanıklık Sakinlik Meditasyon	Oksipital Parietal Frontal	α
Beta	14-30	Dikkat Odaklanma	Frontal Parietal	β
Delta	1-3	Derin uyku Bilinçsizlik	Frontal Oksipital	δ
Teta	4-7	Rahatlık Uykuya geçiş	Temporal Parietal	θ
Gama	31-50	Öğrenme Yoğun Bilişsel Aktiviteler	Frontal Temporal Parietal	γ

2.3.2. Çalışmada kullanılan EEG cihazı (Emotive™ EPOCH)

Emotive™ EPOCH, beyin aktivitesini ölçmek için sinir dokusunun ürettiği elektrik potansiyellerinden yararlanan bir EEG cihazıdır. Cihazın metalik elektrotları, beyin aktivitesini ölçmek amacıyla kafa derisine yerleştirilmektedir. Beyin sinyallerini gürültüsüz bir şekilde almak için iletkenliğin artırılması ve performansların iyileştirilmesi gerekmektedir. Bu gereklilik ise elektrotların iletken çözeltiyle ıslatılması ile yani her elektrotta yeterli miktarda solüsyonun bulunması ile gerçekleştirilmektedir. Ayrıca elektrotların doğru konuma yerleştirilmiş olmasına dikkat edilmelidir (Raju vd., 2016). Emotive™ EPOCH cihazı beyin sinyallerinin toplandığı elektrotlar haricinde kafa konumu bilgisi sağlamak için iki dahili jiroskopa da sahiptir (Benitez vd., 2016). Emotive™ EPOCH' un bilgisayar ile iletişimi bir USB alıcısı aracılığıyla kablosuz olarak gerçekleşmektedir ve Emotiv yazılımı bu iletişimi;

✓ Beyin sinyallerini işlemek, sistemi eğitmek ve nöroheadset'i test etmek için grafik arayüzüne sahip bazı paketler veya geliştirilmiş uygulamalar ile,

✓ Kullanıcıların, nöroheadset ile kullanılacak C veya C++ yazılımını geliştirmelerine olanak tanıyan bir uygulama programlama arayüzü (API) vasıtasıyla sağlamaktadır.

Emotive™ EPOCH, Delta (0,5–4 Hz), Teta (4–8 Hz), Alfa (8–14 Hz) ve Beta (14–26 Hz) bantlarındaki beyin dalgalarını yakalayabilmekte ve işleyebilmektedir. Bu bantlardaki sinyallerden gelen bilgilerle ifade edici eylemler, duyuşsal durumlar ve bilişsel eylemler tespit edebilmektedir (Alonso vd., 2011). Sistem tarafından işlenen ve ekrandaki avatar eylemlerine dönüştürülen gülümseme, göz kırpma gibi 30 farklı duygu ve eylemi kapsamaktadır (Raju vd., 2016). Şekil 2.6'da Emotiv EPOCH cihazı gösterilmektedir.




Şekil 2. 6. Emotive™ EPOCH mobil EEG cihazı (Emotiv, 2023)

Nöroheadset, beyin aktivitesini ölçmek için toplam 14 elektrotun yanı sıra referans noktası olarak çalışan iki ekstra elektrotla donatılmıştır. Elektrotlar, uluslararası sistem 10-20'nin önerdiği şekilde kafa derisinin kilit noktalarına konumlandırılmaktadır. EPOCH tarafından algılanan elektrot konumları, Ortak Mod Algılama (Common Mode Sense (CMS)) aktif elektrotu ve referans olarak Sürülen Sağ Bacak (Driven Right Leg (DRL)) pasif elektrodu (P3 ve P4) içermektedir. Ayrıca, Nöroheadset bir sinyal amplifikatörü, 0.16 Hz'de bir yüksek geçiş filtresi (Capacitor-Resistor (CR)), 85 Hz'de bir analog alçak geçiş filtresi

(Analog Low-Pass Filter (ALPF)), yüksek frekanslı gürültünün yanı sıra elektrik şebekesinden kaynaklanan gürültüyü nötralize etmek için 50 Hz'de bir çentik filtresi içermektedir. Saniyede 128 örnekte sıralı örneklemeyi sağlayan basit bir Analog-Dijital Dönüştürücü içermektedir. Farklı kanallardaki ham beyin sinyalleri, LabVIEW aracılığıyla doğrudan EPOCH cihazında elde edilebilmektedir (Benitez vd., 2016). Kaydedilen bu sinyaller, kablosuz teknoloji kullanılarak bilgisayara iletilmektedir. Ayrıca Emotive™ EPOCH, yaklaşık 12 saat sürekli çalışma sağlayan bir lityum polimer pil ile mobilite, kablosuz çalışma özelliği ve hafif bir yapı sunmaktadır (Holewa ve Nawrocka, 2014).

Emotiv Şirketi, EPOCH cihazının EEG sinyallerini alıp işlediğini ve bir BBA olduğunu belirtmektedir (Emotiv, 2023) ve ayrıca literatürde de Emotive™ EPOCH, bir BBA olarak kabul edilmektedir (Ranky ve Adamovich, 2010). Emotive™ EPOCH sistemi tasarımı için uygulanan aşama adımları Şekil 2.7'de, Neural Impulse Actuator (NIA) ise Şekil 2.8'de sunulmuştur.



Şekil 2. 7. Emotive™ EPOCH geliştirme aşamaları (Benitez vd., 2016)


Şekil 2.8 'de Neural Impulse Actuator (NIA) gösterilmiştir.



Şekil 2. 8. Neural Impulse Actuator (NIA)(Neurosky, 2023)

Sinirsel İmpuls Aktüatörü (Neural Impulse Actuator (NIA)), OCZ Company tarafından oyun uygulamaları için geliştirilen ve tüketici beyin-bilgisayar arayüzü cihazlarında popüler bir yardımcı teknoloji olarak önerilen bir cihazdır. Emotive™ sistemleri ve NeuroSky™ ile karşılaştırıldığında, NIA'nın kullanımı basittir ve ayrıca daha uygun fiyatlıdır (Hawsawi and Semwal, 2014).

Emotive™ EPOCH; bir kullanıcının katılımını, hayal kırıklığını, heyecanını ve motivasyonunu gerçek zamanlı olarak algılayabilen 14 kanala sahiptir. Bu özellikleri nedeniyle Emotive™ EPOCH akademik araştırmalar için NeuroSky'dan daha üstündür (Xu ve Zhong, 2018; Liorakapis vd., 2014; Maskeliunas, 2016). Buna karşılık, NIA tek bir cihazdır. Çok elektrotlu bir EEG cihazı, cihazın maliyetini artırabilmektedir veya kullanım kolaylığı özelliklerini azaltabilmektedir. Bu nedenle Emotive™ EPOCH neuroheadset, NeuroSky cihazından daha pahalıdır (Xu ve Zhong, 2018). Emotiv, NeuroSky, InteraXon, OpenBCI kullanım verileri karşılaştırılması ise Sawangjai vd. (2020) tarafından gerçekleştirilen çalışmada incelenmiş ve Şekil 2.9'da sunulmuştur.



Şekil 2. 9. Emotiv, NeuroSky, InteraXon, OpenBCI kullanım verileri
(Sawangjai vd., 2020)

Bazı araştırmalarda, Emotive™ EPOCH neurohead set başlığının güvenilir bir beyin sinyali algılama aracı olarak kullanılabileceği belirtilmiştir (Alonso vd., 2011; Cernea vd., 2011, Cernea vd., 2012, Holewa ve Nawrocka, 2014; Badcock vd., 2013 ve Kuber ve Wright, 2013; Benitez vd., 2016; Jun vd., 2016). Emotive™ EPOCH'un kullanıldığı diğer çalışmalarda ise, öğrenenlerin dikkat ve duyguları değerlendirilmiş ve bu değerlendirmeler geçerli bulunmuştur (Xu ve Zhong, 2018).

Emotive™ EPOCH, 14 kanallı yapıya sahip kablosuz (taşınabilir) bir cihazdır. Cihazın EEG sinyalleri haricinde duygu metriklerini sunması, farklı kanallardan elde edilen ham sinyalleri Fourier Transform Dönüşümü yaparak hazır hale getirerek güç spektrumlarını sunması ve yüksek tanımlama doğruluk

performansı vermesi ve kontrol uyumluluğu sağlaması gibi özellikler taşıması nedeniyle bu çalışmada Emotive™ EPOCH tercih edilmiştir.

2.3.3. EEG tabanlı eğitsel oyunlar

Eğitimcilerin ve araştırmacıların, yeni öğretim yöntemlerine ve öğrencilerin tercih ettiği farklı öğrenme stillerine hızlı bir şekilde uyum sağlayabilmeleri için niceliksel bir eğitim değerlendirmesi sunan araçlar ve metodolojilerin geliştirilmesi gerekmektedir (Moreno vd., 2021). Kablosuz cihazlar aracılığıyla öğrencilerden alınan canlı geribildirim kullanan dinamik dersler ve öğrenci-öğretmen etkileşimi için sosyal medya eğitim platformları gibi modern teknolojileri kullanan yeni öğretim yöntemleri, daha geleneksel öğretim yöntemleriyle karşılaştırıldığında öğrenciler tarafından daha çok kabul görmektedir (Vatfa, 2015).

Günümüzde yararlandığı yeni teknolojiler sayesinde EEG tabanlı oyunlar büyük ilgi çekmekte ve bu alanda önemli miktarda eğitsel dijital oyun geliştirilmektedir. EEG teknolojisi ile yakalanan beyin dalgalarının anlaşılması ve izlenmesi, öğrencilerin öğrenme stiline belirlenebilmesi ve bilişsel becerilerinin analiz edilmesine katkı sunmaktadır (Shadiev vd., 2017). Bazı çalışmalarda EEG tabanlı eğitsel dijital oyunların, öğrenenlerin problem çözme becerilerindeki performanslarının değerlendirilmesini sağlayabildiği görülmüştür (Castaño-Candamil vd., 2015).

Çok modlu öğrenme analitiği, öğrenme süreçlerinin daha derinlemesine anlaşılmasını sağlayan etkili bir araç olarak öne çıkmaktadır. Pek çok araştırmacı, öğrencilerin öğrenme süreçlerini geniş bir bakış açısıyla değerlendirebilmek amacıyla çok modlu öğrenme analitiğine odaklanmaktadır. Bu analitik veriler, birbirini tamamlayarak ve doğrulayarak daha bütüncül bir değerlendirme sunabilir. Uygun maliyeti, ölçeklenebilirliği ve taşınabilirliğiyle dikkat çeken EEG tabanlı oyun teknolojileri, yüksek etkileşim sağlama potansiyeline sahip olup, hızla yaygınlaşan eğitim araçları arasında yer almaktadır (Singh ve Sood, 2018).

Belirli olay veya uyaranlara yanıt olarak beyinde üretilen sinyallere, “Olaya Bağlı Potansiyeller (ERP-Event-related potentials)” denilmektedir (Blackwood ve Muir, 1990). Herhangi bir olayın neden olduğu bu beyin sinyalleri, EEG ile kaydedilmektedir ve farklı duyuşsal, bilişsel veya motor etkenlerle meydana gelebilmektedir. Klados vd. (2015) tarafından yüksek matematik kaygısına sahip bireylerin EEG ölçümleriyle yapılan farklı bir çalışmada ise çalışma belleği ve matematiksel işlemlerle ilgili görevler sırasında frontocentral (180-320 ms arasında) ve centroparietal bölgelerde (380-420 ms arasında) ERP voltajlarının azaldığı ifade edilmiştir. Bu bulgular matematiksel işlemler ile beyin sinyalleri arasında ilişkisel bir süreç olduğunu ortaya koymaktadır.

2.4. Yapay Zekâ

Yapay (suni), doğadaki örneklerine benzetilerek insan tarafından üretilmiş olan anlamına gelmektedir (TDK, 2023). Zekâ ise insanın düşünme, akıl yürütme, öğrenme, değerlendirme gibi becerilerinin tümüdür (TDK, 2023). Yapay zekâ kavramının isim babası sayılan McCarthy (2004), yapay zekâyı insana benzetilebilen zeki makineler üretme bilimi ve mühendisliği şeklinde tanımlamıştır. Yapay zekâ, herhangi bir canlıdan faydalanılmadan yapay araçlar ile insana özgü duygu, mantık, öğrenme vb. davranışların gerçekleşmesi için geliştirilen teknolojidir (Nabiyev, 2020). Kısaca yapay zekâ, insan zekasını taklit eden bir temsil olup geniş bir ağla topladığı bilgilerden yararlanarak kendini geliştiren sistemdir. Erbay (2019) ise yapay zekânın bir hücre olarak varsayılması durumunda çekirdeğinin algoritma olarak temsil edilebileceğini belirtmiştir. Algoritma, bir sorunu çözebilmek için kullanılan deneyimler, tekrarlar ve fonksiyonlardan oluşan bir çözüm yoludur (Erbay, 2019).

Yapay zekanın ilk örneği, 14. yüzyılda filozof Raymond Lulle tarafından ortaya atılmış (Dursun, 2023), gelişimini sürdürerek günümüze kadar gelmiştir. Bugünün yapay zekası, insan zekasının yalnızca bir bölümünü simüle edebilir, değiştirebilir, genişletebilir ancak bilinen çalışmaların amacı; akıl yürütme, yargılama, tanımlama, algılama, düşünme, tasarlama ve bir soruna çözüm bulma

gibi faaliyetleri içeren insan benzeri bir zeka üretmek haline gelmiştir (Harika vd., 2022).

1996 yılında dünya satranç şampiyonu Garry Kasparov ile yapay zeka programı arasında gerçekleşen karşılaşma yapay zekaya olan dikkatlerin yoğunlaşmasını sağlamıştır. Yapay zeka ile insan arasında gerçekleşen bu maçta Kasparov kazanırken, 1997 yılında gerçekleştirilen ikinci maçta yapay zeka galip gelmiştir (NTV, 2022). Günümüzde yapay zeka, herkes tarafından bilinen bir kavramdır. Sağlıktan enerjiye, araba kullanımından sesli asistanlara, chatGPT gibi uygulamalara, bunların yanında yazılım, eğitim ve öğretim gibi pek çok alanda kullanılmaktadır. Yapay zekanın eğitim ve öğretim teknolojilerinde kullanımı çok önemli bir gelişmedir (Becker vd., 2018). Yapay zeka ayrıca not verme, performans değerlendirme, sınıf yönetimi, öğretmenin diğer görev ve işlerinde kullanılabilen eğitsel bir teknoloji haline gelmiştir (Arslan, 2020).

Makine öğrenimi, yapay zekanın bir alt kümesi olup ortaya çıkabilecek bir sorunu önceden haber vermek yerine, geliştirilen algoritmalar ile durumu çözebilecek tanımlamalar sunmaktadır (Gürsakil, 2014). Bu algoritmalar, deneyim kazanarak tahminlerden veri grupları oluşturarak duruma uygun çözümler üretebilmektedir. Yapay zeka teknolojileri ile bu teknolojilerle birarada olan makine öğrenmesi ise katılım, motivasyon ve yeni teknolojileri öğrenme isteği gerektiren önemli bir alandır (Rattadilok, 2018). Makine öğrenmesi, geçmişte matematiksel altyapı gerektirmesi ve eski dönemlerde öğrencilerin bilgisayar kullanımındaki bilgi eksiklikleri gibi nedenlerle öğrenciler için öğrenmesi zor bir alandı (Reyes vd., 2020). Ancak günümüzde birçok farklı alana yönelik farklı çözüm önerileri ile hayatı kolaylaştırmayı sağlayan yapay zeka, eğitim ve öğretimin olmazsa olmaz yapı taşlarından bir haline gelmiş ve bu yapı taşına yönelik farklı disiplinlerin de ilgisi artmıştır. Bu doğrultuda Türkiye’de Yüksek Öğretim Kurumu (YÖK) önlisans ve lisans programında yapay zekaya yönelik programlar, bölümler ve dersler açmayı üniversitelerde teşvik etmiştir (Türetken, 2024).

Günümüzde yapay zekanın eğitimde kullanılmasıyla, geleneksel öğretim hibrit öğretime doğru evrilmiş ve bu sayede öğretim sürecinde, öğretmenlerin fiziksel öğretim materyallerine olan ihtiyacı azalmıştır. Öğrenciler, yapay zeka teknolojilerinin eğitimde yaygınlaşması ile her zaman ve her yerde öğrenme, dersleri ile ilgili gerekli bilgileri önceden kavrayabilme, özerk öğrenme sürecinde anlayamadıkları konularda çevrimiçi danışma hizmetlerinden faydalanabilme ve alan uzmanlarına soru sorabilme imkanı bulmuşlardır (Mali ve Huaxi, 2019). Ayrıca, teknolojideki olası gelişmelerle birlikte, yapay zeka uygulamalarının her disiplin alanında daha da yaygınlaşması, eğitim-öğretim alanında kullanım alanlarının genişleyerek çeşitlenmesi ve bu doğrultuda ilköğretimden yükseköğretime kadar eğitimin her kademesinde vazgeçilmez bir unsur haline gelmesi öngörülmektedir.

2.5. Veri Madenciliği

Veri; bir araştırmanın temeli olan ana öge olmakla beraber deney ve gözleme dayalı olan araştırma sonuçlarıdır (TDK, 2023). Savaş (2012), bilginin bir amaca yönelik olarak işlenmiş veri olduğunu ve ham veriye ya da geçmişin bir yansıması olan enformasyona dayalı karar almanın imkânsız olduğunu belirtmiştir. Verilerin miktarı ve karmaşıklığı arttıkça bu verilerin depolanması, alınması ve işlenmesi de zorlaşmakta ve bu nedenle çeşitli, hacimli ve dinamik verilerin işlenmesi zorlayıcı olabilmektedir (Marquardt, 2014). Bu zorlayıcı durum ise çeşitli algoritmaların işe koşulduğu veri madenciliği süreçleri ile aşılmaktadır.


Doğan ve Türkoğlu (2007) veri madenciliğini, bilgisayar programları kullanarak büyük veri yığınları arasından gelecekle ilgili tahminde bulunmamızı sağlayabilecek bağlantı kurma süreci olarak tanımlamıştır. Kalikov (2006) ise, veri tabanı sistemleri içerisindeki saklı bilgilerin açığa çıkarılmasını sağlayan veri analizi tekniği olarak tanımlamıştır. Özetle veri madenciliği, büyük miktarda veriden anlamlı ve gizil bilgiyi keşfetme görevidir.

Veri madenciliği; algoritma, sınıflandırma, kümeleme, ilişkilendirme kuralları, regresyon, özetleme ve anormallik tespiti gibi teknikleri içermektedir. Bu algoritmaların verilen veri kümelerine uygulayıp ve bunları analiz edebileceği

çeşitli tescilli ve ücretsiz açık kaynak kodlu veri madenciliği araçları bulunmaktadır. Keel, KNIME, RapidMiner, Weka, Tanagra ve Orange gibi yazılımlar ücretsiz ve açık kaynaklı veri madenciliği araçlarına birer örnektir. Ücretsiz ve açık kaynaklı yazılımlar, çeşitli veri kaynaklarını kullanarak verileri ön işleyebilme, farklı teknikleri birleştirebilme, büyük veri kümesi üzerinde çalışabilme, verileri modelleyip görselleştirebilme, verileri genişletilebilme ve diğer sistemle birlikte çalışabilme gibi yetkinliklerin birkaçına ya da tamamına sahip olabilmektedir (Chen vd., 2007). Tescilli ve açık kaynak olmayan SPSS, KXEN, Microsoft Analysis Services, SAS Enterprise Miner, STATISTICA ve Oracle Data Mining gibi araçlarda mevcuttur (Dol ve Jawandhiya, 2022).

Veri madenciliği süreçleri genellikle aşağıda sunulan belirli adımlar izlenerek gerçekleştirilmektedir:

1. Seçme: Veri madenciliği süreci için ihtiyaç duyulan birçok farklı ve heterojen veri kaynağından verinin seçilmesidir.
2. Ön işleme: Aykırı ya da eksik değerlerin bulunarak kaldırılmasını içermektedir.
3. Dönüşüm: Verilerin işlenmek üzere ortak bir formata dönüştürülmesidir. Veri ve boyut azaltma gibi teknikler, görüntülü verilerin sayısını azaltmak için kullanılmaktadır.
4. Veri madenciliği: Veri setinden örüntü oluşturmak için gerçekleştirilmektedir.
5. Yorumlama/Değerlendirme: Veri madenciliği sonuçlarının kullanıcıya sunulduğu son aşamadır (Kovalerchuk ve Vityaev, 2005).
6. Veri madenciliğinin etkin ve verimli bir şekilde kullanılmasını sağlayan bu sürece ait adımlar Şekil 2.10' da sunulmuştur.



Şekil 2. 10. Veri madenciliği süreci (Dol ve Jawandhiya, 2022)

Artan veri tabanları ile paralel hesaplama sistemleri, veri madenciliği algoritmalarını kullanarak veri madenciliği uygulamalarında önemli avantajlar sağlayabilmektedir. Veri madenciliği uygulamaları; kümeleme, sınıflandırma ve birliktelik kuralı olarak kategorize edilebilen bilim ve araştırma gibi birçok alanda kullanılmakta olup, e-ticaret, tıp ve duygu analizinde sıklıkla tercih edilmektedir (Shukla vd., 2020). 2012 yılında gerçekleştirilen International Data Corporation (IDC) konferansında, çok sayıda internet uzmanı ve akademisyen, büyük veri ve veri analizi madenciliği teknolojisinin gelecekte kurumsal gelişimin temel rekabet gücünden biri olacağına dikkat çekmiştir. Günümüzde ise bazı araştırmacılar büyük ve çeşitli veri bilgilerinin gün geçtikçe düşük maliyetli, verimli ve hızlı madencilik yoluyla elde edilebileceğini ifade etmiştir (Dong, 2022).


EEG, veri madenciliği kullanarak iki boyut öğrenenlerin bilişsel katılımını makro düzeyde gösterebilmektedir. Daha sonra öğrenme örüntülerini bulmak için bazı istatistiksel ve modelleme yöntemleri uygulanabilmektedir. Ayrıca

davranışsal ve duyuşsal durumlarla oldukça bağlantılı olan zihinsel durum da mikro düzeyde açıklığa kavuşturulabilmektedir (Feng vd., 2021). Geçtiğimiz yüzyıla kadar bilişsel katılımın, “gözlemlenemez” olarak ifade edilme durumu, EEG teknolojileri ile son bulmuştur. Artık, video kodlama ve EEG, veri madenciliği yoluyla hem makro hem de mikro düzeyde kullanılan bütünleşmiş bir gözlem tekniği olarak araştırmacılar tarafından çoğunlukla tercih edilen teknolojiler arasında yerini almıştır (Feng vd., 2021).

2.6. İlgili Alan Araştırmaları

2.6.1. Dijital oyunların eğitsel amaçlı kullanımı üzerinde gerçekleştirilen çalışmalar

Dijital oyunların eğitsel amaçlı kullanımının olumlu etkileri, bu alanda yapılan araştırmaların sayısında belirgin bir artışa yol açmıştır. Bu doğrultuda, “Eğitsel Dijital Oyun” ve “Eğitsel Video Oyun” anahtar kelimeleri “ya da/and” işlemine tabi tutularak son 20 yılda IEEE akademik veri tabanında yayımlanan akademik çalışmalar taranmıştır. Elde edilen yayınlar, beşer yıllık dönemler halinde incelenmiş ve bu dönemlere ait eğitsel dijital oyunlar ile ilgili yapılan çalışmalar Şekil 2.11’de sunulmuştur. Şekil 2.11’den de anlaşılacağı üzere, son yirmi yılda eğitimde dijital oyunların kullanımı ile ilgili araştırmaların sayısı gün geçtikçe artış göstermiştir.



