
GAZİ ÜNİVERSİTESİ
Gazi
1926

# EEG SİNYALLERİNİN VERİ MADENCİLİĞİ TEKNİKLERİYLE DEĞERLENDİRİLMESİ

**Pınar Karabakla**

**YÜKSEK LİSANS TEZİ**

**EĞİTİM BİLİMLERİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ**

**EĞİTİM BİLİMLERİ ENSTİTÜSÜ**

**EKİM, 2024**

# TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU

Bu tezin tüm hakları saklıdır. Kaynak göstermek koşuluyla tezin teslim tarihinden itibaren 12 (on iki) ay sonra tezden fotokopi çekilebilir.

## YAZARIN

Adı : Pınar

Soyadı : Karabakla

Bölümü : Eğitimde Ölçme ve Değerlendirme

İmza :

Teslim tarihi :

## TEZİN

Türkçe Adı : EEG Sinyallerinin Veri Madenciliği Teknikleriyle Değerlendirilmesi

İngilizce Adı : Evaluation of EEG Signals with Data Mining Techniques

# ETİK İLKELERE UYGUNLUK BEYANI

Tez yazma sürecinde bilimsel ve etik ilkelere uyduğumu, yararlandığım tüm kaynakları kaynak gösterme ilkelerine uygun olarak kaynakçada belirttiğimi ve bu bölümler dışındaki tüm ifadelerin şahsıma ait olduğunu beyan ederim.

Yazar Adı Soyadı: Pınar Karabakla

İmza:

# JÜRİ ONAY SAYFASI

Pınar Karabakla tarafından hazırlanan "EEG Sinyallerinin Veri Madenciliği Teknikleriyle Değerlendirilmesi" adlı tez çalışması aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Gazi Üniversitesi Eğitim Bilimleri Ana Bilim Dalı Eğitimde Ölçme ve Değerlendirme Bilim Dalı'nda Yüksek Lisans Tezi olarak kabul edilmiştir.

**Danışman:** Prof. Dr. Dilara Bakan Kalaycıoğlu ……

(Eğitimde Ölçme ve Değerlendirme, Gazi Üniversitesi)

**Üye:** Prof. Dr. Nilüfer Kahraman ……

(Eğitimde Ölçme ve Değerlendirme, Gazi Üniversitesi)

**Üye:** Dr. Öğr. Üyesi Ergün Cihat Çorbacı ……

(Eğitimde Ölçme ve Değerlendirme, Sinop Üniversitesi)

Tez Savunma Tarihi: 12.09.2024

Bu tezin Eğitimde Ölçme ve Değerlendirme Ana Bilim Dalı'nda Yüksek Lisans tezi olması için şartları yerine getirdiğimi onaylıyorum.

Prof. Dr. Şaban ÇETİN

Eğitim Bilimleri Enstitü Müdürü ……

# TEŞEKKÜR

Yüksek Lisans sürecimde 2210-Yurt İçi Lisansüstü Burs Programı kapsamında burs vererek maddi destek sağlayan TÜBİTAK'a teşekkür ederim.

Kendisiyle tanışmanın ve rehberliğinde çalışmanın büyük bir şans olduğunu bana her zaman hissettiren, bilgi ve deneyimleriyle hep bir adım ileriye taşınmamı sağlayan çok değerli danışman hocam Prof. Dr. Dilara Bakan Kalaycıoğlu'na en içten teşekkürlerimi sunarım.

Tez çalışmamın temelini oluşturan TÜBİTAK tarafından desteklenen 215K027 numaralı projeyi yürüten ve aynı zamanda jüri üyesi olarak çalışmamı değerlendiren Sayın Prof. Dr. Nilüfer Kahraman'a teşekkür ederim. Bunlara ek olarak, tez hazırlama aşamasında her ihtiyacım olduğunda zaman ayırarak sorularımı yanıtlayan, verdiği geri bildirimlerle çalışmamın başarıyla tamamlanmasında önemli bir rol oynayan Dr. Öğr. Üyesi Ergün Cihat Çorbacı'ya çok teşekkür ederim.

Tez yazma sürecinde sorunlarıma her daim çözüm arayan ve manevi desteğini benden hiçbir zaman esirgemeyen değerli arkadaşım Necmettin Gün'e teşekkürlerimi sunarım.

Hayatım boyunca her adımımda arkamda duran, zorlandığım ve düştüğüm her an bana nasıl kalkacağımı sabırla öğreten, beni özgüvenli bir insan olarak yetiştiren canım annem Reyhan Karabakla ve canım babam Hakan Karabakla'ya; beni koşulsuz destekleyen ve benim için tarif edilemez bir güç kaynağı olan biricik kardeşim Canan Karabakla'ya en derin minnet ve sevgilerimi sunarım. Sizlerin sevgisi, desteği ve emeği olmadan bugünlere gelmem mümkün olmazdı.