Şekil 2. 11. Son yirmi yılda beşer yıllık dönemler halinde eğitimde dijital oyunların kullanımı ile ilgili yapılan araştırma sayısı

Alanyazında dijital oyunların eğitimde kullanımı ile ilgili çalışmalar incelenmiştir. Hostetter (2002), eğitsel dijital oyunların; akıl yürütme, hafıza stratejileri gibi bilişsel becerileri ve el-göz koordinasyonunu geliştirdiğini, mükemmel bir öğrenme aracı olduğunu ifade etmiştir. Sitzmann (2011), eğitim alanında dijital oyunları tercih etmenin öğrenilen bilgilerdeki kalıcılığı arttırdığını saptamıştır. Öğrencilerin eğitsel dijital oyunları istedikleri kadar oynayabilmelerinin öğrenme üzerinde olumlu etkilere sahip olduğunu, öğrenenlerin bilgi ve beceri düzeyini arttırdığını saptamıştır. Connolly vd. (2012), eğitsel dijital oyunların beceri gelişimi, öğrenme ve derse katılım üzerindeki etkilerini araştırmış ve dijital oyunların bilişsel ve davranışsal olarak öğrenmeye önemli katkıları olduğunu, ayrıca öğrenci motivasyonunu artırarak duyuşsal alanda olumlu sonuçlar sağladığını tespit etmişlerdir. Wouters ve Van Oostendorp (2013) ise dijital oyunların öğrenmeye etkisini inceledikleri araştırmada dijital oyunların öğrenmeyi geliştirdiğini sonucuna ulaşmışlardır. Lin ve Lin (2014), eğitsel dijital oyunların, öğrenenlerin var olan öğrenme potansiyellerini kolaylaştırıp artırdığını belirtmiştir. Nolan ve McBride (2014) yaptıkları çalışmada, ilköğretim ve ortaöğretim eğitiminde eğitsel dijital oyunların kullanılmasının teşvik edilmesini içeren kavramsal bir çerçeve önermiştir. Seng ve Yatim (2014), eğitsel dijital oyunların uygun şekilde kullanıldığında öğrenenler için kendi kendine öğrenme ortamı oluşturabildiğini belirtmiştir. Alan vd. (2016) eğitsel dijital oyunların öğrenenlere işbirlikçi öğrenme, problem çözme, eleştirel ve stratejik düşünme, akıl yürütme gibi yetenekleri kazandırdığını belirtmiştir. Bodnar vd. (2015), mühendislik öğrencileri üzerinde yaptıkları bir çalışmada, eğitsel dijital oyunların öğrenme ve öğrenci tutumları üzerinde olumlu etkileri olduğunu belirtmişlerdir. Boyle vd. (2016), eğitsel dijital oyunların öğrenenlerde sosyal etkileşim, sosyal beceriler ve empati duygusunu geliştirdiğini tespit etmişlerdir. Hainey vd. (2016), 2000 ile 2013 arasında onyediy farklı akademik veri tabanında “ciddi oyunlar”, “simüle oyunlar”, “dijital oyunlar” anahtar kelimelerin taranması ile elde edilen araştırmaları inceleyerek Connolly ve ark. 2012 yılında ve Boyle ve ark. 2015 yılında gerçekleştirdikleri araştırmaların güncelleştirerek yeniden yeni araştırmalar ile yeniden sentezleyerek değerlendirmeler ve çıkarımlarda bulunmuşlardır. Connolly ve ark. (2012)’nin yaptığı çalışmayı baz alarak 105 adet araştırmanın analizi gerçekleştirdiği ve analiz sonucunda matematik ve fen

bilimleri alanındaki oyunlarının sayı olarak fazla olduğunu ve bu disiplinlerde daha çok eğitsel dijital oyunların kullanıldığı sonucuna ulaşmıştır. Seow ve Wong (2016), eğitsel dijital oyunların öğrencileri pasif bir izleyiciden aktif bir katılımcıya dönüştürdüğünü ve bu oyunların öğrencilerin katılımını, motivasyonunu ve başarı puanlarını artırdığını ifade etmişlerdir.

Alexiou ve Schippers (2018), eğitsel dijital oyunların, bireyin bilişsel ve duyuşsal gelişim alanlarına destek olduğunu belirtirken, Awortwe vd. (2019) bu oyunların soyut kavramları görseller ile somutlaştırarak anlamayı kolaylaştırdığını vurgulamışlardır. Huang (2019), eğitsel dijital oyunların, öğrencilerin motivasyonunu ve sorumluluk bilincini arttırdığını ifade etmiştir. Jantakoon (2021), eğitsel dijital oyunların öğrenenlerin hem eğlenmesini hem de bilgilerini pekiştirmesini sağladığını belirtirken, Yang ve Chen (2021) bu oyunların öğrencilerin öğrenme performansını yükselttiğini ve öğrenilen bilgilerin kalıcılığını artırdığını ifade etmişlerdir. Antequera-Barroso vd. (2022), dijital oyunlar öğrenenlerde olumlu duyguları ortaya çıkardığını, López-Fernández vd. (2023) ise bu oyunlar öğrenenler için ilgi çekici ve motive edici olduğunu belirtmişlerdir.

Thai ve arkadaşları (2022), "My Math Academy" adlı oyun tabanlı bir öğrenme uygulamasının anaokulu öğrencileri üzerindeki incelemiş ve bu uygulamanın matematik bilgisi üzerindeki olumlu etkilerini saptamışlardır. Deney grubundaki öğrencilerin başarı puanlarının kontrol grubuna göre daha yüksek olduğu belirlenmiş ve eğitsel dijital oyunların matematik eğitime katkı sağladığı, öğrencilerin matematiğe olan ilgilerini ve özgüvenlerini artırdığı tespit edilmiştir.

2.6.2. Türkiye’de dijital oyunların eğitsel amaçlı olarak kullanımı üzerine gerçekleştirilen araştırmalar

YÖKTEZ veri tabanında 2024 yılı haziran ayında “Eğitsel Dijital Oyun” anahtar kelimeleri ile yapılan taramada tüm yıllarda 16 adet kayıt listelenmiştir. “Eğitsel Video Oyun” kelimesi ile yapılan taramada hiçbir çalışmanın olmadığı görülmüştür. Dergipark veri tabanında 2024 yılı haziran ayında “Eğitsel Dijital

Oyun” anahtar kelimeleri ile yapılan taramada ise tüm yıllarda 13 adet çalışma listelenmiştir. Dergipark veri tabanında “Eğitsel Video Oyun” kelimesi ile yapılan taramada hiçbir çalışmanın olmadığı görülmüştür.

Yıldırım (2016), “Dijital oyun tasarım programlarının eğitimde önemi” başlıklı araştırmasında, Eğitim Fakültesi Bilgisayar Öğretmenliği ve Teknik Bilimler MYO Bilgisayar Teknolojileri Bölümü’nde öğrenim gören 177 öğrenci ile gerçekleştirdiği ankette, öğrencilerin eğitsel dijital oyun tabanlı öğretime yönelik olumlu görüşlere sahip olduklarını ve bu tür oyunlarla öğrenmenin kalıcılığı artırdığını belirtmiştir. Yürekli ve Şahiner (2017), eğitsel dijital oyunların eğitimde tercih edilmesinin sonuçlarını inceledikleri çalışmalarında, bu tür oyunların öğrenci motivasyonunu artırdığını tespit etmişlerdir. Sarıçam (2019) ise “Dijital Oyun Tabanlı STEM (Science, Technology, Engineering, Mathematics) Uygulamalarının Öğrencilerin Stem Alanlarına İlgileri ve Bilimsel Yaratıcılığı Üzerine Etkisi” başlıklı çalışmasında, 6. sınıf düzeyi fen bilimleri dersinde eğitim sürümü içeren Minecraft oyununu kullanarak, eğitsel dijital oyun tabanlı STEM uygulamalarının öğrencilerin bilimsel yaratıcılığını ve STEM alanlarına olan ilgilerini artırdığını ifade etmiştir.

Varinlioğlu vd. (2019), Teos Antik Kenti’nde sanal gerçeklik uygulamaları kullandıkları mobil oyunla öğrenmenin, farklı eğitim geçmişlerine sahip çok sayıda kullanıcı için bile öğrenmeyi geliştirebildiğini ortaya koymuşlardır. Yaşar ve Alkan (2019), eğitimde dijital oyunların nasıl kullanılabileceğini inceledikleri çalışmalarında, eğitsel dijital oyunların geleneksel öğretim yöntemlerinin yerini alarak, öğrenmeyi teşvik ettiğini belirtmişlerdir.

Koparan (2021), “Yükseköğretimde dijital oyun tabanlı öğrenme ortamından yansımaların incelenmesi” başlıklı çalışmasında, 28 matematik öğretmeni adayı ile gerçekleştirdiği özel durum çalışmasında, eğitsel dijital oyunların matematiksel düşünme, öğretimde farklı yöntemlerin kullanımı ve oyun tabanlı öğrenme ortamlarının katkılarını incelediğini belirtmiştir. Bu çalışmada, eğitsel dijital oyunların matematik öğretiminde etkili bir öğrenme ortamı sunduğu ve tartışma, düşünme, iş birliği gibi fırsatlar sağladığı sonucuna ulaşılmıştır.

Özkan (2021), "Dijital oyun tabanlı öğrenme uygulamalarının teknoloji entegrasyonu sürecinde kullanılması" başlıklı çalışmasında, eğitsel dijital oyunların sınıf içi katılımı ve iş birliğini artırdığını belirtmiştir. Savaş ve arkadaşları (2021), Mesleki ve Teknik Anadolu Liselerinin bilişim teknolojileri programında kullanılmak üzere eğitsel bir dijital oyun geliştirdikleri çalışmalarında, dijital materyal hazırlama süreçlerine ve bu süreçlerin literatüre katkısına değinmişlerdir. Öğretmenlerin dijital oyun materyali tasarlama konusundaki zorluklarından ve dijital oyunların eğitim programlarına entegrasyonu konusundaki eksikliklerden bahsedilmiş, ayrıca öğretmen eğitiminde dijital becerilerin yer alması gerektiği vurgulanmıştır.

Özer (2022) ise "Yabancı Uyruklu İlkokul Öğrencilerinin Türkçe Okuma-Anlama ve Yazma Becerilerinin Eğitsel Dijital Oyun Destekli Öğretim Etkinlikleri ile Geliştirilmesi" başlıklı tez çalışmasında, yabancı uyruklu ilkokul öğrencilerinin Türkçe okuma-anlama-yazma yeteneklerini geliştirmek amacıyla eğitsel dijital oyunlar kullanmıştır. Bu çalışmada, eğitsel dijital oyunların Türkçe okuma-anlama ve yazma yeteneklerini olumlu yönde etkilediği sonucuna ulaşılmıştır.

2.6.3. Dijital matematik oyunlarının eğitsel amaçla kullanıldığı çalışmalar

Ke (2008)' de yaptığı araştırmada, eğitsel dijital oyunların öğrencilerin matematik eğitimine olan tutumlarına etkisini incelediği çalışmasında öğrenci tutumları üzerinde çok olumlu bulgular elde ettiğini belirtmiştir. Shin vd. (2011), yaptıkları araştırmada, eğitsel dijital aritmetik oyunu oynayan öğrencilerin, kağıt kullanarak aritmetik oyunu oynayan öğrencilere göre daha iyi başarımlar gösterdiğini saptamışlardır. Pratama ve Setyaningrum, 2018'de "GeoGame Macera" adlı eğitsel dijital oyununu ortaokul 8.sınıf öğrencilerinin sınıfta kullanmasıyla yaptıkları araştırma sonucunda, eğitsel dijital oyun kullanımının matematik sonuç puanlarını artırdığını belirtmişlerdir.

Tokaç vd. (2019), "Oyun Temelli Öğrenmenin Öğrencilerin Matematik Başarısı Üzerindeki Etkileri: Bir Meta-Analiz" adlı çalışmada, K-12 düzeyindeki

öğrencilerin derslerinde eğitsel dijital matematik oyunlarının kullanımının, geleneksel ders işleme yöntemlerine kıyasla matematik başarısını artırdığını göstermiştir.

Di Sun vd. (2021), yaptıkları çalışmada; eğitsel dijital oyun kullanılan eğitimin, öğrencilerin aritmetik yetenek, başarı puanları ve matematiğe olan ilgilerini artırdıklarını tespit etmişlerdir. Kärki vd. (2022), "NanoRoboMath" isimli eğitsel dijital oyununun 5. ve 6.sınıf öğrencileri ile yapılan matematik derslerinde kullanımıyla rasyonel sayılar konusunun öğretiminin üzerindeki etkilerini araştırmayı hedeflemiştir. Araştırmacılar eğitsel dijital matematik oyunlarının rasyonel sayılar konusunun anlaşılmasında olumlu katkılar saptadıklarını belirtmişlerdir.

Poçan (2023) ise "Matematik Eğitiminde Dijital Oyun Tabanlı Öğrenme Üzerine Bibliyometrik Analiz" başlıklı araştırmasında, 1996-2022 yılları arasında Web of Science veri tabanında yayımlanmış 177 çalışmanın bibliyometrik analizini yapmıştır. Bu analizde, eğitsel dijital oyunların matematik eğitiminde kullanımının yaygınlaştığı, bu oyunların bilişsel ve duyuşsal etkilerinin araştırıldığı, ancak uygulamaların sorunsuz bir şekilde gerçekleşmesi için öğretmen ve ebeveyn denetiminin gerekli olduğu sonucuna ulaşılmıştır. Ayrıca çalışmada, "video oyunu" teriminin yerini giderek "dijital oyun" teriminin aldığı belirtilmiştir.

Her ne kadar eğitsel dijital oyunların öğrenme üzerinde olumlu etkileri olduğu alanyazında yaygın olarak vurgulansa da Türkiye ve dünya genelinde eğitimcilerin çoğunluğunu oluşturan Y kuşağı ve önemli bir kısmını oluşturan X kuşağı öğretmenler arasında dijital becerilerde büyük farklılıklar bulunmaktadır (OECD, 2020c). Bu durum, dijital oyunların eğitimde yaygınlaşmasını geciktirebilir. Dijital yetenekleri sınırlı olan eğitimcilerin yanı sıra, birçok programı kullanabilen ve kodlama bilgisine sahip olan, hatta eğitsel dijital oyun geliştirebilen öğretmenler de bulunmaktadır. Ancak, eğitsel dijital oyunların eğitim programlarına ve kazanımlara uyumlu oyun sayısının azlığı, bu tür

oyunların öğretimde rutin olarak kullanılmasını zorlaştırmaktadır (Sánchez-Mena ve Martí-Parre, 2017).

Alanyazında, eğitsel dijital oyunların bir öğretim metodu olarak kullanılmamasının nedenlerini inceleyen çalışmalar mevcuttur. Bu çalışmalar, eğitimcilerin sınıf içinde eğitsel dijital oyunları ne ölçüde rutin hale getirdiğini araştırmakta ve okullarda öğrenme faaliyetlerine uyum sağlamak için daha güvenilir pedagojik yöntem ve yaklaşımlar geliştirme arayışında olduklarını ortaya koymaktadır (Can ve Çağıltay, 2006; Demirbilek ve Tamer, 2010; De Grove vd., 2012; Bourgonjon vd., 2013; Emin-Martinez ve Ney, 2013; Graafland vd., 2012; Hamari ve Nousiainen, 2015; Bado, 2022).

2.6.4. EEG ile ilgili yapılmış çalışmalar

EEG (Elektroensefalogram) tabanlı çalışmalar; dijital oyunlar, bilişsel performans ve duygusal durumların analizi gibi alanlarda önemli sonuçlar ortaya koymaktadır. Chandra ve arkadaşları (2016), "Tom Clancy's Rainbow Six: Vegas 2" adlı tek oyunculu aksiyon video oyununu beş oyuncuya oynatarak EEG verileri toplamış ve oyuncuların bilişsel yetenekleri ile performanslarındaki değişiklikleri analiz etmişlerdir. Bu çalışmada K-En Yakın Komşu (kNN) ve Doğrusal Diskriminant Analizi (DDA) sınıflandırıcıları kullanılmış ve elde edilen veriler, antrenmanın oyuncuların tepki hızlarını artırdığını, bilişsel yeteneklerini geliştirdiğini ve stres düzeylerini azalttığını göstermiştir.

Raju ve arkadaşları (2016), Emotiv nöroheadset adlı EEG cihazı ile yakaladıkları sinyalleri Bluetooth aracılığıyla dizüstü bilgisayara aktararak MATLAB ile arayüz oluşturmuş ve uykusuzluk sorunlarını teşhis etmeye yönelik bir çalışma gerçekleştirmişlerdir. Bu çalışmada, MATLAB yazılımının EEG verilerini kullanarak uykusuzluğu teşhis etmede etkili olduğu tespit edilmiştir.

Yang ve arkadaşları (2018), dijital oyunlar sırasında yaşanan psikofizyolojik tepkilerin duygusal durumlarla ilişkisini incelemişlerdir. EKG, EMG ve diğer biyosinyallerle birlikte oyun ekran kayıtları, oyunun zorluk derecesi ve başarı

puanları gibi veriler toplanmış ve makine öğrenimi teknikleri kullanılarak yüksek uyarılma durumlarının daha iyi tespit edilebilir olduğu sonucuna varılmıştır. Araştırmada, EMG sinyallerinin duygu algısında en iyi performansı gösterdiği, en güvenilir sonuçların ise ACC ve EKG'den elde edildiği belirlenmiştir.

Moghimi ve arkadaşları (2020), duyuşsal bir sanal ortamda 30 katılımcının EEG, GSR ve kalp hızını sınıflandırarak bir psikofizyolojik veri tabanı oluşturmuşlardır. Bu çalışmada, fizyolojik sinyallerden çıkarılan 743 öznitelik 30'a indirgenmiş ve dört farklı sınıflandırma tekniği (kNN, SVM ve sınıflandırma ağacı) kullanılmıştır. Sonuçlar, duyguların sınıflandırılmasında KNN ve SVM algoritmalarının çok yüksek bir başarı gösterdiğini ortaya koymuştur.

Torres ve arkadaşları (2020), 2015-2020 yılları arasında EEG tabanlı duygu tanıma çalışmaları üzerine bir alanyazın incelemesi yapmışlar ve bu çalışmalarda kullanılan algoritmaların eğilimlerini ve karşılaştırmalı analizini gerçekleştirmişlerdir. Bu incelemede, veri kümeleri, özellik çıkarma ve seçme, duygu tespiti, sınıflandırma algoritmaları ve performans değerlendirmelerine yönelik yorumlar yapılmıştır.

Koç (2022), "Video Oyun Yaş Etiketlerinin Çok Modlu Biyosinyaller ve Yapay Zeka ile Tahmini" başlıklı tez çalışmasında, gönüllülerin aksiyon türündeki popüler video oyunlarının tanıtım videolarını izlerken EEG, oksimetre, GSR ve hareket sensörleri aracılığıyla biyosinyal ölçümleri yapmış ve bu verilerle bir yaş etiketleme sistemi geliştirmiştir. Geliştirilen sistem, manuel yaş etiketlemesiyle karşılaştırıldığında biyosinyaller ve yapay zeka ile yaş etiketlemesinin yüksek düzeyde başarılı olduğunu göstermiştir.

Aslan (2023), "Derin Öğrenme Algoritmaları Kullanılarak EEG Sinyallerinden Yalan Tespiti" adlı tezinde, yalan tespiti için EEG sinyallerinin işlenmesini ve derin öğrenme algoritmaları kullanılarak sınıflandırılmasını amaçlamıştır. Bu çalışmada, LieWaves adlı bir EEG yalan veri seti oluşturulmuş ve çeşitli yöntemlerle ön işleme tabi tutulmuştur. Sonuçlar, EEG sinyallerinden yalan

tespiti yapılabileceğini ve belirli yöntemlerin bu amaçla daha etkili olduğunu ortaya koymuştur.

2.6.5. EEG ile ilgili eğitim alanında yapılan çalışmalar

EEG ile ilgili eğitim alanında yapılan çalışmalar, beyin sinyallerinin öğrenme süreçleri, bilişsel yük ve dikkat düzeyleri gibi çeşitli eğitim parametreleri üzerindeki etkilerini incelemiştir. Di Stasi ve arkadaşları (2013), helikopter pilotlarının uçuş egzersizleri sırasında EEG sinyallerini analiz ederek, zorlu uçuş görevlerinde EEG bant güçlerinde artış gözlemlemişlerdir. Uçuş egzersizleri sırasında ise bu bant güçlerinde bir düşüş tespit edilmiştir, bu da görev zorluğunun beyin aktivitesi üzerindeki etkisini ortaya koymuştur.

Aghajani ve ekibi (2017), EEG ve fNIRS tekniklerini birleştirerek insan zihinsel iş yükünü (MWL) ölçmek amacıyla bir çalışma gerçekleştirmiştir. Katılımcılara verilen çalışma belleği ve n-geri harf görevleri sırasında EEG ve fNIRS ile biyoelektriksel sinyaller kaydedilmiş, bu sinyaller SVM algoritması ile sınıflandırılmıştır. Sonuçlar, bu hibrit modelin, sadece EEG veya sadece fNIRS ile yapılan sınıflandırmalara kıyasla zihinsel iş yükleri arasında daha iyi bir ayrım yapabildiğini göstermiştir.

Ülker (2017), "EEG Biyosensör Kullanılarak Dikkat ve Meditasyon Oranlarının Öğrenmeyle İlişkilendirilmesi" adlı tez çalışmasında, lise öğrencilerinin ders çalışırken EEG ile kaydedilen beyin sinyallerini analiz etmiş ve öğrencilerin başarılı olduğu derslerde dikkat ve meditasyon seviyelerinin daha yüksek olduğunu tespit etmiştir.

Ay (2023), "Sinyal Ayırıştırma Teknikleri ve Derin Öğrenme Modeli Kullanılarak EEG Sinyallerinden Zihinsel İş Yükünün Otomatik Tespiti" adlı tezinde, katılımcıların zihinsel iş ve dinlenme durumlarındaki değişimleri EEG sinyalleriyle ölçmüştür. Aritmetik görevler sırasında kaydedilen EEG sinyallerine DWT ve EMD yöntemleri uygulanmış ve belirli bantların güç spektral

yoğunlukları hesaplanmıştır. Çalışmanın sonunda, DWT+Welch yönteminin en yüksek doğruluk değerlerini sağladığı belirlenmiştir.

Hızar (2023), "GO/NOGO Testi ile EEG Verilerinin Destek Vektör Makineleri, Doğrusal Ayırma Analizi ve Rastgele Orman Algoritmaları ile Sınıflandırılması" adlı tezinde, dikkat durumunu izlemek amacıyla bir Go/NoGo testi gerçekleştirmiş ve EEG verilerini Python kullanarak sınıflandırmıştır. Çalışma, beyin sinyallerindeki frekans bantlarındaki değişimlerin uyku ve zihinsel çalışmalarla bağlantılı olduğunu ortaya koymuştur.

Keleş (2023), "EEG Sinyalleri Kullanılarak Yeni Nesil Cümle Sınıflandırma Modellerinin Geliştirilmesi" adlı tezinde, EEG sinyalleriyle cümle sınıflandırması yapmak üzere bir veri seti oluşturmuştur. 40 gönüllüden 1600 EEG sinyali toplayarak, bu verileri sınıflandırmak için çeşitli makine öğrenme yöntemleri kullanmış ve yüksek doğruluk oranlarına ulaşmıştır.

Kuduz (2023), "Etkileşimli Kitap Okuma Programının İşitme Yetersizliği Olan 6 Yaş Grubu Çocukların Dikkat ve Anlama Seviyelerine Etkisinin Mobil EEG Cihazı Kullanılarak Ölçülmesi" adlı tezinde, işitme cihazı kullanan çocukların beyin sinyallerini EEG ile kaydederek, etkileşimli okuma programının geleneksel okuma programından daha geniş bir frekans bandında ve daha yoğun bir beyin aktivitesi sağladığını göstermiştir. Bu çalışmalar, EEG'nin eğitim alanında dikkat, bilişsel yük, meditasyon ve öğrenme süreçlerini anlamak için nasıl kullanılabileceğine dair önemli bulgular sunmaktadır.

2.6.6. Matematik eğitiminde EEG verilerinin analizi ile ilgili yapılan çalışmalar

Matematik eğitiminde EEG verilerinin analizi ile ilgili yapılan çalışmalarda, EEG verilerinin eğitim süreçlerine entegrasyonu ve öğrencilerin bilişsel performanslarının ölçülmesi üzerine önemli bulgular elde edildiği görülmektedir. Yıldırım ve Varol (2013), "Beyin Dalgalarıyla Dikkat ve Meditasyonu Ölçen Eğitsel Oyun Yazılımı Geliştirme: Zihin Matematiğini

Eşleştirme" adlı çalışmalarında, dikkat ve meditasyon değerlerini ölçen bir eğitsel oyun geliştirmeyi hedeflemişlerdir. Bu amaçla "Matching Mind Math (MMM)" isimli yazılımı geliştirerek, öğrencilerin oyunu oynarken beyin dalgalarını NeuroSky MindWave Mobile cihazıyla ölçmüşlerdir. Araştırma, öğrencilerin oyun sırasında dikkat ve meditasyon seviyelerinin tespit edilmesi üzerine odaklanmış ve literatürde beyin dalgaları ile kontrol edilebilen eğitici oyunların yetersiz olduğuna dikkat çekmiştir.

Kober ve arkadaşları (2020) ise "Oyun Tabanlı Öğrenme Ortamlarının Ön Beyin Aktivitesine Etkileri" adlı çalışmalarında, sayı doğrusu tahmin görevini oyun tabanlı ve oyun tabanlı olmayan versiyonları ile gerçekleştirirken beyin aktivasyon modellerini karşılaştırmışlardır. Çalışma, oyun öğelerinin eklenmesinin, beyin alanlarında daha güçlü bir aktivasyona yol açtığını ve oyun tabanlı öğrenmenin nöronal bağıntılarını araştırmak için önemli veriler sunduğunu göstermiştir.

Roy ve arkadaşları (2015), iki ve altı basamaklı sayıları ezberleme görevinde zihinsel iş yükünü EEG ile ölçülen beyin aktiviteleri üzerinden tahmin etmeyi amaçlamışlardır. LDA algoritmaları kullanarak zihinsel iş yükünü düşük ve yüksek olmak üzere iki düzeyde sınıflandırmışlar ve ERP potansiyelleriyle temel bileşen analizi (PCA) ve kanonik korelasyon analizi (CCA) yaparak xDAWN algoritmaları ile EEG verilerini filtrelemişlerdir.

Verkijika ve De Wet (2015), "Matematik Kaygısını Azaltmak için Beyin-Bilgisayar Arayüzünün (BBA) Kullanılması: Güney Afrika'dan Kanıtlar" adlı çalışmalarında, "Math-Mind" isimli eğitsel dijital matematik oyununu geliştirerek, öğrencilerin bu oyunu oynarken Emotiv EPOCH nöro-başlığı ile gerçek zamanlı beyin aktivitelerini yakalamayı amaçlamışlardır. Çalışmada, oyunun öğrencilerin kaygı düzeylerini kontrol etmelerine yardımcı olduğu ve BBA tabanlı eğitsel dijital matematik oyunlarının matematik kaygısını azaltmada etkili olabileceği belirtilmiştir. Bu çalışmalar, matematik eğitiminin daha etkin ve öğrenci odaklı hale getirilmesi için EEG verilerinin nasıl kullanılabileceğine dair önemli katkılar sunmaktadır.

3. YÖNTEM

3.1. Araştırma Modeli

Bu çalışmanın araştırma modeli, beynin oyun esnasında verdiği tepkilerin değerlendirilmesi üzerine kurulmuştur. Araştırma, EEG (Elektroensefalografi) sinyalleri aracılığıyla elde edilen verilerin, eğitim amaçlı dijital oyun performansı ile ilişkilendirilmesi ve bu performansın tahmin edilmesi amacını taşımaktadır. Araştırma modeli aşağıdaki ana aşamalardan oluşmaktadır:

1. Uyarın Modülü: Katılımcılara, eğitim amaçlı olarak tasarlanmış dijital bir matematik oyunu sunulmuştur. Bu oyun, katılımcıların bilişsel ve motor becerilerini ölçmek ve değerlendirmek amacıyla tasarlanmıştır.
2. Sinyal Toplama: Oyun oynanırken, katılımcıların beyin aktiviteleri Emotiv EEG cihazı kullanılarak kaydedilmiştir. Beyin dalgaları, özellikle bilişsel süreçlerle ilgili olan Gamma ve Beta dalgaları üzerine odaklanılmıştır. Bu sinyaller, 128 Hz hızında kaydedilmiş ve büyük bir veri havuzu oluşturulmuştur.
3. Ön İşleme: Toplanan EEG sinyalleri, ham veri olarak analiz edilmeden önce çeşitli ön işleme adımlarından geçirilmiştir. Bu adımlar arasında, eksik veri temizliği, sinyal normalizasyonu ve gürültü azaltma teknikleri yer almaktadır. Bu süreç, elde edilen verilerin doğruluğunu artırmak ve analiz için uygun hale getirmek amacıyla gerçekleştirilmiştir.
4. Öznitelik Çıkarma: EEG sinyallerinden anlamlı verilerin elde edilmesi amacıyla öznitelik çıkarma işlemi uygulanmıştır. Bu aşamada, beynin farklı bölgelerinden elde edilen sinyaller arasından oyun performansını tahminlemede belirleyici olmayan öznitelikler belirlenmiştir.
5. Ayırt Adici Öznitelik Seçme: Özellik çıkarma işlemi sonrasında, hangi sinyallerin oyun performansını tahmin etmede en etkili olduğu belirlenmiştir. X^2 (ki-kare) fonksiyonu kullanılarak yapılan bu işlemde, en iyi ayırt edici özellikler sıralanmış ve daha sonra sınıflandırma algoritmalarında kullanılmak üzere en iyi ayırt edici beş öznitelik seçilmiştir.
6. Sınıflandırma Algoritmaları: Seçilen öznitelikler, farklı makine öğrenmesi algoritmaları (k-Nearest Neighbors (kNN), Support Vector Machine (SVM),

Random Forest (RF), AdaBoost, Gradient Boosting, Neural Network (NN), Stochastic Gradient Descent (SGD)) kullanılarak katılımcıların oyun performansı tahmin edilmiştir.

7. Performans Değerlendirme: Son olarak, kullanılan algoritmaların performansı, AUC (Area Under Curve) değeri ile ölçülmüştür.

3.2. Araştırmanın Çalışma Grubu ve Araştırma Ortamı

3.2.1. Çalışma grubu seçimi

Bu çalışma, 18 yaş üstü ve gönüllü, bilgisayar mühendisliği bölümünde öğrenim görmekte olan 20 katılımcı ile gerçekleştirilmiştir. Katılımcı seçimi, araştırmanın hedef grubuna uygun bireylerin kolay ve hızlı bir şekilde seçilmesini sağlayan elverişli örnekleme yöntemi ile gerçekleştirilmiştir. Elverişli örnekleme, belirli bir popülasyondan rastgele seçim yerine, araştırmacının erişim sağladığı ve çalışmaya gönüllü olarak katılmayı kabul eden bireylerden oluşan bir örneklem oluşturarak zaman ve kaynakların etkin kullanımını sağlamaktadır (Robinson, 2014). Bu yöntemle, araştırmanın amaçlarına uygun veri toplama süreci hızlandırılmış ve eğitsel dijital matematik oyununun oynanması sürecinde EEG verilerinin kayıt altına alınması kolaylaştırılmıştır. Katılımcılar, eğitim seviyeleri ve çalışma kapsamında belirlenen hedef özellikleri göz önünde bulundurularak seçilmiştir. Bu sayede, belirli bir öğrenci grubu ile çalışma yürütülmüş olup, eğitsel dijital oyunların etkilerini analiz etmek için yeterli veri elde edilmiştir.

Araştırmada kullanılan EEG cihazının taşınabilir olması, katılımcıların daha rahat bir ortamda veri toplamalarını sağlamış ve bu durum, gürültülü verilerin miktarını azaltmıştır. Ancak taşınabilir EEG cihazlarının, saç yoğunluğu fazla olan bireylerde elektrotların kafa derisine temasındaki zorluklar nedeniyle veri toplama sürecinde olumsuzluklara yol açabileceği göz önünde bulundurulmuştur. Bu nedenle, veri toplama sürecindeki olası hataları minimize etmek amacıyla, katılımcıların tamamı erkek bireylerden seçilmiştir. Ayrıca, EEG sinyallerini beyin ile ilişkili hastalıklar etkileyebilmektedir. Bu nedenle katılımcı seçiminde; beyin travması, görme bozukluğu, psikiyatrik ve nörolojik hastalık

geçmişı bulunmayan, ilaç kullanmayan, deney sürecinde herhangi bir hastalıđı olmayan bireyler tercih edilmiştir.

Ana deneyler başlamadan önce, 3 katılımcı ile eğitim ve test amaçlı bir ön deney gerçekleştirilmiştir. Bu ön deney sırasında elde edilen veriler, EEG cihazının tanınması ve kalibrasyon amacıyla kullanılmış olup, araştırma verilerinin analizine dahil edilmemiştir. Dolayısıyla, veri analiz süreci 17 katılımcıya ait veriler üzerinden yürütölmüştür.

3.2.2. Deney ortamı ve şartları

Deney öncesinde katılımcılara, deneyin amacı ve işleyişı hakkında detaylı bilgi verilmiş ve deneyle ilgili yönergeleri içeren "Gönüllü Katılım Formu" dağıtılarak yazılı onamları alınmıştır (EK A). Deneyin ardından, katılımcılara deney sonrası bilgilendirme amacıyla "Katılım Sonrası Bilgilendirme" formu (EK B) sunulmuştur. Ayrıca, deneyin sağlıklı bir şekilde gerçekleştirilebilmesi için katılımcılardan deney günü ve bir gün öncesinde alkol tüketmemeleri, deney sırasında tok olmaları ve EEG sinyallerinin kalitesini artırmak amacıyla saçlarını yıkayıp herhangi bir saç bakım ürünü kullanmamaları istenmiştir. Deney öncesinde, katılımcılara tek kullanımlık taraklar dağıtılmış ve saçlarını taramaları sağlanmıştır.

Deney sırasında katılımcılara rahat bir sandalye sağlanmıştır. Her katılımcı için aynı ortamda EEG sinyali kaydedilmiştir. Deneyler, sabit bir oda sıcaklığı (23°C) sağlanan klimalı bir odada gerçekleştirilmiştir. Deney sürecinde kullanılan bilgisayar, Intel® Raptor Lake Core™ i9 işlemci, 64 GB RAM ve 16 GB ekran kartı hafızasına sahip bir dizüstü bilgisayardır. EEG cihazı, bu bilgisayara kablosuz olarak bağlanmış ve veriler Emotiv firmasına ait Emotiv Pro öğrenci lisanslı yazılımı ile kaydedilmiştir. Deney süresince her katılımcı, yaklaşık 4 dakika boyunca Wordwall platformunda tasarlanmış eğitsel dijital matematik oyunu "Labirent"i oynamıştır. Bir katılımcıdan ortalama 3 dakika 25 saniye boyunca EEG verisi toplanmıştır.

3.3. Veri Toplama Araçları

3.3.1. EEG cihazı ve özellikleri

Bu tez çalışmasında beyin sinyal kayıtları 14 kanallı kablosuz Emotive™ EPOCH adlı EEG cihazı ile toplanmıştır. Emotiv EPOCH neuroheadset, Emotiv APP mağazasında satılan çeşitli sanal ortamlar ve oyunlar için geliştirilmiş bir nöro başlık setidir. EPOCH üzerindeki elektrotların, EPOCH kit setinde bulunan, dezenfektan görevi de gören bir salin solüsyonuyla hafifçe nemlendirilip takılması gerekmektedir.

Emotive EPOCH yardımı ile beyin sinyallerinin alınabilmesi için sensörlerin konumlandırılması uluslararası 10–20 metoduyla yapılmıştır. Bu çerçevede, 14 kanallı EEG cihazının cihazının elektrotları, katılımcıların kafa derisinin tepe noktası ve birincil görsel korteksinin (Fz, Cz, Pz, Oz, P3, P4, O1 ve O2) etrafına yerleştirilmiştir. Elektrotların yerleştirilmesi, görsel uyaranlara karşı beyin tepkisi olarak bilinen P300 potansiyelini gözlemlemeye yönelik olarak belirlenmiştir. Bu yerleşimle, beyin ön, çevresel, oksipital ve temporal bölgeleri kapsamıştır. Her iki yarım küre için referans elektrot görevi gören ek bir elektrot da mevcuttur. EEG verileri ise 128 Hz örnekleme hızında kaydedilmiş olup, EEG sinyallerine ait bant genişliği 0,2-45 Hz arasında olacak şekilde ayarlanmıştır.

3.3.2. Eğitsel dijital matematik oyunu: “Labirent”

Bu çalışmada katılımcılara oynatılan eğitsel dijital matematik oyunu, Wordwall platformunda bu araştırmada kullanılmak üzere tasarlanmış olan online “Labirent” oyunudur.

Yapılan eğitsel dijital oyun tasarımında, oyuncuların oyun oynayıp eğlenirken kazanımları öğrenmesi hedeflenmiştir. Oyunda katılımcıların tamamının bilgi sahibi olduğu temel matematik becerilerini içeren kazanımlar kullanılmıştır. Sorular her oyuncunun karşısına farklı ve rastgele sıralarda çıkmaktadır. Oyuncu doğru yanıtlar verdikçe labirent zorluk seviyesi değişmektedir. Ayrıca her doğru yanıtta açılan yeni labirente oyuncunun elenmesine sebep olabilecek yeni bir

avatar eklenmektedir. Oyuncunun doğru yanıtı ulaşırken avatarlardan kaçması ve onlara değmemesi gerekmektedir. Labirentin yol güzergahında birden fazla yanıt olabilecek sayı bulunduğundan oyuncuların öncelikle düşünerek doğru yanıtı bulup labirentte doğru cevaba doğru ilerlemesi gerekmektedir. Bu oyunda avatarlardan kaçarken, labirentteki zorlu yol güzergahı esnasında, sorunun doğru yanıtını düşünürken yaşanan heyecan yarışmacıya ekstra duygu ve deneyimler yaşatmaktadır.

Hedef: Temel matematik eğitimi becerilerine yönelik belirlenen kazanımlarının kazandırılması.

Senaryo: Karakterin labirent içinde diğer avatarlardan kaçarak birden fazla seçenek içerisinden doğru yanıtı ulaşmasıdır. Oyun 5 soru boyunca devam etmektedir. Sorular doğru cevaplandığı takdirde yeni ve farklı bir labirent açılmaktadır. Her doğru cevap sonrası ekranda yeşil bir “tick” işareti çıkmakta ve “Doğru” şeklinde bir geribildirim verilmektedir. Oyunda oyunculara toplam 10 can hakkı verilmekte ve ekranda kalp simgeleriyle gösterilmektedir. Her yanlış cevap sonrasında veya karakterin avatarlara dokunma durumunda can hakkı azalmaktadır. Yanlış cevap sonrası ekranda kırmızı renkte “Yanlış” yazısı çıkmakta, yeni labirent açılmamakta, oyun aynı labirent ve aynı soruyla doğru cevap bulunana kadar can hakları yettiği sürece devam etmektedir. Oyuncunun sahip olduğu can hakları bittiğinde oyun bitmektedir.

Labirent oyununda oyunculara sorulmuş olan sorular:

- 1) Hangisi asal sayıdır?
- 2) İki basamaklı en küçük tam sayı kaçtır?
- 3) En büyük negatif tam sayı kaçtır?
- 4) Karesi 9 olan sayı kaçtır?
- 5) Dik açı kaç derecedir?

Kazanım Listesi:

- 1) Asal sayıları özellikleriyle belirler.
- 2) Tam sayıları karşılaştırır ve sıralar.
- 3) Tam sayıları karşılaştırır ve sıralar.
- 4) Bir doğal sayının kendisiyle tekrarlı çarpımını üslü ifade olarak yazar ve değerini hesaplar.
- 5) 90° 'lik bir açıyı referans alarak dar, dik ve geniş açıları oluşturur; oluşturulmuş bir açının dar, dik ya da geniş açılı olduğunu belirler.

Zaman: Oyunda herhangi bir zaman kısıtlaması bulunmamakla beraber sol üst köşede zaman ölçer bulunmaktadır. Katılımcıların soruları okumadan geçmemesi ve şans faktörüne engel olması açısından süre kısıtlaması getirilmemiştir. Oyuncuların yanıtları hızlı bir şekilde bulup tüm labirentleri tamamlaması oyuncunun skor tablosunda öne çıkmasını sağlamaktadır. Skor tablosunda sadece oyunda tüm soruları doğru cevaplayıp, oyunu can hakkı bitmeden bitiren oyuncular yer almaktadır. Skor tablosu oyunu en kısa sürede bitiren oyuncu en üst sırada olacak şekilde düzenlenmektedir. Dolayısıyla oyunu kısa sürede bitirmek önemli olmaktadır.

Kurallar: Oyuncunun 10 oyun hakkı süresince 5 soruya doğru yanıt vererek can hakları bitmeden tüm labirentleri tamamlaması.

Şekil 3.1'de görüldüğü üzere oyuncudan alt-üst-sağ-sol yönlerle giderek soruların doğru yanıtı ulaşması ve labirentteki zorlu yolculuğu elenmeden tamamlaması istenmektedir.



Şekil 3. 1. Wordwall labirent oyunu ekran görüntüsü

Şekil 3.2’ de görüldüğü üzere oyuncuya ait süre, puan, doğru yanıt bilgisi ve sorular ekran üzerinde bulunmaktadır.



Şekil 3. 2. Wordwall labirent oyunu ekran görüntüsü

Şekil 3.3 ve Şekil 3.4 ‘te görüldüğü gibi oyun sonunda oyuncuya geribildirim verilmektedir. Oyun sonunda oyuncu isterse yanlış yaptığı soruların doğru yanıtlarını öğrenebilmektedir. Ayrıca diğer oyuncular arasındaki sıralama bilgisi, oyunu bitirme süresi gibi bilgiler de yer almaktadır. (Şekil 3.5.)



Şekil 3. 3. Wordwall labirent oyunu oyun sonu geri bildirim ekran görüntüsü



Şekil 3. 4. Wordwall labirent oyunu oyun sonu geri bildirim ekran görüntüsü

Şekil 3.4'te görüldüğü üzere oyuncular, oyunu tamamladıktan sonra eğer isterlerse yanlış yanıtladıkları soruların doğru cevaplarını inceleyebilmektedir.

Skor Tablosu

Sıra	Adı	Skor	Zaman
1	KAZANDIM YAŞASIN 1.	5	1:41
2	dn_2	5	1:43
3	64	5	1:47
4	Akil	5	1:50
5	Meva	5	1:52

Daha fazla göster ▼

Şekil 3. 5. Wordwall labirent oyunu oyuncularının skor tablosu

Yukarıdaki skor tablosunda görüldüğü üzere katılımcıların KVKK (Kişisel Verileri Koruma Kanunu) doğrultusunda, kişisel verilerini anonimleştirmek amacıyla oyuncuların serbest bir şekilde çeşitli mahlaslar belirlemesi sağlanmış bu sayede deney sürecinin tarafsızlığı korunmuş ve kişisel verilerin gizliliği sağlanmıştır.

3.3.3. Veri toplama süreci

Veri toplama süreci, Süleyman Demirel Üniversitesi Fen ve Mühendislik Bilimleri Etik Kurulu'ndan alınan 28.03.2023 tarihli ve 72/4 sayılı resmi onay (EK C ve EK D) ile gerçekleştirilmiştir. Deney sırasında katılımcılara rahat bir oturma düzeni sağlanmış ve her katılımcının EEG sinyalleri aynı ortamda kaydedilmiştir. EEG sinyal alımı sırasında senkronizasyon hatalarının oluşmaması için dikkatli bir gözlem yapılmıştır. Her katılımcıya oyunu oynaması için bir tur verilmiş ve her turun sonunda katılımcının puanı manuel olarak kaydedilmiştir. Katılımcıların mobil oyunu oynarken harcadıkları ortalama süre 3 dakika 25 saniye olarak kaydedilmiştir. Şekil 3.6'da gönüllülerin eğitsel dijital matematik oyununu oynarken çekilmiş fotoğrafları sunulmaktadır.



Şekil 3. 6. Gönüllülerin eğitsel dijital matematik oyununu oynama durumundaki fotoğrafları

Deneyde doğru ve güvenilir sonuçlar elde edebilmek için standart bir yönerge hazırlanmış ve tüm katılımcılar bu yönergeye uygun şekilde deneye tabi tutulmuştur. Bu adımlar ise aşağıda listelenmiştir:

- ✓ Katılımcılara, oyun ve EEG cihazı hakkında ayrıntılı bilgi verilmesi,
- ✓ Deneyin amacı, oyunun nasıl ilerleyeceği, sürenin sistematik hata oluşumunu önleme açısından önemi ve deneyin ciddiyeti üzerine ilgili bilgilerin sunulması,
- ✓ Oyunda hangi tuşların kullanılacağı konusunda oyunculara gerekli açıklamaların yapılması,

- ✓ Bilgisayar ve EEG cihazının bağlantılarının sağlanması ile kurulum tamamlandıktan sonra sinyal seviyelerinin beklenen düzeye getirilmesi,
- ✓ Emotiv EPOCH marka EEG cihazının katılımcıların kafa derisine yerleştirilmesi,
- ✓ Katılımcılara bu araştırma kapsamında tasarlanıp geliştirilen “Labirent” isimli eğitsel dijital matematik oyununun oynatılması,
- ✓ Her katılımcının oyunu tamamlama süresi ile elde ettiği puanların kaydedilmesi.

3.4. Veri Analizi

3.4.1. Oyun performans puanının hesaplanması

Oyunda her doğru yanıt 1 puan kazandırmaktadır. Tüm sorulara doğru yanıt veren 5 puan almaktadır. Ayrıca oyuncunun oyunda geçirdiği süre arttıkça performans skoru bu süreye bağlı olarak azalmaktadır. Başka bir ifadeyle, oyuncunun oyunu bitirme süresi düştükçe elde ettiği skor yükselmektedir. Bu doğrultuda çalışmada puanlar tüm katılımcılar için oyuncuların oyunda geçirdikleri sürenin saniye cinsinden hesaplanmasıyla elde edilmiştir. Elde edilen süreler ise ters orantılı puanlama ile hesaplanarak oyun skoruna dönüştürülmüştür. Ters orantılı puanlama formülü aşağıdaki Denklem 3.1’deki gibi hesaplanabilir.

$$\text{Puan} = \frac{K}{t} \quad (3.1)$$

Burada K sabit bir sayı, t geçen zamandır.

Çizelge 3. 1’de Tüm katılımcılar için zaman ve zamandan dönüştürülmüş puanlar verilmiştir.

Çizelge 3. 1. Zaman, puan ve zamanın puana dönüştürülmüş hali.

Katılımcılar	Zaman (saniye)	Puan	Zamanın Puana Dönüştürülmüş Hali
K1	138	5	72,46
K2	106	5	94,34
K3	258	5	38,76
K4	116	5	86,21
K5	99	5	101,01
K6	129	5	77,52
K7	115	5	86,96
K8	109	5	91,74
K9	123	5	81,30
K10	113	5	88,50
K11	110	5	90,91
K12	109	5	91,74
K13	104	5	96,15
K14	112	5	89,29
K15	117	5	85,47
K16	110	5	90,91
K17	114	5	87,72

3.4.2. EEG verilerinin analizi

Katılımcıların Wordwall'da tasarlanan eğitsel matematik oyununu oynamaları esnasında ham EEG verileri kaydedilmiştir. Şekil 3.7'de K1 katılımcısına ait ham EEG verilerinin bir Excel dokümanında kaydedilmiş hali gösterilmiştir. Bu veriler, analiz öncesi aşamada işlenmemiş, orijinal (Raw) EEG sinyallerini temsil etmektedir.

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
Timestamp	OriginalTimestamp	EEG.Counter	EEG.Interpolated	EEG.AF3	EEG.F7	EEG.F3	EEG.FC5	EEG.T7	EEG.P7	EEG.O1	EEG.O2	EEG.P8	EEG.T8	EEG.FC6	EEG.F4
1711698063	1711698063	20	0	4.227.205.127	4.294.102.539	4.309.102.539	4.301.666.504	4.263.077.148	4.271.538.574	4.273.974.121	4.265.512.695	4.264.102.539	4.253.333.496	4.463.589.844	4.498.717.773
1711698063	1711698063	21	0	4.241.794.922	4.278.333.496	4.298.846.191	4.285.641.113	4.274.743.652	4.274.358.887	4.273.717.773	4.264.743.652	4.263.077.148	4.246.025.879	4.453.846.191	4.488.717.773
1711698063	1711698063	22	0	4.255.128.418	4.276.282.227	4.301.666.504	4.271.794.922	4.280.641.113	4.276.666.504	4.276.666.504	4.266.153.809	4.261.538.574	4.247.820.313	4.459.743.652	4.492.820.313
1711698063	1711698063	23	0	4.289.230.957	4.290.769.043	4.315.641.113	4.289.743.652	4.270.384.766	4.273.333.496	4.276.922.852	4.268.846.191	4.253.461.426	4.252.436.035	4.473.461.426	4.503.846.191
1711698063	1711698063	24	0	4.305.897.461	4.303.205.078	4.315.897.461	4.311.922.852	4.271.794.922	4.266.922.852	4.272.179.688	4.268.846.191	4.238.205.078	4.250.769.043	4.471.922.852	4.506.538.574
1711698063	1711698063	25	0	4.306.794.922	4.305.384.766	4.31.294.873	4.310.641.113	4.280.512.695	4.266.538.574	4.270.128.418	4.265	4.225.641.113	4.248.461.426	4.466.794.922	4.506.794.922
1711698063	1711698063	26	0	4.288.589.844	4.299.615.234	4.322.820.313	4.29.794.873	4.281.282.227	4.274.871.582	4.275	4.264.358.887	4.214.871.582	4.248.205.078	4.464.358.887	4.505.256.348
1711698063	1711698063	27	0	4.270.128.418	4.293.333.496	4.326.922.852	4.294.358.887	4.279.102.539	4.281.282.227	4.279.358.887	4.271.153.809	4.205.384.766	4.251.794.922	4.461.410.156	4.502.692.383
1711698063	1711698063	28	0	4.282.436.035	4.294.230.957	4.323.974.121	4.298.205.078	4.281.410.156	4.281.794.922	4.279.102.539	4.278.077.148	4.202.436.035	4.259.871.582	4.467.820.313	4.511.538.574
1711698063	1711698063	29	0	4.302.436.035	4.296.282.227	4.325.512.695	4.298.077.148	4.286.410.156	4.283.205.078	4.281.282.227	4.279.487.305	4.202.692.383	4.265.769.043	4.473.846.191	4.519.358.887
1711698063	1711698063	30	0	4.285	4.293.077.148	4.325.384.766	4.293.205.078	4.282.692.383	4.281.794.922	4.284.102.539	4.278.077.148	4.200.384.766	4.260.256.348	4.465.512.695	4.511.666.504
1711698063	1711698063	31	0	4.261.538.574	4.293.717.773	4.326.538.574	4.293.589.844	4.276.282.227	4.279.615.234	4.281.666.504	4.277.820.313	419.794.873	4.251.922.852	445.705.127	4.511.025.879
1711698063	1711698063	32	0	4.276.922.852	4.296.794.922	4.330.641.113	4.297.692.383	4.279.358.887	4.280.897.461	4.280.384.766	4.278.077.148	4.199.102.539	4.256.794.922	4.461.282.227	4.518.974.121
1711698063	1711698063	33	0	4.305.256.348	4.294.615.234	4.328.846.191	4.295.512.695	4.285.128.418	4.282.692.383	4.283.333.496	4.276.922.852	4.201.025.879	4.267.436.035	4.464.615.234	4.516.666.504
1711698063	1711698063	34	0	4.297.307.617	4.285.384.766	4.32.294.873	4.292.179.688	4.279.230.957	4.279.487.305	4.282.179.688	4.275.769.043	4.202.563.965	4.269.230.957	4.463.974.121	4.511.538.574
1711698063	1711698063	35	0	4.260.384.766	4.278.974.121	4.318.205.078	4.291.794.922	4.270.256.348	4.275.897.461	4.277.94.873	4.275.769.043	4.200.641.113	4.257.436.035	4.462.307.617	4.507.692.383
1711698063	1711698063	36	0	4.253.333.496	4.285	4.318.205.078	4.292.436.035	4.276.025.879	4.277.692.383	4.277.820.313	4.276.153.809	4.201.538.574	4.247.692.383	4.457.179.688	4.502.307.617
1711698063	1711698063	37	0	4.280.641.113	4.293.717.773	4.322.307.617	4.295.384.766	4.289.102.539	4.281.282.227	4.279.358.887	4.276.282.227	4.208.717.773	4.255.128.418	4.462.436.035	4505
1711698063	1711698063	38	0	4.296.153.809	4.297.692.383	4.326.282.227	4.298.333.496	4.280.641.113	4.282.307.617	4.279.358.887	4.278.974.121	4.205.384.766	4.266.666.504	4.478.589.844	4.515.128.418
1711698063	1711698063	39	0	4.281.025.879	4.293.846.191	4.323.205.078	4.294.358.887	4.276.794.922	4.281.794.922	4.275.512.695	4.276.794.922	4.184.230.957	4.264.358.887	4.477.307.617	4.509.487.305
1711698063	1711698063	40	0	4.270.128.418	4.284.743.652	4.315.769.043	4.289.358.887	4.27.205.127	4.280.897.461	4.271.794.922	4.266.282.227	4.166.282.227	4.256.410.156	4.461.153.809	4.495.128.418
1711698063	1711698063	41	0	4.281.410.156	4.280.769.043	4.311.794.922	4.28.705.127	4.283.205.078	4.280.384.766	4.274.871.582	4.266.666.504	4.170.641.113	4.253.974.121	4.464.487.305	4.498.077.148
1711698063	1711698063	42	0	4.280.769.043	4.281.538.574	4.307.820.313	4.280.256.348	4.287.179.688	4.28.294.873	4.280.384.766	4.272.436.035	4.181.922.852	4.248.461.426	4.476.025.879	4.503.077.148
1711698063	1711698063	43	0	4.261.410.156	4.279.871.582	4.30.294.873	4.278.589.844	4.280.769.043	4.289.358.887	4.283.077.148	4.268.077.148	4.181.538.574	4.244.615.234	4.466.410.156	4.493.333.496
1711698063	1711698063	44	0	4.251.153.809	4.275.897.461	4305	4.279.358.887	4.278.461.426	4.280.641.113	4.28.294.873	4.268.974.121	4.184.102.539	4.246.410.156	4.456.666.504	4.491.538.574
1711698063	1711698063	45	0	4.270.769.043	4.276.666.504	4.311.538.574	4.280.512.695	4.27.705.127	4.28.294.873	4.279.230.957	4.272.820.313	4.194.615.234	4.24.705.127	4.465.512.695	4.501.410.156

Şekil 3. 2. Ham (raw) EEG verileri

K1 katılımcısına ait EEG verileri, EXCEL’de 24.759 satır, 37 sütundan oluşmakta ve veri kümesi 10,7 MB büyüklüğündedir. 17 katılımcının tamamına ait veriler ele alındığında büyük bir veri yığını ile karşı karşıya kalınmaktadır. Bu doğrultuda elde edilen bu büyük veri yığınının belirli ön işleme süreçlerinden geçirilerek analize hazır hale getirilmesi gerekmektedir. Bu süreçte ait gerçekleştirilen işlemler ise aşağıda alt başlıklar altında sunulmuştur.