# EEG SİNYALLERİNİN VERİ MADENCİLİĞİ TEKNİKLERİYLE DEĞERLENDİRİLMESİ

**(Yüksek Lisans Tezi)**

**Pınar Karabakla**

**GAZİ ÜNİVERSİTESİ**

**EĞİTİM BİLİMLERİ ENSTİTÜSÜ**

**Ekim 2024**

## ÖZ

Bu çalışma, multimedya öğrenme ortamlarında öğrencilerin EEG sinyallerinin veri madenciliği sınıflandırma teknikleri kullanılarak değerlendirilmesini amaçlamaktadır. Araştırmada, öğrencilerin video izleme sonrasında yöneltilen sorulara doğru cevap verip vermeme durumlarına göre Alfa, Beta, Delta, Teta ve Gama dalgalarını ölçen EEG (Elektroensefalografi) verileri kullanılmıştır. 25 öğrenciye ait EEG verileri toplanmış ve bu verilerle Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları kullanılarak sınıflandırma analizleri yapılmıştır. Araştırmada kullanılan sınıflandırma modellerinin performansları doğruluk, duyarlılık, özgüllük ve F Puanı gibi kriterlere dayalı olarak karşılaştırılmıştır. Bayes sınıflandırma algoritması, sorulan her iki soru özelinde doğruluk ve özgüllük açısından en yüksek performansı göstermiştir. Delta, teta, alfa, beta ve gama dalga boylarının farklı sorular için nasıl değiştiği incelenmiş ve bu dalga boylarının model performanslarına etkisi araştırılmıştır. Bulgulara göre hem birinci hem de ikinci soru için beta ve gama dalgalarının dikkat süreçleri açısından önemli olduğu görülmektedir. Çalışmanın bulgularına göre, daha etkileşimli ve ilgi çekici eğitim materyalleri geliştirilmemesi ve özellikle çevrimiçi eğitim ortamlarında, videoların daha dinamik ve etkileşimli hale getirilmesi önerilmektedir. Eğitimciler, öğrencilerin bireysel dikkat seviyelerindeki farklılıkları göz önünde bulundurarak, kişiselleştirilmiş eğitim programları geliştirebilirler. EEG verileri ile öğrencilere özgü eğitim programları

oluşturulabilir ve bu sayede dikkat eksikliği problemleri minimize edilebilir. EEG ve benzeri nörobilimsel araçlar, öğrencilerin dikkat seviyelerini anlık olarak izleme ve değerlendirme imkânı sunmaktadır. Eğitim kurumları, bu tür teknolojileri kullanarak öğrencilerin öğrenme süreçlerini optimize edebilir ve dikkat seviyelerini artırıcı stratejiler geliştirebilir. Bu çalışma, EEG verilerinin eğitimde dikkat süreçlerini izleme ve değerlendirme açısından büyük bir potansiyele sahip olduğunu göstermektedir. Gelecekteki çalışmalar, daha büyük veri setleri ve optimize edilmiş model parametreleri kullanarak bu sınırlılıkları aşabilir. Sonuç olarak, bu tez çalışması, eğitim süreçlerinin izlenmesi ve değerlendirilmesi açısından önemli bilgiler sunmaktadır.

Anahtar Kelimeler : EEG, Dikkat, Multimedya Öğrenme, Veri Madenciliği

Sayfa Adedi : xx+105

Danışman : Prof. Dr. Dilara Bakan Kalaycıoğlu

**EVALUATION OF EEG SIGNALS WITH DATA MINING TECHNIQUES**

**(M.S. Thesis)**

**Pınar Karabakla**

**GAZI UNIVERSITY**

**GRADUATE SCHOOL OF EDUCATIONAL SCIENCES**

**October 2024**

## ABSTRACT

This study aims to evaluate students' EEG signals in multimedia learning environments using data mining classification techniques. In the study, EEG (Electroencephalography) data measuring Alpha, Beta, Delta, Theta and Gamma waves were used according to whether the students answered the questions posed after watching the video correctly or not. EEG data of 25 students were collected and classification analyses were performed using Bayesian Classification Algorithm, Logistic Regression, C5.0, CHAID and Artificial Neural Networks. The performances of the classification models used in the study were compared based on criteria such as accuracy, sensitivity, specificity and F Score. Bayesian classification algorithm showed the highest performance in terms of accuracy and specificity for both questions. The effect of delta, theta, alpha, beta and gamma wavelengths on model performance was analyzed for different questions. According to the findings, it is seen that beta and gamma wavelengths are important in terms of attention processes for both the first and second questions. According to the findings of the study, it is recommended that more interactive and interesting educational materials should be developed and videos should be made more dynamic and interactive, especially in online educational environments. Educators can develop personalized training programs by taking into account the differences

in students' individual attention levels. EEG data can be used to create training programs specific to students and thus attention deficit problems can be minimized. EEG and similar neuroscientific tools offer the opportunity to monitor and evaluate students' attention levels instantaneously. By using such technologies, educational institutions can optimize students' learning processes and develop strategies to increase their attention levels. This study shows that EEG data have great potential for monitoring and evaluating attention processes in education. Future studies can overcome these limitations by using larger data sets and optimized model parameters. In conclusion, this thesis provides important insights for monitoring and evaluation of training processes.