3.4.2.1. Farklı katılımcılardan elde edilen verilerin birleştirilmesi

Çalışmada eğitsel dijital oyun sırasında, katılımcılara EEG başlığı katılarak beyin sinyalleri zaman damgalı olacak şekilde kaydedilmiştir. Her bir katılımcının EEG verileri, kendilerine atanan numaralarla etiketlenmiş ve Excel dokümanında saklanmıştır. Şekil 3.8’de K1 katılımcısına ait EEG verileri, Şekil 3.9’da ise bu verilerin etiketlenmiş hali görsel olarak sunulmuştur.

Etiketlemenin sonrasında tüm katılımcılara ait EEG verileri tek bir veri dosyasında birleştirilmiştir. Böylece 114.414 satır, 122 sütundan oluşan bu data dosyası 18 MB alan kaplamıştır.

3.4.2.2. EEG verilerinin ön işleme

EEG verilerinin ön işlenmesi aşamasında, sinyal işleme adımları dikkatlice uygulanmıştır. İlk olarak, Emotiv yazılımı kullanılarak verilerden CSV formatında dijital veri dosyaları elde edilmiştir. Bu dosyalardaki artık veriler ve gürültüler, sinyal kalitesini artırmak amacıyla azaltılmıştır. Böylelikle veriler, analiz için daha uygun hale getirilmiştir. Bu çalışmada kullanılan veri seti, toplamda 371.664 örnekten oluşmuş ve bu verilerden 91 adet öznitelik çıkarılmıştır. Şekil 3.5'te gösterildiği gibi, sonraki adımlarda verilerin normalizasyonu, eksik verilerin tamamlanması, özniteliklerin azaltılması ve skorların tahmin edilmesi için ilgili makine öğrenmesi algoritmaları kullanılmış, bu algoritmaların performansları değerlendirilmiştir.



Şekil 3. 5. EEG verilerinin ön işleme ve sınıflandırma süreci akış diyagramı

3.4.2.3. Kayıp değerlerin silinmesi

Çalışmada, eksik verilerin analiz sonuçlarını olumsuz etkileyebileceği ve modelin doğruluğunu düşürebileceği göz önünde bulundurularak kayıp değerlerin silinmesi tercih edilmiştir. Bu süreç sonucunda, veri setindeki örnek sayısı 283'e, öznitelik sayısı ise 91'e düşmüştür. Eksik veri içeren satırlar çıkarılarak, analizde yalnızca tam ve güvenilir verilerin kullanılması sağlanmıştır.

3.4.2.4. Normalizasyon

Normalizasyon, sinyal içerisindeki veri ölçeklerindeki farklılıkları azaltarak verilerin analiz edilebilirliğini artırmayı amaçlayan kritik bir veri işleme sürecidir (Hu ve Zhang, 2019; Kuduz, 2023). Bu süreç, verilerin belirli bir aralıkta aynı ölçeğe getirilmesiyle gerçekleştirilmekte ve böylece farklı salınımlardan kaynaklanan beyin sinyallerinin analiz sürecine olumsuz etkisi minimize edilmektedir.

Novak ve arkadaşlarına (2012) göre, normalizasyon işlemine yönelik üç olası yaklaşım bulunmaktadır. İlk yaklaşım, konuyla ilgili herhangi bir uyaran olmadan referans koşullarının kaydedilmesidir. Elde edilen değerler önce referans değerinden çıkarılmakta, ardından referans değerine bölünerek (veya referans değerinden tekrar çıkarıldıktan sonra aynı değere bölünerek) normalizasyon gerçekleştirilmektedir. İkinci yaklaşım da referans koşullarını gerektirmektedir; bu yöntemde, 'temel matrisi' oluşturan özellikler iki katına çıkarılarak özellik vektörüne dahil edilmektedir. Üçüncü yaklaşım ise verileri bağımsız olarak normalleştirmekte ve bu sayede -1 ile 1 arasında bir aralık elde edilmektedir. Bu yöntem ise her özelliğin aynı değer aralıklarına sahip olmasını sağlamaktadır. Bu çalışmada ise beyin sinyallerinin analizini daha güvenilir hale getirmek amacıyla veriler üçüncü yaklaşım kullanılarak normalize edilmiştir. Uygulanan normalizasyon formülü Denklem 3.2'de sunulmuştur.

$$\text{Normalize}_{\text{Veri}} = \frac{(\text{Veri} - \text{Veri}_{\text{Min}})}{(\text{Veri}_{\text{Max}} - \text{Veri}_{\text{Min}})} \quad (3.2)$$

Veri: Normalize edilmemiş veri

Veri_{Min}: En küçük veri

Veri_{Max}: En büyük veri

Bu formül sayesinde tüm veriler 0 ile 1 arasında değerler alır (Kuduz, 2023). Kayıp değerlerin işlenmesinin ardından, veri seti 257 örnek ve 91 öz nitelikten oluşmuştur. Şekil 3.6'da, kayıp değerlerin işlenmesinden sonra çıkarılan öz nitelikler gösterilmiştir.

EEG.AF3	EEG.F7	EEG.F3	EEG.FC5	EEG.T7	EEG.P7	EEG.O1	EEG.O2	EEG.P8	EEG.T8	EEG.FC6	EEG.F4	EEG.F8	EEG.AF4	PM.Attention.Scaled	PM.Engagement.Scaled
0.719935	0.646681	0.606151	0.432153	0.584342	0.682526	0.76241	0.514601	0.118863	0.457001	0.184288	0.432663	0.585287	0.566994	0.657981	0.741504
0.847073	0.783086	0.796724	0.500843	0.630212	0.694476	0.780535	0.529094	0.194906	0.537333	0.201563	0.440421	0.669949	0.699679	0.529183	0.794578
0.844629	0.772362	0.83885	0.463759	0.629002	0.648252	0.774625	0.542289	0.271502	0.562381	0.186806	0.363985	0.654737	0.677849	0.590146	0.572226
0.757669	0.784792	0.970244	0.405184	0.616761	0.708456	0.791962	0.537962	0.166205	0.524783	0.171701	0.34205	0.6504	0.670038	0.502989	0.25733
0.869514	0.788854	0.811768	0.507374	0.637208	0.709808	0.759652	0.523469	0.229882	0.463885	0.167274	0.434196	0.664364	0.672942	0.532334	0.478295
0.954122	0.803965	0.796729	0.593974	0.637746	0.725592	0.769109	0.54164	0.196844	0.536804	0.208073	0.287548	0.742853	0.689766	0.483238	0.761567
0.771604	0.730604	0.737881	0.313317	0.617299	0.782864	0.74271	0.519576	0.206995	0.426975	0.132552	0.235153	0.617256	0.698478	0.554517	0.845091
0.870871	0.79649	0.75861	0.529709	0.646086	0.633597	0.785263	0.558728	0.16519	0.431423	0.166059	0.354406	0.665099	0.723112	0.613808	0.824563
0.81703	0.78073	0.840855	0.452592	0.552596	0.694476	0.80457	0.518062	0.206626	0.597437	0.15651	0.404885	0.661277	0.710094	0.610169	0.823604
0.847525	0.767893	0.772986	0.508639	0.645413	0.649155	0.768321	0.538828	0.219638	0.459225	0.176649	0.418103	0.664878	0.715401	0.601929	0.841142
0.919645	0.76375	0.740555	0.384956	0.580038	0.673055	0.765563	0.544452	0.231174	0.535056	0.189844	0.38841	0.606967	0.674744	0.536205	0.796982
0.813953	0.776099	0.802073	0.478087	0.637477	0.671928	0.769897	0.558079	0.205519	0.497299	0.170139	0.329502	0.667818	0.68546	0.550195	0.841889
0.870238	0.775693	0.765296	0.457648	0.560533	0.683653	0.801417	0.546831	0.131783	0.474317	0.166406	0.317145	0.642904	0.677749	0.665647	0.82616
0.844086	0.789179	0.781678	0.512642	0.618375	0.684555	0.748226	0.521523	0.21484	0.465632	0.168863	0.407088	0.618432	0.67895	0.613706	0.810981
0.776038	0.785117	0.780007	0.456806	0.759214	0.77407	0.806541	0.534718	0.19223	0.533944	0.146181	0.323372	0.646432	0.659724	0.576383	0.856307
0.81513	0.77423	0.791039	0.502739	0.914044	0.736866	0.781324	0.532122	0.211609	0.468386	0.178733	0.420881	0.655324	0.68596	0.604941	0.859623
0.814044	0.797303	0.861251	0.48504	0.60869	0.740023	0.739559	0.537314	0.113603	0.48602	0.200694	0.462356	0.675902	0.730623	0.653561	0.745583
0.893946	0.855553	1	0.569954	0.658461	0.709357	0.841213	0.566083	0.0983758	0.504342	0.212934	0.41887	0.812155	0.760565	0.410187	0.385808

0.95186	0.887075	0.855566	0.654025	0.649448	0.764826	0.83018	0.581441	0.270303	0.498835	0.255903	0.423851	0.743073	0.846885	0.471069	0.349541
0.823907	0.723373	0.737546	0.418036	0.585688	0.594363	0.672182	0.518495	0.181248	0.489462	0.130555	0.436494	0.60535	0.663929	0.592798	0
0.964076	0.81152	0.749248	0.463337	0.592279	0.690192	0.771472	0.479126	0.315061	0.502912	0.138715	0.441283	0.599397	0.651412	0.599914	0.0415116
0.704371	0.741003	0.970578	0.570164	0.677428	0.74115	0.918439	0.611724	0.213086	0.498994	0.119271	0.461782	0.567869	0.52854	0.466485	0.334288
0.599493	0.595987	0.697425	0.230089	0.618106	0.62097	0.579196	0.564569	0.218808	0.490309	0.0885416	0.383812	0.535313	0.312337	0.447224	0.510611
0.826169	0.7605	0.819458	0.437842	0.612053	0.652086	0.823088	0.584036	0.300295	0.500582	0.163542	0.474234	0.646138	0.638494	0.410625	0.498252
0.870329	0.836867	0.931796	0.633797	0.701775	0.863811	0.975571	0.609128	0.241141	0.538657	0.231771	0.480651	0.604027	0.730923	0.533794	0.41697
0.844539	0.781136	0.958542	0.516646	0.629405	0.651184	0.778566	0.529959	0.239941	0.497246	0.159115	0.402203	0.946277	0.687663	0.475679	0.45452
0.786716	0.776424	0.709796	0.483354	0.616357	0.642391	0.764775	0.510059	0.175618	0.472146	0.16875	0.409195	0.82825	0.691067	0.452345	0.452646
1	0.888699	0.899365	0.717447	0.646355	0.792334	0.767139	0.584253	0.227852	0.498199	0.287847	0.48908	0.727567	0.822351	0.417549	0.404758

Şekil 3. 6. Kayıp değerlerden (After Outliers) sonra çıkarılan öz nitelikler

3.4.2.5. Aykırı verilerin kapsam dışı bırakılması (outliers detection)

Katılımcıların oyun oynama sırasında gerçekleştirdikleri bazı hareketler, sinyal bozucu etkilere yol açabilir. Bu tür sinyaller, veri kümelerinde olağandışı noktalarda yer alarak veri dağılımını bozabilir ve bu durum, asıl ölçümlerdeki veri dağılımını ve veri analizini olumsuz etkileyebilir. Tutarlı bir veri analizi gerçekleştirebilmek için bu tür aykırı değerlerin düzeltilmesi veya gerekirse veri setinden çıkarılması gerekmektedir. Bu süreçte, her özellik için minimum değer 0, maksimum değer ise 1 olacak şekilde belirlenir ve diğer değerler 0 ile 1 arasında bir ondalık değer olarak normalize edilir.

Bu çalışmada, aykırı değerlerin tespit edilip veri setinden çıkarılması için Yerel Aykırı Değer Faktörü (Local Outlier Factor (LOF)) algoritması kullanılmıştır. LOF algoritması, kNN yöntemi ile yerel yoğunluk sapmalarını tespit etmekte ve bir veri noktasının komşularına göre anormal olup olmadığını belirlemektedir. Bu doğrultuda, sapma derecesine göre aykırı değerler dışarıda bırakılmış, komşu sayısı olarak 20 belirlenmiş ve sapma oranı (contamination) [0,1] aralığında tanımlanmıştır. Uzaklık ölçümü için ise Euclidean Metriği kullanılmıştır. Bu yöntemin uygulanması sonrasında başlangıçta 283 olan giriş örneklem sayısı, 26 aykırı değer çıkarılmasıyla birlikte 257'ye düşmüştür.

3.4.2.6. Ayırt edici özniteliklerin seçilmesi

EEG sinyalleri, oldukça büyük miktarda veri içermekte ve bu veri miktarı ölçüm süresi, EEG cihazının kanallarının sayısı ve frekansına bağlı olarak değişmektedir. Örneğin, 14 kanallı bir EEG cihazı ile 5 saniye boyunca, 500 Hz frekansında yapılan bir ölçümde, $14 \times 5 \times 500 = 35.000$ adet genlik noktası elde edilmektedir. Bu ise sadece 5 saniyelik bir sinyal kaydıyla bile devasa miktarda büyük veri kümeleri üretilebileceğini göstermektedir. Bu tür büyük veri kümelerinden sınıflandırma yapabilmek ve anlamlı sonuçlar çıkarabilmek amacıyla veri boyutunu azaltmak için bazı süreçler izlenmektedir. Öznitelikler, araştırmacının analiz için kullanacağı sinyaller içerisinde bulunan kritik bilgi ve kriterlerdir (Kuduz, 2023). Yalnızca analiz için gerekli olan verilerin elde edilmesi işlemi ise "öznitelik çıkarma" olarak adlandırılmaktadır (Sadık, 2022; Hızar, 2023). Özetle öznitelik çıkarma, ham verinin frekansı ve süresine bağlı olarak bazı referans değerlerin belirlenmesi işlemi olup çıkarılan öznitelikler, sınıflandırma, tanıma ve tahmin gibi işlemler için kullanılacak yeni verilerin elde edilmesini sağlamaktadır (Sadık, 2022; Ay, 2023; Kuduz, 2023).

Bu çalışmada, çeşitli düzenlemeler sonrasında anlamlı hale getirilen verilerden farklı öznitelikler çıkarılmış ve veriler özniteliklerle ifade edilebilir bir forma dönüştürülmüştür. Toplamda 17 katılımcıdan elde edilen verilere dayanarak, dikkat (Attention), katılım (Engagement), heyecan (Excitement), stres, rahatlama (Relaxation), ilgi (Interest) ve odaklanma (Focus) gibi duygu metrikleri, ham EEG

verileri ve bu verilerin Fourier Dönüşümü ile elde edilen güç spektrum (Power) metriklerine ait öznitelikler çıkarılmıştır. Bu süreç sonucunda ise toplamda 91 adet özniteliğe ulaşılmıştır.

3.4.3. Oyun performansının tahminlenmesinde kullanılan algoritmalar ve algoritmaların modellenmesi

Bu çalışmada, oyun performansını tahmin etmek amacıyla çeşitli makine öğrenmesi algoritmaları kullanılmıştır. Bu algoritmalar, elde edilen EEG verilerinden anlamlı sonuçlar çıkarmak ve oyuncu performansını tahmin etmek için kullanılmıştır. Çalışmada; AdaBoost, Gradient Boosting, k-Nearest Neighbors (kNN), Naive Bayes, Random Forest (RF), Tree, Neural Network (NN), Stochastic Gradient Descent (SGD) ve Support Vector Machine (SVM) algoritmaları kullanılmıştır.

3.4.3.1. AdaBoost

AdaBoost, zayıf sınıflandırıcıları birleştirerek daha güçlü bir sınıflandırıcı oluşturan bir yükseltme algoritmasıdır. Bu algoritma, zor sınıflandırma örneklerine uyum sağlayabilmesiyle bilinmektedir. Algoritmanın başlangıcında, her eğitim örneğine eşit ağırlık atanmakta ve zayıf sınıflandırıcılar eğitilmektedir. Sınıflandırıcıların performansına bağlı olarak ağırlıklar güncellenmekte; yanlış sınıflandırmaların ağırlıkları artırılmakta ve böylece her turda bu örnekler daha önemli hale gelmektedir. Bu süreç, birkaç kez tekrarlanarak son aşamada zayıf sınıflandırıcıların performansına göre ağırlıkların toplamı alınmakta ve güçlü bir sınıflandırıcı elde edilmektedir (Hornýák ve Iantovics, 2023).

Bu çalışmada, AdaBoost algoritması temel tahminleyici model olarak karar ağaçlarını (decision trees) kullanmıştır. 50 adet karar ağacının birleştirilmesiyle güçlü bir model oluşturulmuştur. Algoritmanın öğrenme hızı, modelin yavaş ama daha ayrıntılı bir öğrenme gerçekleştirmesi amacıyla 1.0 olarak belirlenmiştir. Ağırlıkların ayarlanmasında SAMME.R sınıflandırma algoritması tercih edilmiştir. Hataları en aza indirmek amacıyla, regresyon kayıp fonksiyonlarından

lineer kayıp fonksiyonu kullanılmıştır. Bu sayede, modelde her bir örnek için tahmin edilen değer ile gerçek değer arasındaki farkın mutlak değeri hesaplanarak hata miktarı minimize edilmiştir.

3.4.3.2. Gradient Boosting (GB)

Gradient Boosting, zayıf sınıflandırıcıları ardışık olarak eğitip bu tahminleri birleştirerek güçlü bir sınıflandırma ve regresyon modeli oluşturan bir makine öğrenme yöntemidir. Bu yöntemde, modelin tahminleri ile gerçek değerler arasındaki hatalar belirlenmekte ve bu hataları azaltmak için zayıf sınıflandırıcılar eğitilmektedir. Her iterasyonda yeni tahminler, önceki tahminlere eklenerek model sürekli olarak güncellenmekte ve iyileştirilmektedir (Bentéjac vd., 2021).

Bu çalışmada, Gradient Boosting yöntemi olarak scikit-learn kütüphanesi kullanılmıştır. Modelde, 100 adet sınıflandırma ağacı eklenmiş ve öğrenme oranı 0.1 olarak belirlenmiştir. Maksimum ağaç derinliği 3 olarak ayarlanmış olup, eğitim tekrar edilmeyecek şekilde düzenlenmiştir. Eğitim örneklerinin oranı 1 olarak sınırlandırılmış ve budama sırasında bölünecek en küçük alt küme sayısı 2 olarak tespit edilmiştir. Bu ayarlar, modelin performansını optimize etmek amacıyla yapılmıştır.

3.4.3.3. kNN (K-Nearest Neighbors- K-en yakın komşu)

K-en yakın komşu algoritması (kNN) birbirine yakın olan nesnelerin benzer özellik gösterip aynı sınıfta olması mantığına dayanan, sınıflandırma ve regresyon için kullanılan denetimli öğrenme algoritmasıdır (Türk ve Özerdem, 2014). kNN algoritması özellikleri net bir şekilde belirlenmiş olan normal veri kümelerine en yakın k adet veride mevcut olan en fazla sınıfa göre yapılan sınıflandırmadır (Ay, 2023). Bu algoritma basit olması, ön bilgi ihtiyacının çok az olması ve hızlı sonuç vermesi sebebiyle tercih edilmektedir (Sadık, 2022).

kNN algoritmasında, veri noktalarının birbirine olan uzaklığı hesaplanırken genellikle öklid uzaklığı metriği kullanılmaktadır (Sha'bani, 2020). Öklid uzaklığı, seçilen veri noktasının diğer veri noktalarına olan uzaklığını belirlemek için kullanılan yaygın bir yöntemdir. Bu çalışmada da Öklid uzaklığı mesafe ölçüm metriği olarak tercih edilmiş ve Öklid uzaklığına ait olan denklem Denklem 3.3' te sunulmuştur.

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (3.3)$$

d: uzaklık

x_1 ve y_1 : 1. verilerin bulunduğu koordinatlar

x_2 ve y_2 : 2. verilerin bulunduğu koordinatlar

Örneğin bir test veri kümesinde seçilen bir k noktasına en yakın 10 eğitim noktasının 8'inin veri sınıfı "X" ve 2'sinin veri sınıfı "Y" ise veri noktasının sınıfı en yakın olduğu "X" sınıfı olacak ve bu şekilde etiketlenecektir.

Bu çalışmada, k değeri 5 olarak belirlenmiştir ve ağırlık fonksiyonu olarak Uniform ağırlığı kullanılmıştır. Bu seçimler ise algoritmanın performansını optimize etmek amacıyla yapılmıştır.

3.4.3.4. NB (Naive Bayes)

Veri özelliklerinin birbirinden bağımsız olduğu varsayımına dayanarak model tarafından tahmin edilen en yüksek olasılığa sahip olan veri noktasının sınıflandırmasının yapıldığı algoritmadır. Veri niteliğinin fazla olduğu durumlarda bile çok az eğitim verisi ile çok iyi sonuçlar vermektedir (Kamel vd., 2019). X veri noktasının özellikleri olmak üzere $P(C|X)$ olasılığı aşağıdaki Denklem 3.4 'teki gibi hesaplanır.

$$P(C|X) = \frac{P(X|C) \cdot P(C)}{P(X)} \quad (3.4)$$

$P(C|X)$: X özellik vektörü verildiğinde C sınıfının olasılığı

$P(X|C)$: C sınıfı verildiğinde X özellik vektörünün olasılığı

$P(C)$: C sınıfının olasılığı

$P(X)$: X özellik vektörünün olasılığı

3.4.3.5. RF (Random Forest-Rastgele Orman)

Random Forest (RF), birden fazla karar ağacının (decision tree) birleşiminden oluşan esnek ve güçlü bir algoritmadır. Hem regresyon hem de sınıflandırma problemlerinde kullanılan bu algoritma, her bir karar ağacının bağımsız olarak tahmin yapması ve bu tahminlerin ortalamasını alarak nihai sonuca ulaşması prensibine dayanmaktadır. Modelin çeşitliliğini artırmak ve aşırı uyumu önlemek için ağaçlar, rastgele seçilmiş bir alt kümeden eğitilmektedir. Eğitilen ağaçlar budanmamaktadır ve her zaman en doğru sonucu veren ağaçlar seçilmektedir (Hızır, 2023).

Sınıflandırma problemlerinde, ormandaki ağaçların çoğunluk oyu nihai tahmini belirlerken, regresyon problemlerinde ise tahminlerin ortalaması alınmaktadır. Bu çalışmada, Random Forest modeli 10 adet karar ağacından oluşacak şekilde tasarlanmış, özellik sayısına sınırlama getirilmemiş ve maksimum ağaç derinliği sınırsız olarak belirlenmiştir. Ayrıca, budama sırasında bölünecek en küçük alt küme sayısı 5 olarak tespit edilmiştir.

3.4.3.6. Karar Ağaçları (Decision Trees)

Karar ağaçları, eksik verilerin bulunduğu durumlarda bile güçlü sonuçlar üretebilen, esnek ve kolay yorumlanabilir makine öğrenimi yöntemlerindendir. Bu model hem regresyon hem de sınıflandırma problemlerinde yaygın olarak kullanılmakta ve genellikle çok az varsayıma dayandığı için geniş bir uygulama yelpazesi sunmaktadır (Gacar, 2023). Karar ağaçları, veri setini alt gruplara ayırarak aşırı uyumu (overfitting) engelleyebilme gücüne sahiptir. Regresyon problemlerinde ortalama kare hatası kriteriyle, sınıflandırma problemlerinde ise Gini safsızlığı kriteriyle çalışmaktadır.

Bu çalışmada, karar ağaçları ikili yapıdadır ve her bir yaprakta en az iki örnek, iç düğümlerde ise en az beş örnek bulunacak şekilde yapılandırılmıştır. Maksimum derinlik ise 100 olarak belirlenmiştir ve sınıflandırmada çoğunluk % 95'e ulaştığında bölme işlemi durdurularak çalışmaktadır.

3.4.3.7. NN (Neural Networks- Sinir Ağları)

Neural Networks (NN), yapay zekâ sayesinde insan beyninin çalışma süreçlerini taklit eden ve makine öğrenme modellerinde yaygın olarak kullanılan bir yaklaşımdır. Neural Networks temel olarak üç katmandan oluşmaktadır:

Giriş Katmanı (Input Layer): Ham verilerin alındığı ilk katmandır.

Gizli Katmanlar (Hidden Layers): Ham verileri işleyerek daha karmaşık özellikler elde etmek için eğitilmekte ve gizli katman sayısı, modelin derinliğini belirlemektedir.

Çıkış Katmanı (Output Layer): Bu katman, sınıflandırma veya regresyon tahminlemelerini gerçekleştirmektedir (Uzair ve Jamil, 2020).

Neural Networks'te ReLU (Rectified Linear Unit), Sigmoid ve Tanh gibi üç temel aktivasyon fonksiyonu bulunmaktadır. Bu fonksiyonlar ise modeli doğrusal olmayan bağlantılar konusunda eğitmek için kullanılmaktadır (Banerjee vd., 2019).

Bu çalışmada kullanılan Neural Network modelinde, her bir gizli katman için 100 nöron (fonksiyon sayısı) belirlenmiştir. Modelde ayrıca, alpha değeri 0,0001, aktivasyon fonksiyonu ise ReLU (Rectified Linear Unit Function) olarak seçilmiştir. Ağırlık optimizasyonu için ise Adam fonksiyonu (Adaptive Moment Estimation) kullanılmıştır. Düzenleme terim parametresi için maksimum yineleme sayısı 200 belirlenmiştir.

3.4.3.8. SGD (Stochastic Gradient Descent- Stokastik Gradyan İnişi)


Stochastic Gradient Descent, büyük veri kümelerinde kayıp fonksiyonunu optimize etmek ve derin öğrenme modellerini eğitmek için kullanılan bir algoritmadır. Bu algoritma, kayıp fonksiyonunun türevini alarak hesaplamalar yapmaktadır. Bu modelin Gradient Descent algoritmasından temel farkı, her

seferinde tek bir öğrenme adımı gerçekleştirmesidir. Bu sayede, çok büyük veri kümeleri üzerinde çalışırken oldukça hızlı sonuçlar elde edilebilmektedir. Stochastic Gradient Descent modelinin en önemli avantajlarından biri ise veri akışı devam ederken modeli güncelleyebilmesidir (Ketkar, 2017).

Bu çalışmada, SGD algoritmasının belirli parametreleri, modelin veri seti üzerinde daha hızlı ve verimli çalışmasını sağlamak amacıyla özenle seçilmiştir. Sınıflandırma hatalarını en aza indirmek için Hinge kayıp fonksiyonu ve Squared Loss fonksiyonu tercih edilmiştir. Modelin aşırı öğrenmesini (overfitting) engellemek amacıyla Ridge (L2) düzenleme parametresi 0.00001 olarak belirlenmiştir. Başlangıçtaki öğrenme hızı (Initial Learning Rate) 0.01 olarak ayarlanmış, her iterasyondaki öğrenme oranı değişimini kontrol eden Inverse Scaling Exponent değeri 0.25 olarak seçilmiştir. Modelin eğitileceği iterasyon sayısı 1000 olarak belirlenmiş ve modelin iyileşmesi durduğunda eğitimi durdurmak için gerekli olan tolerans (Stopping Criterion) değeri 0.01 olarak ayarlanmıştır. Ayrıca, modelin daha iyi genelleştirme yapabilmesi için eğitim sürecinde verilerin sıralı olmasının olumsuz etkilerini önlemek amacıyla her iterasyondan sonra verilerin karıştırılması sağlanmıştır.

3.4.3.9. SVM (Support Vector Machine- Destek vektör makinesi)

Support vector machine (SVM) sınıflandırma, aykırı değer ve regresyon tahminlerinde tahminlerinde kullanılan denetimli bir makine öğrenmesi metodudur (Hızar, 2023; Kuduz, 2023). Bu model üç ana bileşenden oluşmaktadır: istatistiksel öğrenme teorisi, optimizasyon algoritması ve çekirdek fonksiyonları (Sadık, 2022). Modelin amacı, verileri en yüksek doğrulukla ayıran bir hiper düzlem bulmaktır. Bu hiper düzlemin sınır genişliğini optimize eden noktalara ise "destek vektörleri" denilmektedir (Hızar, 2023). Support Vector Machine, sınıflandırma doğruluğunu en üst düzeye çıkarmak için sınırlara olan uzaklığı en büyük olan ve en uygun ayrımı sağlayan optimal hiper düzlemi seçerek çalışmaktadır. Bu sayede, hatalar en aza indirgenmekte ve doğru tahminler yapılmaktadır (Sadık, 2022; Kuduz, 2023). Modele ait simülasyon ise Şekil 3.12'de sunulmuştur.



Şekil 3. 7. Support Vector Machine (SVM) işleyiş simülasyon görüntüsü

Bu çalışmada SVM algoritmasının parametreleri şu şekilde belirlenmiştir: maliyet (cost) değeri $C=1,0$ ve ϵ (epsilon) değeri $0,1$ olarak ayarlanmıştır. Sayısal tolerans (Numerical Tolerance) değeri, beklenen sonuçtan izin verilen sapma miktarı olarak $0,001$ ve maksimum yinleme sınırı 100 olarak sınırlandırılmıştır. Öznitelik alanını maksimum uyum sağlayacak şekilde yeni bir özellik alanına dönüştürmek için ise Radyal Tabanlı Fonksiyon (RBF) algoritması kullanılmıştır. RBF formülü Denklem 3.5'te gösterilmiştir:

$$K(x_i, x_j) = \exp(-\phi \|x_i - x_j\|^2) \quad (3.5)$$

x_i ve x_j girdileri arasındaki çekirdek fonksiyonunun değeridir.

ϕ ise RBF çekirdeğinin genişliğini kontrol eden bir parametredir.

Denklem, girdilerin arasındaki Öklidyen mesafenin karesidir.

3.4.4. Performans değerlendirme kriterleri

Bu çalışmada, algoritmaların performansını değerlendirmek ve en iyi modeli belirlemek amacıyla çapraz doğrulama (cross validation) ve karmaşıklık matrisi (Confusion Matrix-CM) yöntemleri kullanılmıştır. Bu değerlendirme süreci ise

kullanılan modellerin doğruluğunu ve genel performansını objektif bir şekilde ölçmeye yönelik olarak gerçekleştirilmiştir.

3.4.4.1. Cross validation (k-kat çapraz doğrulama)

Veri madenciliği ve makine öğrenimi araştırmalarında, kurulan modellerin performansını tahmin etmek için model doğrulama teknikleri gereklidir. k-kat çapraz doğrulama ise bu tekniklerden biri olarak öne çıkmaktadır. Bu yöntemle veri seti, eğitim ve test verisi olarak örneklenmektedir. Veriler, k sayıda farklı alt kümeye bölünmekte ve her bir öğrenmede bir altküme test için ayrılmakta, kalan k-1 altküme ise eğitim için ayrılmaktadır. k-1 altküme ile eğitim gerçekleşmekte ve bu işlem k kez tekrarlanmaktadır. Her tekrarda, farklı bir parça test seti olarak kullanılmaktadır. Alt kümelerin rastgele seçilmesi ile ise her bir veri parçası üzerindeki performans kapsamlı bir şekilde tespit edilmektedir. Sonuç olarak k testlerinin ortalama doğruluğu modelin genel performansını ortaya koymaktadır. k-kat çapraz doğrulama, tüm verilerin eksiksiz bir şekilde eğitim ve test verisi olarak kullanılmasını sağlayarak modellerin genel performansının daha doğru bir şekilde değerlendirilmesine imkân tanımaktadır (Sadık, 2022). Ayrıca bu teknik ile veri setinin tekrar tekrar bölünmesi, farklı varyasyonlarda kullanılmasına olanak tanımakta ve bu durum da modelin aşırı uyum riskini azaltmaktadır. Bu çalışmada, k-kat çapraz doğrulama yöntemi aşırı uyum riskini azaltması, güvenilir performans ölçümü sağlaması, veri setinin etkin kullanımına izin vermesi ve araştırmada kullanılan model ve ayarları için uygun olması gibi olumlu etkileri nedeniyle tercih edilmiştir. Bu tercih ile modelin doğruluğu ve genelleme kabiliyeti artırılarak daha iyi değerlendirme yapılması sağlanmıştır.

3.4.4.2. Karmaşıklık matrisi (Confusion matrix)

Karmaşıklık Matrisi, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan temel bir tablo olarak sunulan bu yöntem ile modelin doğru ve yanlış sınıflandırmaları özetlenebilmekte ve bu bağlamda modelin ne kadar iyi çalıştığı belirlenebilmektedir. Bu matris tablosu, dört ana bileşenden oluşmaktadır:

- Doğru Pozitif (DP): Modelin, pozitif bir durumu doğru bir şekilde pozitif olarak tahmin ettiği durumlardır.
- Yanlış Negatif (YN): Modelin, pozitif bir durumu yanlış bir şekilde negatif olarak tahmin ettiği durumlardır.
- Yanlış Pozitif (YP): Modelin, negatif bir durumu yanlış bir şekilde pozitif olarak tahmin ettiği durumlardır.
- Doğru Negatif (DN): Modelin, negatif bir durumu doğru bir şekilde negatif olarak tahmin ettiği durumlardır.

Bu durumlar, Çizelge 3.2.'de gösterilmiştir:

Çizelge 3. 2. Karmaşıklık Matris Metrikleri

Gerçek/Tahmin	Pozitif (P)	Negatif (N)
Pozitif (P)	Doğru Pozitif (DP)	Yanlış Negatif (YN)
Negatif (N)	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Karmaşıklık matrisinden türetilen bazı önemli performans metrikleri aşağıda açıklanmıştır:

- Precision (kesinlik), modelin pozitif tahminlerinin ne kadarının gerçekten doğru olduğunu gösteren yüzdedir.
- Recall (duyarlılık), gerçek pozitif örneklerin ne kadarının doğru tahmin edildiğinin yüzdesidir.
- F1 ise Precision ve Recall yüzdelerinin harmonik ortalamasıdır (Kuduz, 2023).
- Area Under Curve (AUC): Bu metrik, bir modelin sınıflandırma performansını ROC eğrisi altında kalan alanı ölçerek değerlendirerek modelin pozitif sınıfları ne kadar iyi ayırt edebildiğini sunmaktadır (Mano vd., 2005).
- Classification Accuracy (CA): Bu metrik, modelin doğru tahmin ettiği örneklerin, toplam tahmin edilen örnek sayısına oranını ifade etmekte ve modelin genel doğruluğunu göstermektedir (Mano vd., 2005).

AUC, modelin genel performansını ROC eğrisi üzerinden tüm eşik değerlerinde değerlendirerek pozitif ve negatif sınıfları ne kadar iyi ayırt ettiğini ölçmekte ve özellikle dengesiz veri setlerinde daha güvenilir sonuçlar vererek model

performansını karar eřiđine bađımlı olmadan deđerlendirmektedir. Bu deđerlendirme sonrasında ise farklı modellerin karřılařtırılması kolaylařmaktadır. AUC metriđinin model performans deđerlendirmesindeki bu olumlu etkileri nedeniyle alıřmada, modelin ayırt edici gcn en dođru řekilde yansıtabilmek amacıyla model performansının deđerlendirmesinde AUC metriđi kullanılmıřtır.



4. ARAŞTIRMA BULGULARI

Bu çalışmada oyun performans puanlarının tahmin edilmesi amacıyla veriler, çapraz doğrulama (cross validation) işlemine tabi tutulmuş ve ardından sıralama (rank) ve ki-kare (chi-square) yöntemleri uygulanmıştır. Ki-kare yöntemi ile en iyi ayırt edici özniteliklerin tespit edildiği belirlenmiştir. Elde edilen en iyi 5 ayırt edici özneliğe ait veriler, 10 kat çapraz doğrulama yöntemi ile test edilmiştir. Bu veriler daha sonra AdaBoost, Gradient Boosting, kNN, Naive Bayes, Random Forest, Karar Ağaçları, Neural Network, Stochastic Gradient Descent ve Support Vector Machine algoritmalarına uygulanmış ve algoritmaların performans puanları değerlendirilmiştir. Elde edilen sonuçlar, karmaşıklık matrisi bulguları ile birlikte sunulmuştur.

4.1. Oyun Performansının Değerlendirmesinde Ayırt Edici Özniteliklerin Belirlenmesi

Bu çalışmada, oyun performansını en iyi şekilde tahmin edebilen özniteliklerin belirlenmesi hedeflenmiştir. İlk beş ayırt edici özneliğin seçimi ile daha yüksek bir sınıflandırma doğruluğuna ulaşılacağı varsayılmıştır. Bu doğrultuda, özniteliklerin puanlanmasında chi-2 (ki-kare) puanlama yöntemi tercih edilmiştir. Ki-kare yöntemi, ölçülen özellikler ile öznitelik sınıfları arasındaki bağımlılığı ortaya koyarak, en belirleyici öznitelikleri sıralamaktadır. Çalışmada, ki-kare yöntemi ile yapılan analiz sonucunda elde edilen öznitelik sıralaması Çizelge 4.1’de sunulmuştur.

Çizelge 4. 1. Model tabanlı özellik puan bulguları

Öznitelikler	X ²
POW.FC5.Gamma	67.145
POW.AF3.Gamma	62.166
EEG.O1	58.414
POW.P8.Gamma	56.391
POW.AF3.BetaH	56.156

Çizelge 4.1’de görüldüğü üzere, ki-kare özellik seçim algoritmasına göre en iyi beş ayırt edici öznelik sırasıyla POW.FC5.Gamma, POW.AF3.Gamma, EEG.01, POW.P8.Gamma ve POW.AF3.BetaH olmuştur.

4.2. Oyun Performans Tahminlenmesinde Kullanılan Algoritmaların Değerlendirme Ölçüt Çıktıları

Çalışmada, oyun performansını tahmin etmek amacıyla kullanılan makine öğrenmesi algoritmalarının performansı çeşitli ölçütlerle değerlendirilmiştir. Bu değerlendirme, verilerin 10 kat çapraz doğrulama yöntemiyle işlenmesi sonucunda elde edilen eğitim ve test verileri üzerinde gerçekleştirilmiştir. AdaBoost, Gradient Boosting, kNN, Naive Bayes, Random Forest, Tree, Neural Network, Stochastic Gradient Descent ve Support Vector Machine algoritmalarına ait AUC, CA, F1, Precision ve Recall ölçütleri kullanılarak elde edilen performans çıktıları Çizelge 4.2’de sunulmuştur.

Çizelge 4. 2. Algoritmalarla göre test verilerine uygulanan algoritma değerlendirme ölçütleri ve skor verileri

Model	AUC	CA	F1	Precision	Recall
Gradient Boosting	0.877	0.665	0.664	0.671	0.665
Neural Network	0.868	0.673	0.643	0.628	0.673
Random Forest	0.864	0.693	0.688	0.688	0.693
Support Vector Machine	0.860	0.642	0.593	0.552	0.642
Naive Bayes	0.859	0.658	0.657	0.667	0.658
kNN	0.775	0.584	0.581	0.580	0.584
AdaBoost	0.746	0.642	0.645	0.650	0.642
Tree	0.740	0.588	0.592	0.599	0.588
Stochastic Gradient Descent	0.669	0.580	0.504	0.578	0.580

Çizelge 4.2'de görüldüğü üzere, Gradient Boosting algoritması AUC değerine göre en yüksek performansı göstermiştir. Bu sonuçlar, her bir algoritmanın çeşitli performans ölçütlerine göre güçlü ve zayıf yönlerini ortaya koymaktadır.

4.3. Algoritmaların Karmaşıklık Matrisi Çıktıları

Bu çalışmada, oyun performans puanlarının tahmin edilmesinde kullanılan çeşitli makine öğrenmesi algoritmalarının performansları karmaşıklık matrisi ile değerlendirilmiştir. Kullanılan algoritmalar arasında AdaBoost, Gradient Boosting (GB), kNN, Naive Bayes (NB), Random Forest (RF), Karar Ağaçları (Tree), Neural Network (NN), Stochastic Gradient Descent (SGD) ve Support Vector Machine (SVM) yer almaktadır. Her bir algoritmanın doğruluk, yanlış sınıflandırma oranı ve diğer ilgili performans metrikleri, karmaşıklık matrisi aracılığıyla analiz edilmiştir.

Çizelge 4.3, kNN algoritmasına ait karmaşıklık matrisini sunarken, diğer algoritmaların karmaşıklık matrisleri de aşağıda sırasıyla verilmiştir. Bu matrisler, her bir algoritmanın farklı sınıflar arasındaki tahmin performansını özetlemektedir. Doğru ve yanlış sınıflandırmaların ayrıntılı bir şekilde sunulması, model iyileştirme süreçlerinde hangi sınıflandırmaların düzeltilmesi gerektiğini belirlemeye yardımcı olmaktadır.

Çizelge 4. 3. kNN için Karmaşıklık Matrisi

KARMAŞIKLIK MATRİSİ		TAHMİN					Σ
		Çok iyi	Çok kötü	İyi	Mükemmel	Orta	
GERÇEK	Çok iyi	73	3	3	27	1	107
	Çok kötü	1	5	0	10	3	19
	İyi	7	0	8	0	0	15
	Mükemmel	33	6	3	37	2	81
	Orta	0	2	0	6	27	35
	Σ	114	16	14	80	33	257

Örnek sayılarını içeren AdaBoost için Karmaşıklık Matrisi Çizelge 4.4 'te sunulmuştur.

Çizelge 4. 4. AdaBoost için Karmaşıklık Matrisi

KARMAŞIKLIK MATRİSİ		TAHMİN					Σ
		Çok iyi	Çok kötü	İyi	Mükemmel	Orta	
GERÇEK	Çok iyi	75	4	1	25	2	107
	Çok kötü	3	6	0	7	3	19
	İyi	3	0	11	1	0	15
	Mükemmel	19	7	1	48	6	81
	Orta	1	4	0	5	25	35
	Σ	101	21	13	86	36	257

Örnek sayılarını içeren Tree için Karmaşıklık Matrisi Çizelge 4.5'te sunulmuştur.

Çizelge 4. 5. Tree için Karmaşıklık Matrisi

KARMAŞIKLIK MATRİSİ		TAHMİN					Σ
		Çok iyi	Çok kötü	İyi	Mükemmel	Orta	
GERÇEK	Çok iyi	76	3	3	22	3	107
	Çok kötü	4	5	0	7	3	19
	İyi	2	0	10	3	0	15
	Mükemmel	24	13	2	37	5	81
	Orta	0	6	0	6	23	35
	Σ	106	27	15	75	34	257

Örnek sayılarını içeren SVM için Karmaşıklık Matrisi Çizelge 4.6'da sunulmuştur.

Çizelge 4. 6. SVM için Karmaşıklık matrisi

KARMAŞIKLIK MATRİSİ		TAHMİN					Σ
		Çok iyi	Çok kötü	İyi	Mükemmel	Orta	
GERÇEK	Çok iyi	93	0	0	13	1	107
	Çok kötü	5	0	0	12	2	19
	İyi	5	0	0	8	2	15
	Mükemmel	32	0	0	44	5	81
	Orta	0	0	0	7	28	35
	Σ	135	0	0	84	38	257

Örnek sayılarını içeren Naive Bayes için Karmaşıklık Matrisi Çizelge 4.7’de sunulmuştur.

Çizelge 4. 7. Naive Bayes için Karmaşıklık matrisi

KARMAŞIKLIK MATRİSİ		TAHMİN					Σ
		Çok iyi	Çok kötü	İyi	Mükemmel	Orta	
GERÇEK	Çok iyi	78	1	2	25	1	107
	Çok kötü	3	7	0	5	4	19
	İyi	3	0	10	2	0	15
	Mükemmel	15	2	11	45	8	81
	Orta	0	1	0	5	29	35
	Σ	99	11	23	82	42	257

Örnek sayılarını içeren Gradient Boosting için Karmaşıklık Matrisi Çizelge 4.8’de sunulmuştur.

Çizelge 4. 8. Gradient Boosting için Karmaşıklık Matrisi

KARMAŞIKLIK MATRİSİ		TAHMİN					Σ
		Çok iyi	Çok kötü	İyi	Mükemmel	Orta	
GERÇEK	Çok iyi	82	3	1	20	1	107
	Çok kötü	3	3	0	10	3	19
	İyi	3	0	8	4	0	15
	Mükemmel	18	8	0	53	2	81
	Orta	2	2	0	6	25	35
	Σ	108	16	9	93	31	257

Örnek sayılarını içeren Neural Network için Karmaşıklık Matrisi Çizelge 4.9’da sunulmuştur.

Çizelge 4. 9. Neural Network için Karmaşıklık Matrisi

KARMAŞIKLIK MATRİSİ		TAHMİN					Σ
		Çok iyi	Çok kötü	İyi	Mükemmel	Orta	
GERÇEK	Çok iyi	93	2	0	11	1	107
	Çok kötü	4	7	0	5	3	19
	İyi	6	0	0	7	2	15
	Mükemmel	32	1	0	44	4	81
	Orta	0	1	0	5	29	35
	Σ	135	11	0	72	39	257

Örnek sayılarını içeren SGD için Karmaşıklık Matrisi Çizelge 4.10'da sunulmuştur.

Çizelge 4. 10. SGD için Karmaşıklık Matrisi

KARMAŞIKLIK MATRİSİ		TAHMİN					Σ
		Çok iyi	Çok kötü	İyi	Mükemmel	Orta	
GERÇEK	Çok iyi	99	0	0	3	5	107
	Çok kötü	8	2	1	2	6	19
	İyi	13	0	0	0	2	15
	Mükemmel	55	2	0	17	7	81
	Orta	2	1	0	1	31	35
	Σ	177	5	1	23	51	257

Örnek sayılarını içeren Random Forest için Karmaşıklık Matrisi Çizelge 4.11' de sunulmuştur.

Çizelge 4. 11. Random Forest için Karmaşıklık Matrisi

KARMAŞIKLIK MATRİSİ		TAHMİN					Σ
		Çok iyi	Çok kötü	İyi	Mükemmel	Orta	
GERÇEK	Çok iyi	88	3	1	14	1	107
	Çok kötü	2	5	0	9	3	19
	İyi	3	0	7	4	1	15
	Mükemmel	20	6	1	51	3	81
	Orta	2	2	0	4	27	35
	Σ	115	16	9	82	35	257

5. TARTIŞMA VE SONUÇ

Bu çalışmada ortaokul matematik öğretim programına yönelik tasarlanan eğitsel dijital bir oyunun oynanması sırasında elde edilen EEG verileri kullanarak oyuncu performansının tahmin edilmesi amaçlanmıştır. Çalışmada, matematik öğretiminde kullanılmak üzere geliştirilen eğitsel dijital labirent oyunu katılımcılara oynatılmış ve oyun sırasında katılımcılara ait beyin sinyalleri kaydedilmiştir. Her katılımcıdan elde edilen veriler birleştirilmiş, oyun puanları hesaplanmış ve puanlar etiketlenerek veri ön işleme sürecine geçilmiştir. Bu süreçte eksik veriler çıkarılmış, veriler normalize edilmiş ve aykırı değerler tespit edilerek gürültü azaltılmıştır.

Öznitelik seçim sürecinde, X^2 (ki-kare) fonksiyonu kullanılarak en iyi ayırt edici öznitelikler belirlenmiştir. Bu öznitelikler, POW.FC5.Gamma, POW.AF3.Gamma, EEG.O1, POW.P8.Gamma ve POW.AF3.BetaH olarak tespit edilmiştir. Bu öznitelikler oyuncuların odaklanma, dikkat, görsel işleme, uzamsal farkındalık ve bilişsel yük altında olma durumlarını yansıtmaktadır ve oyun performansını etkileyen kritik bilişsel süreçlerle ilişkilidir (Başar, 2013). Gamma dalgaları, yüksek bilişsel işlevler ve konsantrasyon gerektiren görevlerde önemli bir rol oynarken, Beta dalgaları dikkat ve uyanıklık durumlarını yansıtmaktadır (Rieder vd., 2011). FC5, AF3, O1 ve P8 gibi elektrot yerleşim noktaları ise beyin farklı bölgelerindeki aktiviteyi ölçerek bilişsel ve motor süreçlerin değerlendirilmesine olanak tanımaktadır (Vernet vd., 2012; Williams, 2012).