Keywords. : EEG, Attention, Multimedia Learning, Data Mining

Page Number : xx+105

Supervisor. : Prof. Dr. Dilara Bakan Kalaycıoğlu

# İÇİNDEKİLER

**TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU** ..... i

**ETİK İLKELERE UYGUNLUK BEYANI** ..... ii

**JÜRİ ONAY SAYFASI** ..... iii

**TEŞEKKÜR** ..... iv

**ÖZ** ..... v

**ABSTRACT** ..... vii

**TABLOLAR LİSTESİ** ..... xiii

**ŞEKİLLER LİSTESİ** ..... xvi

**SİMGELER VE KISALTMALAR LİSTESİ** ..... xvii

**BÖLÜM I** ..... 1

**GİRİŞ** ..... 1

**1.1. Dikkat** ..... 4

**1.1.1. Dikkatin İzlenmesi** ..... 6

**1.2. Elektroensefalografi (EEG)** ..... 7

**1.2.1. Delta Bandı (0.5-4 Hz)** ..... 9

**1.2.2. Teta Bandı (4-8 Hz)** ..... 9

**1.2.3. Alfa Bandı (8-13 Hz)** ..... 10

**1.2.4. Beta Bandı (13-30 Hz)** ..... 10

**1.2.5. Gama Bandı (30 Hz ve üzeri)** ..... 10

**1.3. Veri Madenciliği** ..... 11

1.4. Veri Madenciliği Süreci ..... 12
1.5. Veri Madenciliği Modelleri ..... 15
1.5.1. Sınıflandırma ..... 16
1.5.2. Sınıflandırma Model Performansını Değerlendirme ..... 23
1.5.3. Kümeleme ..... 26
1.5.4. Birliktelik ..... 28
1.6. Problem Durumu ..... 28
1.7. Araştırmanın Amacı ve Önemi ..... 29
1.8. Araştırma Soruları ..... 31
1.9. Araştırmanın Sayıltıları ..... 31
1.10. Araştırmanın Sınırlılıkları ..... 31
BÖLÜM II ..... 32
İLGİLİ ARAŞTIRMALAR ..... 32
2.1. Öğrenci Dikkati ve Bilişsel Beceriler Arasındaki İlişki ..... 32
2.2. EEG Sinyalleri ile Dikkat Seviyelerinin Analizi ..... 34
2.3. EEG Sinyallerinin Veri Madenciliğinde Analizi ..... 37
BÖLÜM III ..... 40
YÖNTEM ..... 40
3.1. Çalışma Grubu ..... 40
3.2. Veri Toplama Araçları ..... 41
3.3. Deney Ortamının Hazırlanması ve Deney Düzeneğinin Kurulması ..... 44
3.4. Verilerin İşlenmesi ..... 44
3.5. Veri Analizi ..... 47
BÖLÜM IV ..... 52
BULGULAR ..... 52

**4.1. Öğrencilerin Birinci Soruya Verdikleri Cevapları Belirlemede Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları Yöntemlerinin Sınıflandırma Performansları Ne Düzeydedir? ..... 52**

**4.1.1. Bayes Sınıflandırma Algoritmasına İlişkin Bulgular ..... 52**

**4.1.2. Lojistik Regresyon Yöntemine İlişkin Bulgular ..... 56**

**4.1.3. C5.0 Yöntemine İlişkin Bulgular ..... 58**

**4.1.4. CHAID Yöntemine İlişkin Bulgular ..... 60**

**4.1.5. Yapay Sinir Ağları Yöntemine İlişkin Bulgular ..... 62**

**4.2. Birinci Soruya Ait Verileri Sınıflandırmada Model Performansına İlişkin Bulgular ..... 65**

**4.2.1. Birinci Soruya Ait Test Verisinin Sınıflandırılmasında Model Performanslarının Karşılaştırılması ..... 66**

**4.2.2. Birinci Soruya Ait Eğitim Verisinin Sınıflandırılmasında Model Performanslarının Karşılaştırılması ..... 67**

**4.3. Öğrencilerin İkinci Soruya Verdikleri Cevapları Belirlemede Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları Yöntemlerinin Sınıflandırma Performansları Ne Düzeydedir? ..... 69**