Matematik eğitimi için tasarlanan dijital oyunlar bağlamında, FC5 ve AF3 bölgelerindeki gamma dalgaları dikkat, karar verme ve yoğun konsantrasyon gibi yüksek bilişsel işlevlerle ilişkilidir (Wang vd., 2020). Bu bölgelerdeki artan aktivite, öğrencilerin karmaşık problem çözme süreçlerine odaklanmalarını sağlamaktadır (Handayani ve Rahmah, 2021). O1 bölgesi, görsel işleme ile ilgili beyin aktivitelerini kaydederek, öğrencilerin matematiksel görsel materyalleri daha etkili bir şekilde algılamalarına yardımcı olurken, P8 bölgesindeki gamma dalgaları mekansal farkındalık ve el-göz koordinasyonunu destekleyerek uzamsal görevlerin daha başarılı bir şekilde tamamlanmasını sağlamaktadır

(Cullen, 2022). AF3 bölgesindeki beta dalgaları ise uyanıklık, odaklanma ve hızlı problem çözme süreçlerini yansıtarak, oyun sırasında öğrencilerin doğru ve hızlı kararlar almasını kolaylaştırmaktadır (Tyas vd., 2020). Bu öznelilikler, matematik eğitimi için tasarlanan dijital oyunların, öğrencilerin bilişsel süreçlerini geliştirerek matematiksel performanslarını artırmada önemli bir rol oynadığını göstermektedir.

Elde edilen test ve skor verilerine göre, eğitsel dijital matematik oyununun performansını tahmin etmek için kullanılan en başarılı algoritmalar sırasıyla; SVM %86, Random Forest % 86.4, Neural Network % 86.8, Naive Bayes % 85.9 ve Gradient Boosting % 87.7 doğruluk oranları ile olmuştur. Özellikle Gradient Boosting algoritması, % 87.7 ile en yüksek doğruluğa sahip olup, oyuncu performansını tahmin etmede en başarılı yöntem olarak öne çıkmıştır. Buna karşılık, SGD algoritması % 66.9 doğruluk oranıyla en düşük performansı sergilemiştir. Diğer algoritmalar ise makul doğruluk oranlarıyla ortalama bir performans göstermiştir. Bu bulgular, % 85 doğruluk oranının üzerinde tahmin performansı sergileyen modellerin EEG sinyalleri ile oyun performansını değerlendirmede etkili bir şekilde kullanılabileceğini göstermektedir. Elde edilen algoritma başarımları, gelecekte yapılacak araştırmalarda eğitsel dijital matematik oyunlarının performans tahmini için hangi algoritmaların tercih edilmesi gerektiğine dair önemli ipuçları sunmaktadır. Bu objektif performans tahminleri, eğitsel dijital matematik oyun geliştiricilerine, oyunlarının kullanılabilirliğini test etme ve sonuçlara göre oyunları güncelleme veya piyasaya sürme konusunda değerli geri bildirim sağlayabilir. Ayrıca, bu çalışmada kullanılan sisteme benzer sistemler, diğer teknolojilerin test edilmesi için de temel oluşturabilir ve bu alandaki yenilikleri destekleyebilir.

Bu çalışmada, EEG sinyalleri kullanılarak anket gibi subjektif kişisel algı ve yorumlara dayanmayan, objektif veriler elde edilmesi sağlanmıştır. Bu durum, oyun sırasında katılımcıların bilişsel ve duygusal durumlarını daha standart ve nesnel bir şekilde değerlendirme imkânı sunmuştur. Verilerin, yanlışlık olasılığı düşük olan beyin sinyalleri aracılığıyla toplanması, bu durum araştırmayı önceki çalışmalardan daha yenilikçi kılmaktadır. Ayrıca, EEG verilerinin kullanımı,

oyuncu performansını daha güvenilir ve hassas bir şekilde tahmin etmeyi mümkün kılmıştır. Bu araştırma yöntemi, eğitimde dijital oyunların etkisini objektif olarak ölçen ve değerlendiren bir yaklaşım sunmakla kalmayıp eğitimde nörobilimsel verilerin kullanımına yönelik önemli katkılar sağlamıştır. Bu çalışma ile eğitim teknolojilerinde nörobilimsel verilerin daha yaygın kullanımının önünü açılmasının sağlanabileceği ve nörobilimsel verilerin dijital oyunların eğitimdeki etkisini daha derinlemesine anlamamıza yardımcı olacağı düşünülmektedir.

Sonuç olarak, bu çalışma ile matematik eğitimi için dijital oyunların tasarımında, odaklanma, dikkat ve uzamsal farkındalık gibi bilişsel işlevleri destekleyen özelliklerin ön planda tutulmasının gerektiği, EEG gibi nörobilimsel verilerin eğitimde dijital oyunların etkinliğini nesnel olarak değerlendirmek için daha yaygın kullanılmasının, oyun tasarımını iyileştirmeye katkı sağlayabileceği, ve ayrıca oyun performansını tahmin etmek için Gradient Boosting ve Neural Network gibi yüksek doğruluk oranlarına sahip algoritmaların tercih edilmesi ile kullanıcı deneyimini geliştirmek için oyun içeriği ve zorluk seviyelerinin dinamik olarak ayarlanabileceği sonucuna ulaşılmıştır.

Bu çalışmanın bulgularına dayalı olarak gelecekteki araştırmaların farklı yaş grupları ve eğitim seviyelerinde EEG verileri ile dijital oyun performansı arasındaki ilişkiyi inceleyerek özellikle ilkokul ve lise öğrencileri gibi farklı öğrenim kademelerinde bu tür dijital oyunların etkisinin nasıl değiştiğinin araştırması önemli arz etmektedir. Ayrıca, çalışmanın genellenebilirliğini artırmak amacıyla daha geniş ve çeşitli katılımcı gruplarıyla benzer araştırmalar yapılması, sonuçların farklı demografik gruplara uygulanabilirliğini test etmek açısından faydalı olacağı düşünülmektedir. Nörobilim, psikoloji ve eğitim teknolojisi gibi farklı disiplinlerin bir araya geldiği çapraz disiplinler çalışmaların artırılması ile öğrenme süreçlerini daha derinlemesine anlamaya katkıda bulunabilecektir. EEG verilerinin yanı sıra göz izleme, galvanik deri tepkisi ve kalp atış hızı gibi diğer biyometrik verilerin de dijital oyun performansının tahminlenmesinde kullanılması ise daha kapsamlı bir değerlendirme imkanı sunacaktır. Gelecek araştırmalarda, oyunların içeriği ve zorluk seviyelerinin

gerçek zamanlı olarak EEG verilerine dayanarak dinamik bir şekilde uyarlanabileceđi sistemlerin kurulması ile birlikte öğrencilerin bireysel öğrenme ihtiyaçlarına daha iyi ve anında yanıt verilebileceđi öngörülmektedir. Son olarak, eğitsel dijital oyunların uzun vadeli öğrenme başarıları ve bilişsel gelişimleri üzerindeki etkilerinin araştırılması ile dijital oyunların eğitimde sürdürülebilir etkilerini anlamaya katkı sağlanacağı düşünülmektedir.



KAYNAKLAR

- Abbass H., C. Guan and K. C. Tan. 2016. Computational Intelligence for Brain Computer Interface [Guest Editorial] in IEEE Computational Intelligence Magazine, 11(1), 18.
- Abiyev, R., Akkaya, H., Aytac, N., Ersin, Günsel, Irfan, Çağman, Ahmet. 2016. Brain-Computer Interface for Control of Wheelchair Using Fuzzy Neural Networks, 2016, BioMed Research International, 9359868, 9.
- Abuhamdeh, S., Csikszentmihalyi, M., 2012. The Importance of Challenge for the Enjoyment of Intrinsically Motivated, Goal-Directed Activities. Personality and Social Psychology Bulletin, 38(3), 317-330.
- Acı, Ç. İ., Kaya, M., Mishchenko, Y., 2019. Distinguishing mental attention states of humans via an EEG-based passive BCI using machine learning methods. Expert Systems with Applications, 134, 153-166.
- Adams, E., 2010. Fundamentals of Game Design. Kanada: New Riders.
- Aghajani H, Garbey M, Omurtag A., 2017. Measuring Mental Workload with EEG+fNIRS. Front Hum Neurosci. 2017 Jul 14; 11(359).
- Ahmad, W., Shafie, A., Latif M., 2010. Role-playing game-based learning in mathematics. Electronic Journal of Mathematics & Technology, 4(2), 184-196.
- Akın, E., 2008. Elektronik Spor: Türkiye'deki Elektronik Sporcular Üzerine Bir Araştırma, Anadolu Üniversitesi Sağlık Bilimleri Enstitüsü, Yüksek Lisans Tezi, 109s, Eskişehir.
- Alakuş T.B. ve Türkoğlu, İ., 2019. Farklı Derin Öğrenme Modelleriyle EEG Tabanlı Duygu Tahmini. 2019 4. Uluslararası Bilgisayar Bilimleri ve Mühendisliği Konferansı (UBMK), Samsun, 33-37.
- Alan, B., Sağlam, S., Aydın, B., 2016. Can CELTA qualification be the new bridge between pre-service and in-service education?: Perceptions of in-service teachers. ELT Research Journal, 5(2).
- Alexiou, A., Schippers, M. C., 2018. Digital game elements, user experience and learning: A conceptual framework. Education and Information Technologies, 23, 2545-2567.
- Alonso-Betanzos, A., Álvarez-Estévez, D., Sánchez-Marño, N., Moret-Bonillo, V., 2011. Reducing dimensionality in a database of sleep EEG arousals. Expert Systems with Applications, 38(6), 7746-7754.
- Almalı, A., 2023. Hibrit (Eeg ve nIRS) Beyin Bilgisayar Arayüzü Sistemlerinde Sınıflandırıcı Performansının İyileştirilmesi. Erzurum Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 53s, Erzurum.

- Altun, Murat. 2006. Matematik öğretiminde gelişmeler. Uludağ Üniversitesi Eğitim Fakültesi Dergisi 19(2): 223-238.
- Annetta, L. A., 2008. Video games in education: why they should be used and how they are being used. Theory Practice 47(3):229-239.
- Antequera-Barroso, J. A., Revuelta-Domínguez, F. I., Guerra Antequera, J., 2022. Similarities in procedures used to solve mathematical problems and video games. Education Sciences, 12(3), 172.
- Anwar SM, SMU Saeed ve M. Majid. 2016. Elektroensefalografi Kullanan Mobil Oyun Oyuncularının Uzman-Acemi Seviyesinin Sınıflandırılması. Uluslararası Bilgi Teknolojisinin Sınırları Konferansı (FIT), İslamabad, Pakistans. 315-318.
- Arslan, K., 2020. Eğitimde yapay zekâ ve uygulamaları. Batı Anadolu Eğitim Bilimleri Dergisi, 11(1), 71-88.
- Aslan, M., 2023. Derin Öğrenme Algoritmaları Kullanılarak EEG Sinyallerinden Yalan Tespiti. Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 91s, Elâzığ.
- Australian Council for Educational Research., 1972. Annual Report. Australian Council for Educational Research.
- Awortwe, P. K., Nyatsikor, M. K., Sarfo, D. O., 2019. Impact of using autograph software as a tool in teaching and learning of quadratic functions on gender performance. Journal of Computers in Mathematics and Science Teaching, 38(2), 97-114.
- Ay, Hüseyin C., 2023. Sinyal Ayırıştırma Teknikleri ve Derin Öğrenme Modeli Kullanılarak Eeg Sinyallerinden Zihinsel İş Yükünün Otomatik Tespiti. Dumlupınar Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, 72s, Kütahya.
- Badcock, N. A., Mousikou, P., Mahajan, Y., De Lissa, P., Thie, J., McArthur, G., 2013. Validation of the Emotiv EPOCH® EEG gaming system for measuring research quality auditory ERPs. PeerJ, 1, 38.
- Bado, Niamboue. 2022. Game-based learning pedagogy: a review of the literature, Interactive Learning Environments, 30(5), 936-948.
- Banerjee, C., Mukherjee, T., Pasiliao Jr, E., 2019. An empirical study on generalizations of the ReLU activation function. In Proceedings of the 2019 ACM Southeast Conference, 164-167.
- Bano, K.S. P. Bhuyan and A. Ray. 2022. EEG-Based Brain Computer Interface for Emotion Recognition. 2022 5th International Conference on Computational Intelligence and Networks (CINE), Bhubaneswar, India, 2022, 1-6.
- Barab, S., Pettyjohn, P., Gresalfi, M., Volk, C., Solomou, M., 2011. Game-based curriculum and transformational play: Designing to meaningfully

- positioning person, content, and context. *Computers & Education*, 58(1), 518-533.
- Başar, E. 2013. A review of gamma oscillations in healthy subjects and in cognitive impairment. *International Journal of Psychophysiology*, 90(2), 99-117.
- Baykul, Y., 2009. İlköğretimde Matematik Öğretimi (6-8. Sınıflar). Pegem Akademi, Ankara.
- Becker, S.A., Brown, M., Dahlstrom, E., Davis, A., DePaul, K., Diaz, V. ve Pomerantz, J., 2018. Horizon report 2018 higher education edition brought to you by Educause, 1-54.
- Beggs, R., P. O'Neill, K. Virapen ve S. Alexander. 2009. The Perception of Gaming in Higher Education: Gaming Habits of University of Ulster Staff. Ciddi Uygulamalar için Oyunlar ve Sanal Dünyalar Konferansı, Coventry, Birleşik Krallık, 2009,174-177.
- Bekkedal, M. Y., Rossi III, J., Panksepp, J. 2011. Human brain EEG indices of emotions: delineating responses to affective vocalizations by measuring frontal theta event-related synchronization. *Neuroscience & Biobehavioral Reviews*, 35(9), 1959-1970.
- Bell, I. R., Lewis II, D. A., Lewis, S. E., Schwartz, G. E., Brooks, A. J., Scott, A., Baldwin, C. M., 2004. EEG alpha sensitization in individualized homeopathic treatment of fibromyalgia. *International journal of neuroscience*, 114(9), 1195-1220.
- Benitez, D.S., Toscano S. and Silva, A., 2016. On the use of the Emotiv EPOCH neuroheadset as a low cost alternative for EEG signal acquisition. 2016 IEEE Colombian Conference on Communications and Computing (COLCOM), Cartagena, Colombia, 1-6.
- Bentéjac, C., Csörgő, A., Martínez-Muñoz, G., 2021. A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, 54, 1937-1967.
- Bergstrom, K., 2022. When a door becomes a window: using Glassdoor to examine game industry work cultures. *Information, Communication & Society*, 25(6), 835-850.
- Bertens, P., Guitart A. and Periañez, A., 2017. Games and big data: A scalable multi-dimensional churn prediction model. 2017 IEEE Conference on Computational Intelligence and Games (CIG), New York, NY, USA, 2017, 33-36.
- Bilişim Vadisi. (y.y.)2021. Re-Think Dijital Oyun e-Çalıştayı Sonuç Raporu. Erişim Tarihi: 25.04.2023 https://bilisimvadi.com.tr/wp-content/uploads/2022/05/Dijital_Oyun_Calistay_Raporu-Re-Think.pdf.
- Blackwood, D. H. R., Muir, W. J., 1990. Cognitive brain potentials and their application. *The British Journal of Psychiatry*, 157(S9), 96-101.

- Bloom, B.S., 1968. Eğitim psikolojisi: Modern eğitimin psikolojik temelleri, Gül Yayınevi, Ankara.
- Bodnar, Cheryl A., Daniel Anastasio, Joshua A. Enszer, Daniel D. Burkey. 2015. Engineers at Play: Games as Teaching Tools for Undergraduate Engineering Students. First published: 20 December 2015.
- Bourgonjon, J., De Grove, F., De Smet, C., Van Looy, J., Soetaert, R., Valcke, M., 2013. Acceptance of game-based learning by secondary school teachers. Computers & Education, 67, 21–35.
- Boyle, E. A., Hainey, T., Connolly, T. M., Gray, G., Earp, J., Ott, M., & Pereira, J., 2016. An update to the systematic literature review of empirical evidence of the impacts and outcomes of computer games and serious games. Computers & Education, 94, 178–192.
- Bozkurt, A., 2014. Homo Ludens: Dijital Oyunlar ve Eğitim. Eğitim Teknolojileri Araştırmaları Dergisi. 5(1).
- Büyükgöze, S., 2019. Sağlık 4.0’da giyilebilir teknolojilerden sensör yamalar üzerine bir inceleme. Avrupa Bilim ve Teknoloji Dergisi, (17), 1239-1247.
- Büyükgöze, S., Üstünel, H., Doğan, Ü., Zengin, E., & İlhan, U., 2021. Simplified Human Computer Interface Design Using EEG Signals. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 12(2), 201-210.
- Caesarendra W., M. Ariyanto, S. U. Lexion, E. D. Pasmanasari, C. R. Chang and J. D. Setiawan. 2015. EEG based pattern recognition method for classification of different mental tasking: Preliminary study for stroke survivors in Indonesia. International Conference on Automation Cognitive Science Optics Micro Electro-Mechanical System and Information Technology (ICACOMIT),138-144.
- Calvo R.A., D'Mello.S., 2010. Affect detection: An interdisciplinary review of models methods and their applications. IEEE Transactions on Affective Computing, 1(1), 18-37.
- Can, G., & Cagiltay, K., 2006. Turkish prospective teachers’ perceptions regarding the use of computer games with educational features. Educational Technology & 62 PEER REVIEWED PAPERS Je-LKS13(2), May 2017 Society, 9(1), 308–321.
- Castaño-Candamil S., 2015. Uzay-zaman-frekans yapılı seyreklik kısıtlamalarına dayalı eeg ters problemini çözme, NeuroImage, 118, 598 – 612.
- Cernea, D., Olech, P. S., Ebert, A., & Kerren, A., 2011. EEG-based measurement of subjective parameters in evaluations. In HCI International 2011–Posters’ Extended Abstracts: International Conference, HCI International 2011, Orlando, FL, USA, July 9-14, 2011, Proceedings, Part II 14, 279-283. Springer Berlin Heidelberg.
- Cernea, D., Olech, PS., Ebert, A., 2012. Özneliğin Ölçülmesi. Künstl Intell 26, 177–182.

- Chandra, S., Sharma, G., Salam, A. A., Jha, D. and Mittal, A. P., 2016. Playing action video games a key to cognitive enhancement, *Procedia computer science*, 84, 115-122.
- Chatterjee, R., Datta, A., Sanyal, D. K., 2019. Ensemble learning approach to motor imagery EEG signal classification. *Machine Learning in Bio-Signal Analysis and Diagnostic Imaging*, 29(3), 183-208.
- Chen, W. C., Lee, A. H. I., Deng, W. J. and Liu, K. Y., 2007. The implementation of neural network for semiconductor PECVD process, *Expert Systems with Applications*, 32 (4), 1148-1153.
- Ciolacu M. I., A. F. Tehrani, P. Svasta, I. Tache and D. Stoichescu. 2020. Education 4.0: An Adaptive Framework with Artificial Intelligence, Raspberry Pi and Wearables- Innovation for Creating Value, 2020 IEEE 26th International Symposium for Design and Technology in Electronic Packaging (SIITME), 298-303.
- Coleman, T. E., & Money, A. G., 2020. Student-centred digital game-based learning: a conceptual framework and survey of the state of the art. *Higher Education*, 79, 415-457.
- Connolly, T. M., Boyle, E. A., MacArthur, E., Hainey, T., & Boyle, J. M., 2012. A systematic literature review of empirical evidence on computer games and serious games. *Computers & education*, 59(2), 661-686.
- Cullen, S. A. 2022. Research on The Effects of Art Education on Childhood Cognitive Development: A Literature Review Thesis Surveying Brain Architecture and Neural Activity (Master's thesis, The Ohio State University).
- Çağıltay, N. E., 2007. Teaching software engineering by means of computer-game development: Challenges and opportunities. *British Journal of Educational Technology*, 38(3), 405-415.
- Çankaya, S. ve Karamete A., 2008. Eğitsel Bilgisayar Oyunlarının Öğrencilerin Matematik Dersine ve Eğitsel Bilgisayar Oyunlarına Yönelik Tutumlarına Etkisi. *Mersin Üniversitesi Eğitim Fakültesi Dergisi*, 4(2).
- Çolakoğlu, M., Korkusuz, M.E., 2022. 2st International Conference on Educational Technology and Online Learning – ICETOL 2022 Full Paper Proceedings 293 Türkiye’de Eğitsel Bilgisayar Oyunları ile İlgili Yapılan Çalışmaların İncelenmesi.
- De Grove, F., Bourgonjon, J., & Van Looy, J., 2012. Digital games in the classroom? A contextual approach to teachers’ adoption intention of digital games in formal education. *Computers in Human Behavior*, 28(6), 2023–2033.
- De Smedt, B., Ansari, D., Grabner, R. H., Hannula-Sormunen, M., Schneider, M., & Verschaffel, L., 2011. Cognitive neuroscience meets mathematics education: It takes two to tango. *Educational research review*, 6(3), 232-237.

- Debener, S., F. Minow, E. Emkes, K. Gandras ve M. De Vos. 2012. Düşük maliyetli, küçük ve kablolu bir EEG ile yürüyüşe çıkmaya ne dersiniz? *Psikofizyoloji*, 49(11), 1617-1621.
- Debener, S. and Bleichner, M.G., 2019. Transparent electroencephalography? : Exploring ear-EEG for long-term, mobile electrophysiology. 2019 7th International Winter Conference on Brain-Computer Interface (BCI), Gangwon, Korea (South), 1-2.
- Demirbilek, M., Tamer, S. L., 2010. Math teachers' perspectives on using educational computer games in math education. *Procedia-Social and Behavioral Sciences*, 9, 709-716.
- Di Stasi, L. L., Antolí, A. & Cañas, J. J., 2013. Evaluating mental workload while interacting with computer-generated artificial environments. *Entertainment Computing*, 4(1), 63-69.
- Di Sun, 2021. Educational Quality Evaluation Model of Innovative and Entrepreneurial Talents Based on Information Technology. In 2021 4th International Conference on Information Systems and Computer Aided Education (ICISCAE 2021). Association for Computing Machinery, New York, NY, USA, 1144-1148.
- Dicheva, D., Dichev, C., Agre, G., & Angelova, G., 2015. Gamification in education: A systematic mapping study. *Educational Technology & Society*, 18(3), 75-88.
- Dijital Oyun Raporu, Ankara Kalkınma Ajansı, 2016. (y.y.) Erişim Tarihi: 24.04.2023 <https://www.kalkinmakutuphanesi.gov.tr/dokuman/dijital-oyun-sektoru-raporu/60>.
- Dijital Oyun Sektörü Raporu, 2016. Ankara Kalkınma Ajansı. Erişim Tarihi: 22.04.2023 <http://www.ankaraka.org.tr/tr/files/yayinlar/ankaraka-dijital-oyun-sektoru.pdf>. Yayın Yılı. 2016. Belge İçeriği. 60 Sayfa. 2.08 MB.
- Dillon, R., 2011. 'The Golden Age of Video Games', The Birth of a Multi- Billion Dollar Industry, ABD: A K Peters/CRC Press.
- Doğan, Ş., ve Türkoğlu, İ., 2007. Hypothyroidi and Hyperthyroidi Detection from Thyroid Hormone Parameters by Using Decision Trees, *Doğu Anadolu Bölgesi Araştırmaları Dergisi*, 5(2), 163-169.
- Dol S.M., P. M. Jawandhiya. 2022. Use of Data mining Tools in Educational Data Mining. Fifth International Conference on Computational Intelligence and Communication Technologies (CCICT), Sonapat, India, 2022, 380-387.
- Dong, Z., 2022. Research of Big Data Information Mining and Analysis: Technology Based on Hadoop Technology. 2022 International Conference on Big Data, Information and Computer Network (BDICN), 2022, 173-176.
- Donoghue, J.P., 2002. Connecting cortex to machines: recent advances in brain interfaces, *Nat. Neurosci.*, 5: Supp (2002) 1085-1088.

- Dursun, D.G., 2023. Biyomedikal imgeler için yapay zekâ tabanlı hücre segmentasyonu yöntemi. Süleyman Demirel Üniversitesi. Fen Bilimleri Enstitüsü. Elektronik ve Haberleşme Mühendisliği Ana Bilim Dalı, Doktora Tezi, 100s, Isparta.
- Emin-Martinez, V., Ney, M., 2013. Supporting teachers in the process of adoption of game based learning pedagogy. In Proceedings of the 7th European Conference on Games Based Learning: Academic Conferences International Limited.
- Emotiv. 2023 (t.y.), (y.y.) Brainwear. Erişim Tarihi: 07.02.2023 <https://www.emotiv.com/product/emotiv-insight-5-channel-mobile-brainwear/>
- Erbay, B., Adaş, E., 2022. Yapay Zekâ Sosyolojisi Üzerine Bir Değerlendirme. Gaziantep University Journal of Social Sciences, 21(1), 326-337.
- Esposito, Nicolas. 2005. "A Short and Simple Definition of What a Videogame Is." (2005, January). In Proceedings of DiGRA 2005 Conference: Changing Views: Worlds in Play.
- Feng, S., S. Wang, Y. Chen, S. Zhang and L. Zhang, "An Integrated Observing Technic for Collaborative Learning: The Multimodal Learning Analytics Based on the Video Coding and EEG Data Mining. 2021. 2021 IEEE International Conference on Engineering, Technology & Education (TALE), Wuhan, Hubei Province, China, 1097-1101.
- Forslund, G. H., 2018. Implementing Self-determination Theory in Mobile Applications-A systematic literature review of research in the field of noncommunicable diseases. Master's thesis. NTNU.
- Frasca, G., 2004. Videogames of the Oppressed. In Wardrip-Fruin, N. & Harrigan, P. (eds), First Person, MIT Press.
- Fritsch, M., 2013. Video Oyunu Müziğinin Tarihi. İçinde: Moormann, P. (eds) Müzik ve Oyun. Müzik ve Medien. Springer VS, Wiesbaden.
- Gacar, B.K., 2023. Fonksiyonel Veri Analizinin Karar Ağaçlarında Kullanımı. Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı Ekonometri Programı. Doktora Tezi, 186s, İzmir.
- García-Monge, A., Rodríguez-Navarro, H., & Marbán, J. M., 2023. Potentialities and Limitations of the Use of EEG Devices in Educational Contexts. Comunicar: Media Education Research Journal, 31(76), 47-57.
- Garcia-Monge, A., Torres-Ruiz, F. J., & Sanchez, C. A., 2023. Portable EEG Devices in Education: A Literature Review and Perspectives. Journal of Educational Technology & Society, 26(1), 59-70.
- Gee, J.P., 2003. What Video Games Have to Teach Us about Learning and Literacy, N.Y.: Palgrave Macmillan.