**4.3.1. Bayes Sınıflandırma Algoritmasına İlişkin Bulgular ..... 69**

**4.3.2. Lojistik Regresyon Yöntemine İlişkin Bulgular ..... 71**

**4.3.3. C5.0 Yöntemine İlişkin Bulgular ..... 74**

**4.3.4. CHAID Karar Ağacı Yöntemine İlişkin Bulgular ..... 76**

**4.3.5. Yapay Sinir Ağları Yöntemine İlişkin Bulgular ..... 80**

**4.4. İkinci Soruya Ait Verileri Sınıflandırmada Model Performansına İlişkin Bulgular ..... 82**

**4.4.1. İkinci Soruya Ait Test Verisinin Sınıflandırılmasında Model Performanslarının Karşılaştırılması ..... 83**

**4.4.2. İkinci Soruya Ait Eğitim Verisinin Sınıflandırılmasında Model Performanslarının Karşılaştırılması ..... 84**

**BÖLÜM V ..... 87**

**SONUÇ TARTIŞMA VE ÖNERİLER ..... 87**

**KAYNAKLAR.....90**

# TABLOLAR LİSTESİ

Tablo 1. *Karışıklık Matrisi* ..... 24

Tablo 2. *Tanımlayıcı İstatistikler 1* ..... 48

Tablo 3. *Tanımlayıcı İstatistikler 2* ..... 49

Tablo 4. *Birinci Soru İçin Oluşturulmuş Bayes sınıflandırma Algoritmasına Ait Parametrelerin Önem Dereceleri* ..... 53

Tablo 5. *Birinci Soru İçin Oluşturulmuş Bayes sınıflandırma Algoritmasına Ait Karışıklık Matrisi* ..... 54

Tablo 6. *Birinci Soru İçin Oluşturulmuş Bayes Sınıflandırma Algoritmasına Ait Başarım İstatistikleri* ..... 54

Tablo 7. *Birinci Soru İçin Oluşturulmuş Lojistik Regresyon Yöntemine Ait Parametrelerin Önem Dereceleri* ..... 56

Tablo 8. *Birinci Soru İçin Oluşturulmuş Lojistik Regresyon Yöntemine Ait Karışıklık Matrisi* ..... 57

Tablo 9. *Birinci Soru İçin Oluşturulmuş Lojistik Regresyon Yöntemine Ait Başarım İstatistikleri* ..... 57

Tablo 10. *Birinci Soru İçin Oluşturulmuş C5.0 Yöntemine Ait Parametrelerin Önem Dereceleri* ..... 58

Tablo 11. *Birinci Soru İçin Oluşturulmuş C5.0 Yöntemine Ait Karışıklık Matrisi* ..... 59

Tablo 12. *Birinci Soru İçin Oluşturulmuş C5.0 Yöntemine Ait Başarım İstatistikleri* ..... 59

Tablo 13. *Birinci Soru İçin Oluşturulmuş CHAID Yöntemine Ait Parametrelerin Önem Dereceleri* ..... 60

Tablo 14. *Birinci Soru İçin Oluşturulmuş CHAID Yöntemine Ait Karışıklık Matrisi* ..... 61

Tablo 15. *Birinci Soru İçin Oluşturulmuş CHAID Yöntemine Ait Başarım İstatistikleri* ....62

Tablo 16. *Birinci Soru İçin Oluşturulmuş Yapay Sinir Ağları Yöntemine Ait Parametrelerin Önem Dereceleri* ....63

Tablo 17. *Birinci Soru İçin Oluşturulmuş Yapay Sinir Ağları Yöntemine Ait Karışıklık Matrisi* ....64

Tablo 18. *Birinci Soru İçin Oluşturulmuş Yapay Sinir Ağları Yöntemine Ait Başarım İstatistikleri* ....64

Tablo 19. *İkinci Soru İçin Oluşturulmuş Bayes Sınıflandırma Algoritmasına Ait Parametrelerin Önem Dereceleri* ....69

Tablo 20. *İkinci Soru İçin Oluşturulmuş Bayes Sınıflandırma Algoritmasına Ait Karışıklık Matrisi* ....70

Tablo 21. *İkinci Soru İçin Oluşturulmuş Bayes sınıflandırma Algoritmasına Ait Başarım İstatistikleri* ....71

Tablo 22. *İkinci Soru İçin Oluşturulmuş Lojistik Regresyon Yöntemine Ait Parametrelerin Önem Dereceleri* ....71

Tablo 23. *İkinci Soru İçin Oluşturulmuş Lojistik Regresyon Yöntemine Ait Karışıklık Matrisi* ....72

Tablo 24. *İkinci Soru İçin Oluşturulmuş Lojistik Regresyon Yöntemine Ait Başarı m İstatistikleri* ....73

Tablo 25. *İkinci Soru İçin Oluşturulmuş C5.0 Yöntemine Ait Parametrelerin Önem Dereceleri* ....74

Tablo 26. *İkinci Soru İçin Oluşturulmuş C5.0 Yöntemine Ait Karışıklık Matrisi* ....75

Tablo 27. *İkinci Soru İçin Oluşturulmuş C5.0 Yöntemine Ait Başarım İstatistikleri* ....76

Tablo 28. *İkinci Soru İçin Oluşturulmuş CHAID Yöntemine Ait Parametrelerin Önem Dereceleri* ....76

Tablo 29. *İkinci Soru İçin Oluşturulmuş CHAID Yöntemine Ait Karışıklık Matrisi* ....78

Tablo 30. *İkinci Soru İçin Oluşturulmuş CHAID Yöntemine Ait Başarım İstatistikleri* ....78

Tablo 31. *İkinci Soru İçin Oluşturulmuş Yapay Sinir Ağları Yöntemine Ait Parametrelerin Önem Dereceleri* ....80

Tablo 32. *İkinci Soru İçin Oluşturulmuş Yapay Sinir Ağları Yöntemine Ait Karışıklık Matrisi*.....81

Tablo 33. *İkinci Soru İçin Oluşturulmuş Yapay Sinir Ağları Yöntemine Ait Başarım İstatistikleri*.....82

# ŞEKİLLER LİSTESİ

*Şekil 1.* EEG frekans bantları ..... 11
*Şekil 2.* Veri madenciliğinde bilgi keşfi süreci. Fayyad, U., Piatetsky-Shapiro, G., Smyth, P., & Uthurusamy, R. (1996). *Advances in knowledge discovery and data mining.* AAAI/MIT Press. ..... 12
*Şekil 3.* CRISP-DM modelinin aşamaları (IBM SPSS Modeler CRISP-DM Guide, 2000, s. 1) ..... 13
*Şekil 4.* Veri madenciliği görevleri ve modelleri Dunham, M.H. (2003)'den uyarlanmıştır. ..... 15
*Şekil 5.* Giyilebilir elektrofizyoloji sensör sistemi. iMotions. (n.d.). *İMotions 8*. iMotions. https://imotions.com/products/hardware/iMotions-8/ ..... 42
*Şekil 6.* EEG verisinin işlenmesi sonrasındaki dalga boyları grafiği ..... 47
*Şekil 7.* Birinci soruya ait sınıflandırma algoritmalarının test verisi üzerindeki performans karşılaştırması ..... 66
*Şekil 8.* Birinci soruya ait sınıflandırma algoritmalarının eğitim verisi üzerindeki performans karşılaştırması ..... 68
*Şekil 9.* İkinci soruya ait sınıflandırma algoritmalarının test verisi üzerindeki performans karşılaştırması ..... 83
*Şekil 10.* İkinci Soruya Ait Sınıflandırma Algoritmalarının Eğitim Verisi Üzerindeki Performans Karşılaştırması ..... 85

# SİMGELER VE KISALTMALAR LİSTESİ

| | |
|---|---|
| EEG | Elektroensefalografi |
| FMRI | Functional Magnetic Resonance Imaging |
| PET | Positron Emission Tomography |
| YSA | Yapay Sinir Ağları |
| RBF | Radial Basis Function |
| MSE | Mean Squared Error |
| PPV | Positive Predictive Value |
| NPV | Negative Predictive Value |
| AUC | Area Under Curve |
| TP | True Positive |
| FP | False Positive |
| TN | True Negative |
| FN | False Negative |
| F1 Puanı | Harmonik Ortalama |
| ROC | Receiver Operating Characteristic Curve |
| CRISP-DM | Cross-Industry Standard Process for Data Mining |
| SVM | Support Vector Machines |
| KNN | k-Nearest Neighbors |
| C&RT | Classification and Regression Trees |
| CHAID | Chi-squared Automatic Interaction Detector |

| | |
|---|---|
| C5.0 | C5.0 Karar Ağacı Algoritması |
| LR | Lojistik Regresyon |
| MR | Mantıksal Regresyon |
| RF | Random Forest |
| DEHB | Dikkat Eksikliği ve Hiperaktivite Bozukluğu |
| SPSS | Statistical Package for the Social Sciences |

# BÖLÜM I

# GİRİŞ

İletişim teknolojisindeki ilerlemelerin ve COVID-19 pandemisinin etkisiyle, öğrenciler arasında ders videoları izleme ve az maliyetli çevrimiçi öğrenme ortamlarına katılım popülarite kazanmıştır. Ancak multimedya öğrenme süreçlerinde etkileşim eksikliği nedeniyle öğrencilerin dikkatleri kolayca dağılabilmektedir. Bu konuda yapılan çalışmalar çevrimiçi öğrenme ortamlarındaki ders videolarını izleyen öğrencilerin dikkatini sürdürmekte zorluk yaşadıkları ve dikkat dağılması nedeniyle bu eğitimlerden beklenen verimliliği sağlayamama eğiliminde olduklarını göstermektedir (Aldaghri & Oraif, 2022).

Dikkat, beyin tarafından belirli zihinsel faaliyetlere odaklanma süreci veya bireyin çevresel uyaranlara yönelik odaklanma ve bu uyaranları işleme kapasitesi olarak tanımlanmıştır (Karaduman, 2004). Eğitimde ve bilişsel süreçlerde de dikkatin belirgin bir rolü bulunmaktadır. Araştırmalar, öğrencilerin dikkat seviyelerinin performanslarını önemli ölçüde etkileyebileceğini göstermiştir (Campos vd., 2013; Catwright, 2012; Montei vd., 1996; Woltz vd., 2000; Stevens & Bavelier, 2012). Bu yüzden hem sınıf içi hem uzaktan eğitim ortamlarında öğrencilerin dikkat seviyelerini değerlendirebilmek eğitimciler için son derece önemlidir. Bu değerlendirmeler, öğrencilere geri bildirim sağlanmasına ve öğrenci performansını geliştirmek amacıyla öğretim yöntemine müdahaleler yapılmasına olanak tanır.