- Goenaga, S., Navarro, L., Quintero M, C. G., & Pardo, M., 2020. Imitating human emotions with a nao robot as interviewer playing the role of vocational tutor. *Electronics*, 9(6), 971.
- Gordillo, A., López-Fernández, D., & Tovar, E., 2022. Comparing the effectiveness of video-based learning and game-based learning using teacher-authored video games for online software engineering education. *IEEE Transactions on Education*, 65(4), 524-532.
- Gözalan, E., Koçak, N., 2014. KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi 16 (Özel Sayı II): 115-121, 2147(7833), www.kmu.edu.tr Oyun Temelli Dikkat Eğitim Programının 5-6 Yaş Çocukların Kelime Bilgi Düzeylerine Etkisinin incelenmesi.
- Graafland, M., Schraagen, J. M., & Schijven, M. P., 2012. Systematic review of serious games for medical education and surgical skills training. *British Journal of Surgery*, 99(10), 1322-1330.
- Grabner, RH., De Smedt, B., 2012."Aritmetik Stratejilerin Salınlı EEG Korelasyonları: Bir Eğitim Çalışması", *Ön. Psikol.* 3.
- Guo, L., Daniel Rivero, Julián Dorado, Juan R. Rabuñal, Alejandro Pazos. 2010. Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks, *Journal of Neuroscience Methods*, 191(1), 101-109.
- Guo, W., Weiwei Qin, Dezhong Zheng, Tainian Song, Pengfei Zhang. 2021. "P300 Detection Adaptive Channel Selection Method under the Multiple Kernel Learning", 2021 IEEE International Conference on Emergency Science and Information Technology (ICESIT), s.898-902.
- Gutiérrez, D., & Ramírez-Moreno, M. A., 2016. Assessing a learning process with functional ANOVA estimators of EEG power spectral densities. *Cognitive neurodynamics*, 10(2), 175-183.
- Gündüzalp, C., 2021. Web 2.0 Araçları ile Zenginleştirilmiş Çevrimiçi Öğrenmenin Öğrencilerin Üst Bilişsel ve Yaratıcı Düşünme Becerilerine Etkisi. *Uluslararası Türkçe Edebiyat Kültür Eğitim (Teke) Dergisi*, 10(3), 1158-1177.
- Gürçan, A., 2008. Dijital Oyunlar ve Çocuklar Üzerindeki Etkileri, T.C. Başbakanlık Aile ve Sosyal Araştırmalar Genel Müdürlüğü, Ankara.
- Gürsakal, N., 2014. Büyük Veri., Dora Basım Yayın. Bursa.
- Hainey, T., Connolly, T. M., Boyle, E. A., Wilson, A., & Razak, A., 2016. A systematic literature review of games-based learning empirical evidence in primary education. *Computers & Education*, 102, 202-223.
- Halaçoğlu, Burcu Nehir. 2020. Video Oyun Evreninde Yol Bulmak: Sınıflandırma ve Türler, Ankara: Gece Kitaplığı.

- Haleem, A., Mohd Javaid, Mohd Asim Qadri, Rajiv Suman. 2022. Understanding the role of digital technologies in education: A review, *Sustainable Operations and Computers*, 3, 275-285.
- Hall, J.E. and Hall, M.E., 2020. *Guyton and hall textbook of medical physiology e-book*, Elsevier Health Sciences, Philadelphia, ISBN: 978-0-323-64003-9.
- Hamari, J., Nousiainen, T., 2015. Why do teachers use game-based learning technologies? The role of individual and institutional ICT readiness. In *Proceedings of the 48th Hawaii International Conference on System Sciences (HICSS)*, 682-691. IEEE.
- Handayani, N., Rahmah, G. 2021. Analisis Spektral Daya dan Koherensi Sinyal Electroencephalography (EEG) Area Frontal Pada Pecandu Rokok. *Sunan Kalijaga Journal of Physics*, 3(1), 9-18.
- Harika, J., P. Baleeshwar, K. Navya and H. Shanmugasundaram. 2022. "A Review on Artificial Intelligence with Deep Human Reasoning," 2022 International Conference on Applied Artificial Intelligence and Computing (ICAAIC), pp. 81-84.
- Harmon-Jones, E., 2003. Clarifying the emotive functions of asymmetrical frontal cortical activity *Psychophysiology*, 40 (6), 838-848.
- Hawsawi, O., and Semwal, S.K., 2014. "EEG headset supporting mobility impaired gamers with game accessibility," 2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC), 837-841.
- Hızar, Şuayb. 2023. Go/Nogo Testi ile Eeg Verilerinin Destek Vektör Makineleri, Doğrusal Ayırma Analizi ve Rastgele Orman Algoritmaları ile Sınıflandırılması. Üsküdar Üniversitesi, Sağlık Bilimleri Enstitüsü, YL Tezi, 34s, İstanbul.
- Holewa, K., and A. Nawrocka, 2014. "Emotiv EPOCH neuroheadset in brain-computer interface," *Proceedings of the 2014 15th International Carpathian Control Conference (ICCC)*, Velke Karlovice, Czech Republic, 149-152.
- Hornyák, O., Iantovics, L. B. 2023. AdaBoost algorithm could lead to weak results for data with certain characteristics. *Mathematics*, 11(8), 1801.
- Hostetter, O., 2002. Video games-the necessity of incorporating video games as part of constructivist learning. *Game research: The Art, Business and Science of Computer Games*.
- Hu, PC., P.-H. Chen and P.-C. Kuo, 2018. "Educational Model Based on Hands-on Brain-Computer Interface: Implementation of Music Composition Using EEG," 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Miyazaki, Japan, 982-985.
- Hu, L., Zhang, Z. (Eds.), 2019. *EEG signal processing and feature extraction*. Springer. 89-116.

- Huang, R., 2019. Educational technology a primer for the 21st century. Springer Nature Singapore Pte Ltd.
- Huizinga, Johan. 2015. Homo Ludens Oyunun Toplumsal İşlevi Üzerine Bir Deneme. İstanbul: Ayrıntı Yayınları.
- Hussein, M. H., Ow, S. H., Cheong, L. S., Thong, M. K., & Ebrahim, N. A., 2019. Effects of digital game-based learning on elementary science learning: A systematic review. IEEE Access, 7, 62465-62478.
- Jantakun, T., Jantakun, K., & Jantakoon, T., 2021. A Common Framework for Artificial Intelligence in Higher Education (AAI-HE Mode). International Education Studies, 14(11), 94-103.
- Jewell, J., 2009. Brain Fitness at Work. Bounty Books. 144.
- Johnson, C. I., & Mayer, R. E., 2010. Applying the self-explanation principle to multimedia learning in a computer-based game-like environment. Computers in Human Behavior, 26(6), 1246-1252.
- Jun, Guo ve Kavallur Gopi Smitha. 2016. "EEG tabanlı stres seviyesi tanımlama." IEEE uluslararası sistemler, insan ve sibernetik konferansı (SMC). IEEE.
- Kalikov, A., 2006. Veri Madenciliği ve Bir E-Ticaret Uygulaması, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 94s, Ankara.
- Kamel, H., Abdulah, D. and Al-Tuwaijari, J. M., 2019, Cancer classification using gaussian naive bayes algorithm, 2019 International engineering conference (IEC), 23-25 June 2019 Erbil, IEEE, 165-170.
- Kandel, E. R., Schwartz, J. H., Jessell, T. M., Siegelbaum, S., Hudspeth, A. J., & Mack, S. (Eds.). 2000. Principles of neural science, 4, 1227-1246). New York: McGraw-hill.
- Kang E.S., B.-C. Kim and H.-I. Suk, 2016. "An empirical suggestion for collaborative learning in motor imagery-based BCIs," 2016 4th International Winter Conference on Brain-Computer Interface (BCI), Gangwon, Korea (South), 1-3.
- Kannadasan, K., J. Shukla, S. Veerasingam, B. S. Begum and N. Ramasubramanian, 2024. "An EEG-Based Computational Model for Decoding Emotional Intelligence, Personality, and Emotions," in IEEE Transactions on Instrumentation and Measurement, 73, 1-13, 2505413.
- Karaboyacı, C., 2009. Geometrik özellik temelli yüz ifadesi analizi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 109s, İstanbul.
- Karahisar, Tüba. 2013. Türkiye’de Dijital Oyun Sektörünün Durumu State Of The Digital Gaming Industry In Turkey., İstanbul Gelişim Üniversitesi Güzel Sanatlar Fakültesi.

- Kärki, T., McMullen, J., Lehtinen, E., 2022. Improving rational number knowledge using the NanoRoboMath digital game. *Educational Studies in Mathematics*, 110(1), 101-123.
- Ke, F., 2008. Computer games application within alternative classroom goal structures: Cognitive, metacognitive, and affective evaluation. *Educational Technology. Research and Development*, 56, 539-556.
- Keleş, P., 2018. Fen Bilimleri Dersi Öğretim Programı Hakkında Beşinci Sınıf Fen Bilimleri Öğretmenlerinin Görüşleri. *Eğitimde Nitel Araştırmalar Dergisi*, 6(3), 121-142.
- Keleş, Tuğçe. 2023. Eeg Sinyalleri Kullanılarak Yeni Nesil Cümle Sınıflandırma Modellerinin Geliştirilmesi. Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 54s. Elâzığ.
- Ketkar, N., & Ketkar, N., 2017. Stochastic gradient descent. *Deep learning with Python: A hands-on introduction*, 113-132.
- Kızılkaya, E; 2010. Bilgisayar Oyunlarında İdeolojik Söylem ve Anlatı, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 215s, İstanbul.
- Kim, M., S. Kim, O. Khera, J. Getman. 2014. The experience of three flipped classrooms in an urban university: An exploration of design principles *The Internet and Higher Education*, 22, 37-50, 10.1016/j.iheduc.2014.04.003.
- Kirkpatrick, R., Zang, Y., 2011. "The negative influences of exam-oriented education on Chinese high school students: Backwash from classroom to child." *Language testing in Asia* 1(3), 36.
- Kirriemuir, J., 2002. Video gaming, education and digital learning technologies. *D-Lib Magazine*, 8(2).
- Klados, M.A., P. Simos, S. Micheloyannis, D. Margulies and P. D. Bamidis. 2015. "ERP measures of math anxiety: how math anxiety affects working memory and mental calculation tasks?", *Front. Behav. Neurosci.*, 9, Oct.
- Kober, S. E., Wood, G., Kiili, K., Moeller, K., & Ninaus, M., 2020. Game-based learning environments affect frontal brain activity. *Plos one*, 15(11), e0242573.
- Koç, Durmuş. 2022. Video Oyun Yaş Etiketlerinin Çok Modlu Biyosinyaller ve YapayZeka ile Tahmini. İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 130s, İstanbul.
- Koça, E., 2015. Oyun Tabanlı Eğitim: Çok Oyunculu Çevrimiçi Rol Yapma (MMORPG) Oyun Türüne Yönelik Bir Uygulama. *Bildiri Özetleri*, 17.
- Kolb, David. 1984. *Experiential Learning: Experience As The Source Of Learning And Development*.
- Konar, A.; Chakraborty, A., 2015. *Duygu Tanıma: Bir Örüntü Analizi Yaklaşımı*; John Wiley & Sons: Hoboken, NJ, ABD, ISBN 9781118910566.

- Koo, B., Y. Nam and S. Choi. 2014. "A hybrid EOG-P300 BCI with dual monitors," 2014 International Winter Workshop on Brain-Computer Interface (BCI), Gangwon, Korea (South),1-4.
- Koparan, T., 2021. Yükseköğretimde dijital oyun tabanlı öğrenme ortamından yansımaların incelenmesi. Yükseköğretim ve Bilim Dergisi, 11(3): 503-515.
- Kovalerchuk, B., Vityaev, E., 2005. Data mining in finance: advances in relational and hybrid methods, 547. Springer Science & Business Media.
- Köksal, H., 2023. Eeg Sinyallerini Kullanan Makine Öğrenmesi Tabanlı Kategorik Duygu Sınıflandırma Modeli. Ardahan Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, 78s, Ardahan.
- Krishnan, P.; Yaacob, S., 2019. EEG sinyallerine dayalı bant gücü ve log enerji entropi özelliklerini kullanarak uyukluk tespiti. Uluslararası J. Yenilik. Teknoloji. Keşfet. Müh., 8, 830–836.
- Kuber, R., & Wright, F. P., 2013. Augmenting the instant messaging experience through the use of brain-computer interface and gestural technologies. International Journal of Human-Computer Interaction, 29(3), 178-191.
- Kuduz, Betül. 2023. Etkileşimli Kitap Okuma Programının İşitme Yetersizliği Olan 6 Yaş Grubu Çocukların Dikkat ve Anlama Seviyelerine Etkisinin Mobil Eeg Cihazı Kullanılarak Ölçülmesi. Kto Karatay Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek lisans Tezi, 105s, Konya.
- Kumar, S. J., & Bhuvaneswari, P., 2012. Analysis of Electroencephalography (EEG) signals and Its categorization-A study. Procedia Engineering, 38, 2525-2536.
- Kumar, N., Khaund, K. and Hazarika, S. M., 2016, Bispectral analysis of EEG for emotion recognition, Procedia computer science, 84, 31-35.
- Kuss, D. J., & Griffiths, M. D., 2012. Internet gaming addiction: A systematic review of empirical research. International Journal of Mental Health and Addiction, 10(2), 278–296.
- Liarokapis, F., Debattista, K., Vourvopoulos, A., Petridis, P. ve Ene, A., 2014. Ciddi oyunlar için etkileşim tekniklerinin beyin-bilgisayar arayüzleri aracılığıyla karşılaştırılması: Bir kullanıcı algısı değerlendirme çalışması. Eğlence Bilgisayarı, 5 (4), 391-399.
- Lievesley R., Wozencroft M., D. Ewins., 2011.The Emotiv EPOCH neuroheadset: An inexpensive method of controlling assistive technologies using facial expressions and thoughts? Journal of Assistive Technologies, 5 (2), 67-82.
- Lin, T. C., Lin, T. J., & Tsai, C. C., 2014. Research trends in science education from 2008 to 2012: A systematic content analysis of publications in selected journals. International Journal of Science Education, 36(8), 1346-1372.

- Liu, Z., Qian, Q., Hu, B., Shang, W. L., Li, L., Zhao, Y., ... & Han, C., 2022. Government regulation to promote coordinated emission reduction among enterprises in the green supply chain based on evolutionary game analysis. *Resources, Conservation and Recycling*, 182, 106290.
- López-Fernández, D., A. Gordillo, J. Pérez and E. Tovar, 2023. Learning and Motivational Impact of Game-Based Learning: Comparing Face-to-Face and Online Formats on Computer Science Education, in *IEEE Transactions on Education*, 66(4), 360-368, Aug. 2023.
- Luo A., Sullivan T.J., 2010. A user-friendly SSVEP-based brain-computer interface using a time-domain classifier *Journal of Neural Engineering*, 7 (2), 1-10.
- Maksatbekova, A., 2019. Sanal gerçeklik oyunlarının dayanılmaz çekiciliği: Zihnen, bedenlen ve ruhen., Anadolu University, Sosyal Bilimler Enstitüsü, Master's thesis, 157s, Eskişehir.
- Mali Z., and C. Huaxi, 2019. "On Application of "Artificial Intelligence Plus Large Data" in Public Maths Course Teaching of Engineering Colleges," 2019 International Conference on Smart Grid and Electrical Automation (ICSGEA), 2019, 276-279.
- Mampusti, E.T., J.S. Ng, J.J.I. Quinto, G.L. Teng, M.T.C. Suarez, R.S. Trogo. 2011. Measuring academic affective states of students via brainwave signals *Proceedings of the 2011 third international conference on knowledge and systems engineering (KSE)*, 226-231, 10.1109/KSE.2011.43.
- Mangiron, C., & O'Hagan, M., 2006. Video Games Localisation: Unleashing Imagination with Restricted Translation. *Journal of specialised translation*, (6), 10-21.
- Mano, A., Falcão, A., Godinho, I., Santos, J., Leitão, F., Oliveira, C., & Caramona, M., 2005. CA-125 AUC as a new prognostic factor for patients with ovarian cancer. *Gynecologic oncology*, 97(2), 529-534.
- Marner, L., Nyengaard, J.R., Tang, Y. and Pakkenberg, B., 2003. Marked loss of myelinated nerve fibers in the human brain with age. *J. Comp. Neurol.*, 462: 144-152.
- Marquardt, A., 2014. "HealthSCOPE: An Interactive Distributed Data Mining Framework for Scalable Prediction of Healthcare Costs," 2014 IEEE International Conference on Data Mining Workshop, Shenzhen, China, 2014, 1227-1230.
- Martin S., 2011. Eğitimde yeni teknoloji trendleri: Yedi yıllık tahminler ve yakınsama, *Bilişim. Eğitim* _ 57, 1893 – 1906.
- Maskeliunas, R., Damasevicius, R., Martisius, I., & Vasiljevas, M., 2016. Consumer-grade EEG devices: are they usable for control tasks?. *PeerJ*, 4, e1746.
- McCarthy, K., McGinty, L., & Smyth, B. Reilly, J., 2004. Incremental critiquing. In *International Conference on Innovative Techniques and Applications of Artificial Intelligence*, 101-114. London: Springer London.

- MEB, 2016. Özel Öğretim Kurumları ve Eğitim Öğretim Faaliyetleri 21.06.2016 Tarihli 6813853 Sayılı Genelge.
- Merdin, M., 2020. Mobil oyunlarda grafik arayüzlerinin oyuncu tercihleri üzerindeki etkileri: Üniversite öğrencileri üzerine bir araştırma. KTO Karatay Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 133s, Konya.
- Mert A, T. Nijboer, B. Doyen, H. Meijer ve M. Dankbaar, 2018. A Medical Serious Games Framework Hierarchy for Validity. 10th International Conference on Virtual Worlds and Games for Serious Applications (VS-Games), Würzburg, Almanya, 2018, 1-2.
- Millán, JDR, Rupp, R., Mueller-Putz, G., Murray-Smith, R., Giugliemma, C., Tangemann, M., ... ve Mattia, D., 2010. Beyin-Bilgisayar Arayüzlerini ve Yardımcı Teknolojileri Birleştirmek: Son Teknoloji ve Zorluklar. Sinirbilimde Sınırlar, 161.
- Moghimi, M., Stone, R. and Rotshtein, P., 2020, Affective recognition in dynamic and interactive virtual environments, IEEE transactions on affective computing, 11 (1), 45-62.
- Moreno-Ramirez, MA; Díaz-Padilla, M.; Valenzuela-Gómez, KD; Vargas-Martínez, A.; Tudón-Martínez, JC; Morales-Menendez, R.; Ramirez-Mendoza, RA; Pérez-Henríquez, BL; Lozoya-Santos, JdJ., 2021. Üniversite Öğrencilerinin Sınıftaki Bilişsel Performansını Tahmin Etmek İçin EEG Tabanlı Araç. Beyin Bilimi 2021, 11(698).
- Morrison JL., 2002. Information technology and the future of education: An interview with Diana Oblinger cholar. google.co. id/citations? view_op= view_ citation& hl= id&user=1S4If_UAAAAJ&citation_for_view=1S4If_UAAAAJ:JV2RwH3_ST0 C. Erişim Tarihi: 20.09.2023.
- Nabiyev, V., & Erümit, A. K., 2020. Eğitimde Yapay Zeka Kuramdan Uygulamaya. Pegem Akademi Yayınları, Ankara.
- Nacke L.E, S. Stellmach, C.A. Lindley, 2011. Electroencephalographic assessment of player experience: A pilot study in affective ludology Simulation & Gaming, 42 (5) (2011), 632-655.
- Naidoo, R., Coleman, K., Guyo, C., 2020. Exploring gender discursive struggles about social inclusion in an online gaming community. Information Technology & People, 33(2), 576-601.
- Ngo, C. Q., Chai, R., Jones, T. W., Nguyen, H. T., 2021. The effect of hypoglycemia on spectral moments in EEG epochs of different durations in type 1 diabetes patients. IEEE Journal of Biomedical and Health Informatics, 25(8), 2857-2865.

- Nolan, J., McBride, M., 2014. Beyond gamification: reconceptualizing game-based learning in early childhood environments. *Information, Communication & Society*, 17(5), 594-608.
- Nolen-Hoeksema, S., Morrow, J., 1991. A Prospective Study of Depression and Posttraumatic Stress Symptoms After a Natural Disaster: The 1989 Loma Prieta Earthquake. *Journal of Personality and Social Psychology*, 61(1), 115-121.
- Novak, D., Mihelj, M., & Munih, M. 2012. A survey of methods for data fusion and system adaptation using autonomic nervous system responses in physiological computing. *Interacting with computers*, 24(3), 154-172.
- NTV, 2022. (y.y.) Yapay zeka kart oyunu br  te 8 d  nya   ampiyonunu yendi. Eri  im Tarihi: 29.04.2023 https://www.ntv.com.tr/teknoloji/yapay-zeka-kart-oyunu-bricte-8-dunya-sampiyonunu-yendi,4bxec_dSYEakjdBR3htJYA
- Nugroho, E.W., and B. Harnadi, 2019. "The Method of Integrating Virtual Reality with Brainwave Sensor for an Interactive Math's Game," 2019 16th International Joint Conference on Computer Science and Software Engineering (JCSSE), Chonburi, Thailand, 2019, 359-363.
- Nunez P.L., R. Srinivasan, 2006. A theoretical basis for standing and traveling brain waves measured with human EEG with implications for an integrated consciousness *Clinical Neurophysiology*, 117 (11) (2006), pp. 2424-2435 *Silicon Valley Looks to Artificial Intelligence for the Next Big Thing*, January 2016.
- OECD (2020c), *Education at a Glance 2020: OECD Indicators*, OECD Publishing, Paris.
- O'Hagan, M., Mangiron, C., 2013. "Game localization." Amsterdam: John Benjamins Publishing Company, 386p., Benjamins Translation Library, ISBN: 9789027271860.
- Olfers, K.J.F., Band, G.P.H. 2018. Game-based training of flexibility and attention improves task-switch performance: near and far transfer of cognitive training in an EEG study. *Psychological Research* 82, 186–202 (2018).
-   zer, M.G., 2022. Yabancı Uyruklu İlkokul   ğrencilerinin T  rk  e Okuma-Anlama ve Yazma Becerilerinin Eğitsel Dijital Oyun Destekli   ğretim Etkinlikleri ile Geliştirilmesi. *Anadolu   niversitesi, Eğitim Bilimleri Enstit  s  , Doktora Tezi*, 506s, Eski  ehir.
-   zistek, B., 2022. Mobil Oyun Sekt  r   Raporu. Eri  im Tarihi: 25.04.2023. <https://bogaziciventures.com/wp-content/uploads/2023/05/2022-Mobil-Oyun-Sektoru-Raporu.pdf>.
-   zkan, Yudum. 2021. Dijital Oyun Tabanlı   ğrenme Uygulamalarının Teknoloji Entegrasyonu S  recinde Kullanılması. *Ege   niversitesi, Eğitim Bilimleri Enstit  s  , Master's thesis*, 291s, İzmir.