Bunların yanında, düşünce faaliyetleri üzerine yaşanan odaklanma problemleri yaygınlaştığından birçok araştırma bu konu üzerinde yoğunlaşmaktadır (Aidman, 2020; Katz vd., 2018; Shernoff vd., 2016). Çalışmalar odaklanma sorununun getirdiği dikkat eksikliğinin işyerindeki, okuldaki ve kişisel hayattaki verimliliği etkilediğini göstermektedir.

Özellikle okullardaki öğrencilerin öğretim süreci boyunca dikkatli kalıp kalmamaları öğrenme çıktılarını etkilemektedir (Szczytko vd., 2018). Öğrencilerin dikkat seviyelerinin öğrenme başarısı ile doğrudan ilişkili olduğu gösterilmiştir (Sezer vd., 2017). Bu tür sonuçlar, öğretim sürecindeki dikkat eksikliğinin öğrenci başarısını etkileyebileceğini göstererek, eğitimcilerin bu konuya daha fazla dikkat etmelerini gerektirmektedir.

Günümüz eğitim sistemlerinde öğrencilerin dikkat seviyelerini değerlendirmek, öğrenme süreçlerini daha etkili ve verimli kılmanın kritik bir unsuru olarak öne çıkmaktadır. Dikkat seviyesini değerlendirmek için geleneksel yöntemler arasında öğrenci performansını değerlendirmek, sınavlar, öğretmen gözlemleri ve anketler bulunmaktadır (Hollands & Bakir, 2015). Ancak, bu geleneksel yöntemler, genellikle öznel ve durağan bilgiler sağladığı için objektif bir değerlendirme sunma konusunda sınırlılıklara sahiptir. Öğrenci dikkat performansı, bir test veya sınav sonuçlarına dayanabilir, ancak bu, anlık dikkat seviyelerini ölçmede yetersiz kalabilir. Öğretmen gözlemleri de öğrencinin dikkatini belirli anlarda değerlendirmekte etkili olabilir, ancak sürekli izleme ve nöral aktiviteyi anlama konusunda sınırlılıklara sahiptir. Bu yüzden araştırmacılar dikkat seviyelerini objektif bir şekilde değerlendirmek amacıyla EEG (Elektroensefalografi) verilerini kullanmaya yönelmişlerdir. EEG, beyin aktivitesini doğrudan ölçme yeteneği sunar ve bu da öğrencinin dikkat seviyesini anlık olarak takip etme olanağı sağlamaktadır (Ko vd., 2017). EEG verileri, farklı dikkat seviyelerini belirlemede daha hassas ve nöral temelli bir yaklaşım sunmaktadır. Araştırmacılar, EEG'nin öğrencinin zihinsel durumunu daha kapsamlı bir şekilde anlamalarına ve eğitim stratejilerini kişiselleştirmelerine olanak tanıdığı için bu yöntemi tercih etmektedir (Enriquez-Geppert vd., 2017). EEG'nin kullanımı, öğrenme süreçlerini daha iyi anlama ve eğitim ortamlarını optimize etme amacını taşıyan nörobilim araştırmalarında önemli bir araç haline gelmiştir.

Bu bağlamda, geleneksel yöntemlerin öznel değerlendirmelerine dayalı sınırlamalarının ötesinde, EEG cihazlarının kullanımıyla elde edilen nesnel bilgilerin, öğrencinin dikkat performansını değerlendirme ve öğrenme süreçlerini optimize etme konularında önemli bir potansiyele sahip olduğu belirtilmiştir (Sherif & Sherif, 1969). Öğrencilerin dikkat seviyelerini geleneksel yöntemlerle belirlemek için yüz ve vücut ifadelerine dayalı öznel değerlendirmeler yerine, non-invaziv ve taşınabilir yeni nesil elektroensefalografi (EEG) cihazlarıyla öğrencilerin anlık zihinsel durumları hakkında nesnel bilgiler sağlanmaktadır (Krigolson, 2017). Bu teknolojik gelişmeler, öğrencilerin dikkat seviyelerini objektif bir şekilde ölçme ve anlama konusunda önemli bir ilerleme sağlamıştır.

Yakın dönemde yapılan araştırmalar, EEG cihazlarının kullanımının sınıf içi öğrenme deneyimlerini zenginleştirebileceğini göstermiştir (Samimisabet vd., 2023; Soufineyestani vd., 2020; Värbu vd., 2022). Örneğin, öğrencilerin zihinsel odaklarını belirlemek, öğretmenlere öğrenme süreçlerini daha iyi anlama ve öğrenciye özelleştirilmiş geri bildirim sağlama konusunda değerli bir araç sunabilir. Bu teknoloji sayesinde, öğretmenler öğrencilerin dikkat seviyelerini belirleyerek ders içeriğini daha etkili bir şekilde uyarlayabilir ve öğrencilere bireysel ihtiyaçlarına göre rehberlik edebilirler.

EEG, beyin fonksiyonlarının elektriksel aktivitesini değişik frekanstaki beyin dalgalarını ölçerek elde eder ve bu sinyallerin analizi ile beynin işleyişi hakkında bilgi edinilebilir. Bu ölçümler elektrotlar yardımıyla yapılır. Elektrotlar deride belirlenen özel yerlere, beyindeki elektriksel aktiviteyi ölçmek ve kaydetmek için yerleştirilir (Sürmeli, 2010). Beyin, milyarlarca nöron aracılığıyla kompleks elektriksel sinyalleri işleyerek bilgi işleme merkezi olarak görev yapar. Nöronlar arasındaki bu elektriksel iletişim, beyinde sürekli olarak devam eden bir etkileşim ağı oluşturur ve bu etkileşimler, elektromanyetik dalgalar olarak ölçülebilen aktiviteleri tetikler (Soufineyestani vd., 2020). Bu nedenle, EEG cihazları sayesinde elde edilen nesnel bilgiler, beyindeki kompleks etkileşim ağını anlama ve bu anlayışa dayalı olarak öğrenme süreçlerini takip etme potansiyelini artırabilir.

EEG verileri kullanılarak dikkat sürecinin zaman içinde nasıl değiştiği ve bu değişikliklerin bilişsel performansa etkisi incelenmiştir (Stikic vd., 2011). Ayrıca, EEG analizlerinin öğrenme sürecinin farklı aşamalarında nasıl farklılaştığını göstererek, öğrencilerin bilgi işleme süreçlerini anlamak için EEG'nin nasıl kullanılabileceği üzerine çalışmalar da yürütülmüştür (Chen, Song, & Li, 2019; Rahman & Fattah, 2020).

Öğrencilerin dikkat seviyelerinin bilişsel becerilere olan etkisini anlamak amacıyla EEG sinyallerinin kullanımının bu ilişkiyi aydınlatmak için kritik bir araç olduğu görülmektedir. Öğrencilerin dikkat durumları, bilişsel süreçlerle doğrudan ilişkilidir (Gül & Çeliköz, 2023). Özellikle, öğrencinin dikkatini belirli bir konuya yoğunlaştırma yeteneği, o konuda daha etkili öğrenmesini sağlar. Bu nedenle, EEG verileriyle yapılan analizler, öğrencilerin dikkat seviyelerinin bilişsel işlevler üzerindeki etkilerini açık bir şekilde anlamamıza olanak tanır.

Bu çalışma, video izleme süreci sırasında EEG sinyalleri kaydedilen öğrencilerin izledikleri video ile ilgili sorulan sorulara verdikleri cevaplar aracılığıyla dikkat seviyelerini belirlemeye çalışmaktadır. Çalışmanın sonuçlarının, eğitimciler ve araştırmacılara öğrencilerin bilişsel performansının dikkate bağlı olarak değerlendirilmesinde yol gösterici

olacağı düşünülmektedir. Özellikle, öğrencilerin dikkat eksikliği sorunlarına bireyselleştirilmiş öğrenme yaklaşımları, teknoloji destekli eğitim araçları ve öğrenci destek programları gibi daha etkili müdahaleler geliştirmek adına bu sonuçlar, eğitimde dikkat odaklı politikalarının oluşturulmasına rehberlik edebilir.

Bu çalışma ayrıca, bilişsel psikoloji alanında yapılan çalışmaların bir parçası olarak, dikkatin öğrenme süreçlerine olan etkilerini daha geniş bir bağlamda ele almaktadır. Bu tür çalışmalar, bilişsel süreçlerin karmaşıklığını anlamak için önemlidir ve aynı zamanda eğitim pratiği için değerli bilgiler sunma potansiyeline sahiptir.

Sonuç olarak, bu çalışma kapsamında EEG verileriyle yapılan analizlerin, öğrencilerin dikkat seviyelerinin soruları cevaplama becerilerine olan etkisini anlamaya yardımcı olması ve çalışmanın sonuçlarının, eğitim alanında daha etkili müdahalelerin geliştirilmesi ve öğrencilerin öğrenme süreçlerinin iyileştirilmesi için bir kaynak teşkil etmesi beklenmektedir.

### 1.1. Dikkat

Günlük yaşamda çeşitli kaynaklardan gelen yoğun uyarılarla başa çıkma süreci, beynin tüm uyaranları işlemleyip yanıt üretmesi açısından olanaklı değildir. Dikkat, genel olarak algılanan uyaranların bir kısmına odaklanmayı ve diğerlerini filtrelemeyi sağlayan karmaşık bir bilişsel, fizyolojik ve davranışsal süreç olarak tanımlanır (James, 1890).