- Öztemel, E. 2018. Eğitimde Yeni Yönelimlerin Değerlendirilmesi ve Eğitim 4.0. Üniversite Araştırmaları Dergisi, 1 (1), 25-30.
- Öztürk, H. 2016. EEG sinyallerinde farklı boyut indirgeme ve sınıflandırma yöntemlerinin karşılaştırılması. Adnan Menderes Üniversitesi, Sağlık Bilimleri Enstitüsü, Yüksek Lisans Tezi, 111s, Aydın.
- Park, C., Took, C. C., & Mandic, D. P., 2013. Augmented complex common spatial patterns for classification of noncircular EEG from motor imagery tasks. IEEE Transactions on neural systems and rehabilitation engineering, 22(1), 1-10.
- Parkı H., B. Myung and S. K. Yoo, 2013."Power consumption of wireless EEG device for BCI application: Portable EEG system for BCI," 2013 International Winter Workshop on Brain-Computer Interface (BCI), Gangwon, Korea (South), 2013, 100-102.
- Picard, R.W. 2000. Affective computing, MIT press. Massachusetts.
- Poçan, S., 2023. Matematik Eğitiminde Dijital Oyun Tabanlı Öğrenme Üzerine Bibliyometrik Analiz. İnönü Üniversitesi Eğitim Fakültesi Dergisi, 24(1), 648-669.
- Pratama, L. D., & Setyaningrum, W., 2018. GBL in math problem solving: Is it effective? International Journal of Interactive Mobile Technologies, 12(6), 101-111.
- Prensky, M., 2001. Digital Game-Based Learning. McGraw-Hill. New York.
- Prensky, M., 2002. The Motivation of Gameplay or, the REAL 21th century learning revolution. New York.
- Raju, R., C. Yang, C. Li and A. Cangelosi, 2016. "A video game design based on Emotiv Neuroheadset," 2016 International Conference on Advanced Robotics and Mechatronics (ICARM), Macau, China, 2016, 14-19.
- Ranky, GN; Adamovich, S., 2010. Bir robot kolunun kontrolü için ticari bir EEG cihazının analizi. 36. Yıllık Kuzeydoğu Biyomühendislik Konferansı (NEBEC'10) Bildirileri, New York, NY, ABD, 27-28 Mart 2010, 1-2.
- Rattadilok, Prapa Chris Roadknight ve Li Li, 2018., "P 4 – 7: Teaching Students About Machine Learning Through a Gamed Approach", 2018 IEEE International Conference on Teaching Assessment and Learning for Engineering (TALE).
- Rebsamen B. 2010. "A Brain Controlled Wheelchair to Navigate in Familiar Environments", IEEE Transactions on Neural Systems and Rehabilitation Engineering, 18(6), 590-598.
- Reyes A.A., C. Elkin, Q. Niyaz, X. Yang, S. Paheding ve VK Devabhaktuni, 2020. "A Preliminary Work on Visualization-based Education Tool for High School Machine Learning Education," 2020 IEEE Integrated STEM Education Conference (ISEC), 2020, 1-5.

- Rieber, LP., 1996. Oyunu Ciddi Şekilde Düşünmek: Mikro Dünyaları, Simülasyonları ve Oyunları Harmanlamaya Dayalı Etkileşimli Öğrenme Ortamları Tasarlamak. Eğitim Teknolojisi Araştırma ve Geliştirme, 44, 43-58.
- Rieder, M. K., Rahm, B., Williams, J. D., & Kaiser, J. 2011. Human gamma-band activity and behavior. International Journal of Psychophysiology, 79(1), 39-48.
- Robinson, O. C. (2014). Sampling in interview-based qualitative research: A theoretical and practical guide. Qualitative research in psychology, 11(1), 25-41.
- Rogers, S. 2010. Level Up!, The Guide to Great Video Game Design. İngiltere: A John Wiley & Sons, Ltd., Publication.
- Roy, R. N., Bonnet, S., Charbonnier, S., Jallon, P. & Campagne, A. 2015, August. A comparison of ERP spatial filtering methods for optimal mental workload estimation. In 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)7. 254-7257.
- Sadık, E.Ş., 2022. Biberiye Esansiyel Kokusunun Öğrenme Üzerindeki Etkisinin Eeg Sinyalleri Kullanılarak Yapay Zeka Algoritmaları İle İncelenmesi. Kütahya Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, PhD Thesis, 199s, Kütahya.
- Safri, N.M., Sha'ameri, A.Z., S. Daliman, N. A. Samah and S. Z. Ousai, 2018. "Gender Difference in Problem Solving Based on Electroencephalogram (EEG) Signals," 2018 2nd International Conference on BioSignal Analysis, Processing and Systems (ICBAPS), 2018, 65-69.
- Sakalle, A., Tomar, P., Bhardwaj, H., Iqbal, A., Sakalle, M., Bhardwaj, A. ve Ibrahim, W., 2022. Genetic programming-based feature selection for emotion classification using eeg signal. Journal of Healthcare Engineering, 2022.
- Sălceanu, C., 2014. The influence of computer games on children's development. Exploratory study on the attitudes of parents. Procedia Social and Behavioral Sciences, 149, 837-841.
- Salen, K. & Zimmerman, E., 2003. Rules of Play. Game Design Fundamentals MIT Press, Massachusetts.
- Sánchez-Mena A., ve J. Martí-Parre, 2017."Öğretmenlerin eğitici video oyunlarını kabulü: Kapsamlı bir literatür taraması", J. E-Learn. Knowl. Sos., cilt. 13, hayır. 2, 47-63, 2017.
- Sandham W.A. and D. J. Hamilton, 2006."Biosignal Processing and Analysis using Mathcad®- Pedagogical and Research Issues," 2006 International Conference of the IEEE Engineering in Medicine and Biology Society, 6177-6180.
- Sarıçam, Uğur. 2019. Dijital oyun tabanlı stem uygulamalarının öğrencilerin stem alanlarına ilgileri ve bilimsel yaratıcılığı üzerine etkisi: Minecraft örneği.

Marmara Üniversitesi, Eğitim Bilimleri Enstitüsü, PhD Thesis, 154s, İstanbul.

- Sarpkaya, Seçkin. 2021. "Dijital Oyun/Video Oyunu Folkloru Üzerine Bir Yöntem Denemesi", Uluslararası Halkbilimi Araştırmaları Dergisi, S.6, S. 155172.
- Savaş, S.; Topaloğlu N., 2012. Veri Madenciliği ve Türkiye'deki Uygulama Örnekleri (Tarama Makalesi). İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi Yıl:11 Sayı: 21 Bahar 2012, 1-23.
- Savaş, S., Güler, O., Kaya, K., Çoban, G. & Güzel, M. S., 2021. Eğitimde Dijital Oyunlar ve Oyun ile Öğrenme. International Journal of Active Learning, 6 (2), 117-140.
- Savran, A.; Ciftci, K.; Chanel, G.; Mota, J.C.; Viet, L.H.; Sankur, B.; Akarun, L.; Caplier, A.; Rombaut, M., 2006. Emotion detection in the loop from brain signals and facial images. eNTERFACE, 6, 69-80.
- Sawangjai, P., S. Hompoonsup, P. Leelaarporn, S. Kongwudhikunakorn and T. Wilaiprasitporn, 2020. "Consumer Grade EEG Measuring Sensors as Research Tools: A Review," in IEEE Sensors Journal, 20(8), 3996-4024.
- Saymaz, A., 2020, Mutluluk Eğitiminin Eeg Sinyalleri Üzerine Etkisinin Makine Öğrenmesi Yöntemleriyle Değerlendirilmesi. İstanbul Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, 73s, İstanbul.
- Sejnowski, T. J. 2018. The deep learning revolution. MIT press. Cambridge MA.
- Seng, W. Y., & Yatim, M. H. M., 2014. Computer game as learning and teaching tool for object oriented programming in higher education institution. Procedia-Social and Behavioral Sciences, 123, 215-224.
- Seow, P-S. ve Wong, S-P., 2016. Using a Mobile-Gaming App to Enhance Accounting Education. Journal of Education for Business. 91(8): 434-439.
- Sha'abani, M., Fuad, N., Jamal, N., Ismail, M. F., 2020. kNN and SVM classification for EEG: A Review. Lecture Notes in Electrical Engineering, 632.
- Shadiev, R., Huang, Y. M., & Hwang, J. P., 2017. Investigating The Effectiveness Of Speech-To-Text Recognition Applications On Learning Performance, Attention, And Meditation. Educational Technology Research And Development, 65, 1239-1261.
- Sherry, J., Desouza, R., Greenberg, B. S. ve Lachlan, K. 2003. Relationship between developmental stages and video game uses and gratifications, game preference and amount of time spent in play. Paper presented at the annual meeting of the International Communication Association, Marriott Hotel, San Diego, CA.
- Shin, N., L.M. Sutherland, C.A. Norris, E. Soloway., 2011. Effects of game technology on elementary student learning in mathematics. British Journal of Educational Technology (BJET), 43 (4), 540-560.

- Shiohira, K., 2021.Yapay Zekanın Beceri Gelişimi Üzerindeki Etkisini Anlamak; Birleşmiş Milletler Eğitim, Bilim ve Kültür Örgütü, 59.Paris, Fransa.
- Shukla, R.K. P. Sharma, N. Samaiya and M. Kherajani, 2020."WEB USAGE MINING- A Study of Web data pattern detecting methodologies and its applications in Data Mining," 2nd International Conference on Data, Engineering and Applications (IDEA), 1-6.
- Singh Kiran D, Sood Sandeep K., 2018. An Optical-Fog assisted EEG-based virtual reality framework for enhancing E-learning through educational games, Computer Applications in Engineering Education, John Wiley and Sons.
- Sitzmann, T. 2011. A meta-analytic examination of the instructional effectiveness of computer-based simulation games. *Personnel Psychology*, 64(2), 489–528.
- Song M.R. and S. W. Lee, 2018. "Meta BCI: Hippocampus-striatum network inspired architecture towards flexible BCI," 2018 6th International Conference on Brain-Computer Interface (BCI), Gangwon, Korea (South), 1-3.
- Stacey, K. C. And Pierce, R. U., 2006. Enhancing the image of mathematics by association with simple pleasures from real world contexts. *ZDM*, 38, 214-225.
- Steiner H. ve Martynova, O. 2022. Task-related and Resting-state EEG Correlates of Mathematical Skills, 2022 Fourth International Conference Neurotechnologies and Neurointerfaces (CNN), Kaliningrad, Russian Federation, 2022, 190-193.
- Subrahmanyam, K., & Greenfield, P. M. 1994. Effect of video game practice on spatial skills in girls and boys. *Journal of Applied Developmental Psychology*, 15(1), 13–32.
- Sung, H. Y., & Hwang, G. J. 2013. A collaborative game-based learning approach to improving students' learning performance in science courses. *Computers & education*, 63, 43-51.
- Sur, Shravani; Sinha, V. K. 2009. Event-related potential: An overview. *Industrial Psychiatry Journal* 18(1), 70-73.
- Şahin, Y. 2021. Z kuşağının dijital oyun bağımlılıklarının boş zaman ve değişkenlerinin incelenmesi. Karamanoğlu Mehmetbey Üniversitesi, Sosyal Bilimler Enstitüsü, Beden Eğitimi ve Spor Ana Bilim Dalı, Yüksek Lisans Tezi, 104s, Karaman.
- Tandle, A. L., Joshi, M. S., Dharmadhikari, A. S., & Jaiswal, S. V. 2018. Mental state and emotion detection from musically stimulated EEG. *Brain informatics*, 5, 1-13.
- Thai, K. P., Bang, H. J., & Li, L. 2022. Accelerating early math learning with research-based personalized learning games: A cluster randomized

controlled trial. Journal of Research on Educational Effectiveness, 15(1), 28-51.

Thomas Hainey, Thomas M. Connolly, Elizabeth A. Boyle, Amanda Wilson, Aisya Razak, 2016. A systematic literature review of games-based learning empirical evidence in primary education, Computers & Education, Volume 102, 202-223, ISSN 0360-1315.

Tokac, U., Novak, E. ve Thompson, CG. 2019. Oyun temelli öğrenmenin öğrencilerin matematik başarıları üzerindeki etkileri: Bir meta-analiz. Bilgisayar Destekli Öğrenme Dergisi, 35, 407 – 420.

Torres, Edgar P., Edgar A. Torres, Myriam Hernández-Álvarez ve Sang Guun Yoo. 2020. "EEG Tabanlı BCI Duygu Tanıma: Bir Araştırma" Sensörleri 20(18): 5083.

Trust, T., 2018. Why Do We Need Technology in Education?, Journal of Digital Learning in Teacher Education, 34(2), 54-55.

Tuççe, İ. Ş. Ç. İ., & Yeşiltaş, E., 2018. Sosyal bilgiler öğretiminde dijital oyun geliştirme yazılımı kullanımı ve sosyal bilgiler öğretmen adaylarının buna ilişkin görüşleri. Türkiye Bilimsel Araştırmalar Dergisi, 5(2), 260-284.

Tuğrul, B. 2014. Oyun temelli öğrenme. R. Zembat (Eds) içinde. Okulöncesinde özel öğretim yöntemleri, 187-220.

TÜBİTAK. 2022. Sığırcı, M., Video Oyunları: Kim, Ne Zaman İcat Etti? Erişim Tarihi: 26.04.2023 <https://bilimgenc.tubitak.gov.tr/makale/video-oyunlari-kim-ne-zaman-icat-etti>

Türetken, M. 2024. YÖK Başkanı Özvar: Yapay zeka alanlarında yeni lisans ve ön lisans programları açıyoruz. Erişim Tarihi: 30.04.2024 <https://www.aa.com.tr/tr/egitim/yok-baskani-ozvar-yapay-zeka-alanlarinda-yeni-lisans-ve-on-lisans-programlari-aciyoruz/3203046>

Türk, Ö. ve Özerdem, M. S., 2014. EEG işaretlerinin k-NN ile sınıflandırmasında dalgacıklara ilişkin performansların karşılaştırılması. Tıp Teknolojileri Ulusal Kongresi, Artuklu Üniversitesi, Mardin.

Türk Dil Kurumu (TDK), 2023. Erişim Tarihi: 31.01.2023 <https://sozluk.gov.tr/>

Tyas, A. E., Wibawa, A. D., & Purnomo, M. H., 2020. Theta, alpha and beta activity in the occipital based on eeg signals for mental fatigue in high school students. In 2020 International Conference on Smart Technology and Applications (ICoSTA), 1-7. IEEE.

Uzair, M., & Jamil, N., 2020. Effects of hidden layers on the efficiency of neural networks. In 2020 IEEE 23rd international multitopic conference (INMIC), 1-6. IEEE.

Ülker, B., 2017. EEG biyosensör kullanılarak dikkat ve meditasyon oranlarının öğrenmeyle ilişkilendirilmesi. Bursa Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek lisans tezi, 83s, Bursa.

- Üstün, F., Öz, N. D., Önal, F., Demirci, Y. E. & Akbaba, S. 2022. Üniversite Öğrencilerinin E-Spor Katılım Motivasyonlarının İncelenmesi. Düzce Üniversitesi Spor Bilimleri Dergisi, 2 (2), 128-137.
- Varinlioğlu, Güzden; Alankuş, Gazihan; ASLANKAN, Ali. 2019. Oyun tabanlı öğrenme ile dijital mirasın yaygınlaştırılması. Oyun Tabanlı Öğrenme İle Dijital Mirasın Yaygınlaştırılması. Metu Jfa, 1, 23.
- Vatfa, MK; Audi, DM, 2015. Modern teknolojileri kullanan yeni öğrenme metodolojileri. Uluslararası J. Yenilik. Öğrenmek. 17, 275-297.
- Verkijika, S. F., De Wet, L. 2015. Using a brain-computer interface (BCI) in reducing math anxiety: Evidence from South Africa. Computers & Education, 81, 113-122.
- Vernet, M., Bashir, S., Enam, S. F., Kumru, H., & Pascual-Leone, A. 2012. Electrophysiologic techniques. Brain injury medicine: principles and practice, 2-2.
- Victoria, J.R., G Foehr Ulla and F Roberts Donald, 2010. "Generation m [superscript 2]: Media in the lives of 8-to 18-year-olds", Henry J. Kaiser Family Foundation.
- Wang, Yujin, Xiaorong Gao, Bo Hong, Chuan Jia, and Shangkai Gao. 2008. "Brain-computer interfaces based on visual evoked potentials." Journal of IEEE Engineering in Medicine And Biology, 27(5), 64-71.
- Wang, Y., Yu, S., Ma, N., Wang, J., Hu, Z., Liu, Z., He, J. 2020. Prediction of product design decision Making: An investigation of eye movements and EEG features. Advanced Engineering Informatics, 45, 101095.
- Wang, Z., Wang, Y., Yang, Z., Wu, H., Liang, J., Liang, H., Li, S. 2021. The use of non-invasive ventilation in COVID-19: A systematic review. International Journal of Infectious Diseases, 106, 254-261.
- Wiliams, T. 2012. Brain-Computer Interfacing using Motor Cortical Control and a consumer grade Electroencephalograph, EEG. School of Computer Science and Informatics University College, Dublin.
- Wouters, P., Van Oostendorp, H. 2013. A meta-analytic review of the role of instructional support in game-based learning. Computers& Education, 60(1),412-425.
- Wright, K. 2001. Winning brain waves: Can custom-made video games help kids with attention deficit disorder. Discover, 22(3), 25-27.
- Xiao, D., Z. Mu and J. Hu, 2009. "A Linear Discrimination Method Used in Motor Imagery EEG Classification", Fifth International Conference on Natural Computation, 94-98.
- Xiaojun, J., Chen, Alan, C., West, Donald, M., Cropek, and Scott B. 2007. Detection of the superoxide radical anion using various alkanethiol monolayers and immobilized. Cytochrome, Anal. Chem., 80, 9622-9629.

- Xu, J., Zhong, B., 2018. Review on portable EEG technology in educational research, *Computers in Human Behavior*, 81.
- Yang, Y., Wang, C., & Lai, M. 2012. Using bibliometric analysis to explore research trend of electronic word-of-mouth from 1999 to 2011. *International Journal of Innovation, Management and Technology*, 3(4), 337-342.
- Yang, W., Rifqi, M., Marsala, C. and Pinna, A., 2018. Physiological-based emotion detection and recognition in a video game context, 2018 International joint conference on neural networks (IJCNN), Rio de Janeiro, IEEE, ISBN: 978-1-5090-6014-6, 1-8.
- Yang, K. H., Chen, H. H. 2021. What increases learning retention: employing the prediction-observation-explanation learning strategy in digital game-based learning. *Interactive Learning Environments*, 1-16.
- Yaşar, R. Şebnem; Alkan, Gönül., 2019. Muhasebe eğitiminde oyunlaştırma: dijital oyun tabanlı öğrenme. *Journal of Accounting and Taxation Studies*, 12(2): 331-352.
- Yee, N. 2006. Motivations for play in online games. *Cyberpsychol Behav.* 2006 Dec;9(6):772-5.
- Yengin, D; 2012. *Dijital Oyunlarda Şiddet*, Beta Yayınları, İstanbul.
- Yıldırım, N., Varol, A. 2013. Developing educational game software which measures attention and meditation with brainwaves: matching mind math. In *ICEE ICIT Conference*, 325-332.
- Yıldırım, Ebru. 2016. Dijital oyun tasarım programlarının eğitimde önemi. *Mesleki Bilimler Dergisi (MBD)*, 5(2).
- Yılmaz, E., Yel, S., & Griffiths, M. D. 2022. Comparison of children's social problem-solving skills who play videogames and traditional games: A cross-cultural study. *Computers & Education*, 187, 104548.
- Yücel, A. Çubuk, F. 2014. The Experimental Travel of a Neuromarketing Research and the First Tips of the Research *Fırat University Journal of Social Science*, 24(2), Sayfa: 133-149, Elazığ.
- Yürekli, E. ve Şahiner, A. 2017. Muhasebe Eğitiminde Video Oyun Kullanımına Yönelik Öğrenci Görüşleri ve Öğrencilerin Motivasyonu ile Öğrenme Çıktıları Üzerine Etkilerinin Araştırılması. 36. Türkiye Muhasebe Eğitimi Sempozyumu Kitabı: 143-163.
- Zahed, T., G. White and J. Quarles, 2019. "Play It Safe: An Educational Cyber Safety Game for Children in Elementary School," 2019 11th International Conference on Virtual Worlds and Games for Serious Applications (VS-Games), Vienna, Austria., 1-4, doi: 10.1109/VS-Games.8864594.
- Zaidi, Zeenat F. 2010. Gender differences in human brain: a review. *The open anatomy journal*, 2(1).

- Zhang, S., Shang, B., Yang, J., Yan, W., Wei, S. and Xie, Y. 2011. From VO2 (B) to VO2 (A) Nanobelts: First Hydrothermal Transformation, Spectroscopic Study and First Principles Calculation. *Physical Chemistry Chemical Physics*, 13, 15873-158781.
- Zhang L. and J. Shang, 2016. "Understanding the Educational Values of Video Games from the Perspective of Situated Learning Theory and Game Theory," 2016 International Conference on Educational Innovation through Technology (EITT), Tainan, Taiwan, 76-80.
- Zheng, WL., H.-T. Guo ve B.-L. Lu, 2015. "Derin inanç ağıyla EEG'den duygu tanıma için kritik kanalları ve frekans bantlarını ortaya çıkarmak", 2015 7. Uluslararası IEEE/EMBS Sinir Mühendisliği Konferansı (NER), Montpellier, Fransa, s. 154-157.
- Zheng, Y. Z. Wang ve W. Jia, 2022. "Bilgisayar Destekli İlkokul Matematik Öğretiminin Uygulama Araştırması", 2022 12. Uluslararası Tıp ve Eğitimde Bilgi Teknolojileri Konferansı (ITME), Xiamen, Çin. 2022, s. 167-170.

EKLER

Ek A. Gönüllü Katılım Formu

GÖNÜLLÜ KATILIM FORMU

" Eğitsel dijital matematik oyunu kullanımıyla eeg sinyalleri ve yapay zeka algoritmalarıyla başarının tahminlenmesi" başlıklı projeye veri toplamak amacıyla sizlere soru yöneltilmektedir. Projemizde amaç, eğitsel dijital matematik oyunları ve eeg kullanımıyla başarıyı tahminlemektir.

Eeg ile birlikte oyun uygulanması sırasında tahminen sizden 10 dk istenmektedir. Uygulama esnasında Pınar KILIÇ yanınızda olacaktır.Oyun sonrasında oyun ile ilgili açıklayıcı bilgiler sorabilirsiniz.

Bu formu okuyup onaylamanız araştırmaya katılmayı kabul ettiğiniz anlamına gelmektedir.

Kendiniz ile ilgili verdiğiniz her türlü bilgi gizli kalacaktır. Cevaplar araştırma amaçlı kullanılmaktadır. Bu bilgileri okumanız ve oyundaki soruları cevaplamanız araştırmaya katılmaya gönüllü olduğunuz anlamına gelmektedir.

Araştırmaya katıldığınız için teşekkürler.

Araştırma Yürütücüsünün

EK B. Katılım Sonrası Bilgilendirme Formu

KATILIM SONRASI BİLGİLENDİRME FORMU

Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Eğitim Teknolojileri Anabilim Dalında Pınar KILIÇ tarafından yürütülen "Eğitsel dijital matematik oyunu kullanımıyla EEG sinyalleri ve yapay zeka algoritmalarıyla başarının tahminlenmesi" başlıklı yüksek lisans tezi kapsamında araştırma sorularını cevaplayarak katıldığınız için teşekkür ederiz. Araştırma sonrasında elde edilecek bilgiler sizlerle paylaşılacaktır. Araştırma kapsamında bilgi edinmek için araştırma yürütücüsüne ulaşabilirsiniz.

Araştırma Yürütücüsünün

Ek C. Etik Kurul Onayı



T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
Üniversite Etik Kurulu

Sayı :E-87432956-050.99-471409
Konu :Bilimsel Çalışma Onayı.

Tarih: 28.03.2023

Pınar KILIÇ

Yürütücülüğünü yaptığınız “Eğitsel Dijital Matematik Oyunu Kullanımıyla EEG Sinyalleri ve Yapay Zeka Algoritmalarıyla Başarının Tahminlenmesi” başlıklı bilimsel çalışmanız Fen ve Mühendislik Bilimleri Etik Kurulu’nun 28.03.2023 tarihli ve 72/4 sayılı kararı ile uygun bulunmuştur.

Kararın bir sureti gönderilmiş olup, başvurunuza cevaben bilgilerinizi rica ederim.

Prof. Dr. Mehmet SALTAN
Rektör a.
Rektör Yardımcısı

Bu evrak 5070 sayılı Elektronik İmza Kanununun 5. maddesi gereince güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu: BFC34862
SDÜ Batı Yerleşkesi Çümrü/ISPARTA
Tel No: - Faks No:
E-Posta:
Kep Adresi:

Belge Takip Adresi: <https://ebys.sdu.edu.tr/EvrakDogrula.html?BFC34862>

Bilgi İçin: Zühal Sema BARDAK
Şef
Tel No: 2118052



Ek D. Etik Kurul Onayı

T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
Fen ve Mühendislik Bilimleri
Etik Kurul Kararları

TOPLANTI TARİHİ	TOPLANTI SAYISI	KARAR SAYISI
28.03.2023	72	4

4- Üniversitemiz Fen Bilimleri Enstitüsü Eğitim Teknolojileri Bölümü yüksek lisans öğrencisi Pınar KILIÇ tarafından yürütülen "Eğitsel Dijital Matematik Oyunu Kullanımıyla EEG Sinyalleri ve Yapay Zeka Algoritmalarıyla Başarının Tahminlenmesi" başlıklı bilimsel çalışma hk.

Üniversitemiz Fen Bilimleri Enstitüsü Eğitim Teknolojileri Bölümü yüksek lisans öğrencisi Pınar KILIÇ tarafından yürütülen "Eğitsel Dijital Matematik Oyunu Kullanımıyla EEG Sinyalleri ve Yapay Zeka Algoritmalarıyla Başarının Tahminlenmesi" başlıklı bilimsel çalışmanın kapsam ve uygulama açısından etik ilkelere ve insan haklarına uygun olduğuna,

Mevcudun oybirliği ile karar verildi.

Prof.Dr. Mehmet SALTAN
Başkan

Prof.Dr. Atilla GÜL
Başkan Yrg.

Prof.Dr. Servet MİRDAĞ
Üye

Prof.Dr. Gülcan ÖZKAN
Üye

Prof.Dr. Nevzat Özgü YİĞİT
Üye

Prof.Dr. Selma TABUR
Üye

Prof.Dr. Yılmaz ÇEVEN
Üye

28.03.2023
Zinnal BARDAK
Raportör