Dikkat, bilişsel psikolojide uzun bir tarihsel evrim sürecinden geçmiş ve farklı dönemlerde çeşitli tanımlamalara tabi tutulmuştur. William James ile başlayan bu tarihsel süreçten itibaren dikkat, psikoloji literatüründe kısıtlı bilişsel kaynaklara odaklanma ve odaklanılmayan uyaranları dışlama yeteneği olarak ele alınmıştır (Johnston & Dark, 1986). Daha sonraki yıllarda, Dijksterhuis ve Aarts, (2010) dikkati ilişkisiz yönlerin ihmâl edilmesi ve ilişkili yönlerin seçici ve tercihli bir şekilde işlemden geçirilmesi olarak tanımlayarak, dikkatin seçici işleme yeteneğine vurgu yapmışlardır. Dikkatin tarihindeki bu önemli dönemler, dikkatin farklı yönleri üzerine yapılan kapsamlı araştırmaların temelini atmış ve günümüzde dikkatle ilgili disiplinler arası çalışmaların giderek artmasına neden olmuştur (Posner & Petersen, 1990; Smith & Kosslyn, 2010). Bu bağlamda, dikkatle ilgili çalışmaların evrimi, psikoloji, nöroloji ve bilişsel bilim alanlarında kapsamlı bir anlayışın oluşturulmasına katkı sağlamıştır.

Dikkatin üç göreceli bağımsız bileşeni olduğu öne sürülmüştür. Bu bileşenler, duyusal uyaranlara yönelim, sinyalleri tespit etme ve işleme, uyarılmışlık halini sürdürme ve tetikte olma (vijilans) olarak sıralanır (Posner & Cohen, 1984; Posner & Petersen, 1990). Bu bileşenlerle uyumlu olarak, genel sınıflama seçici (odaklanmış), sürekli (sürdürülebilir) ve bölünmüş dikkat olarak yapılmaktadır (Bion, 2013).

Seçici dikkat, diğer uyarıların ihmal edilerek belirli bir hedefe odaklanılmasını içerir. Bu, tek bir veri kaynağına karşı yanlı hale gelmeyi gerektirir (Posner & Fan, 2008; Sternberg, 1996). Seçici dikkatin yönelim ve ön dikkat olmak üzere iki alt sistemi vardır; yönelim, dikkatin bir odaktan diğerine yönlendirilmesini sağlar, ön dikkat ise algılanan uyaranlardan işlemleme yapılacak olanın seçilmesini ve yönelimin sürdürülmesini destekler (Colombo, 2001; Rothbart & Posner, 2001).

Sürekli dikkat, dikkati belli bir hedefe yönlendirmeyi sürdürebilme yeteneğidir (Johnson vd., 2007). Bu, uyarılmışlık ve tetikte olma durumunun sürdürülmesini içerir. Dağıtıcı etkilere rağmen bir görevi uzun süre devam ettirebilmek için sürekli dikkat şarttır. Sürekli dikkatte yüksek düzeyde uyanıklık vardır, ancak yanıt gerekli olmayabilir (Allport, 1989).

Bölünmüş dikkat ise, bilişsel kapasitenin paylaştırılmasıyla birden fazla bilgi kaynağına dikkat edilmesini içerir, bu da eş zamanlı olarak iki veya daha fazla uyarıcıyla ilgilenilmesini gerektirir (Moat vd., 2024).

Dikkat eksikliği ise, bilişsel süreçlerin odaklanma, sürdürme ve yönetme yeteneğindeki bir düzensizlik olarak tanımlanır ve özellikle eğitim bağlamında ciddi bir endişe kaynağıdır (Posner & Petersen, 1990). Gündelik yaşamda ve özellikle öğrenme süreçlerinde karşılaşılan bu durum, öğrencilerin bilgiyi etkili bir şekilde işlemelerini ve öğrenmeyi derinlemesine anlamalarını engelleyebilir. Dikkat eksikliğine sahip bireyler, dikkatlerini yoğunlaştırmakta zorlanabilir ve çevresel uyaranlardan gelen bilgileri filtreleme konusunda sorunlar yaşayabilirler.

Eğitim bağlamında, dikkat eksikliği genellikle öğrencilerin ders içeriklerine odaklanmalarını güçleştirebilir ve uzun süreli öğrenme aktivitelerinde dikkatlerini sürdürmekte zorlanabilirler (Layton, Barnett, & Hicks, 2018). Bu durum, özellikle çevrimiçi öğrenme ortamlarında, uzaktan eğitimde ve multimedya öğrenme araçlarında daha belirgin hale gelir (Realyvásquez-Vargas vd., 2020). Araştırmalar, çevrimiçi öğrenme platformlarının esnekliği ve erişim kolaylığı sunmasına rağmen, öğrencilerin dikkatini sürdürme konusunda zorluklar yaşadığını göstermektedir (Cinquin, Guitton, & Sauzéon, 2019; Ewe, 2019).

Dikkat eksikliği, öğrencilerin derse katılımını azaltabilir, öğrenme materyallerini etkili bir şekilde işlemelerini engelleyebilir ve sonuç olarak akademik başarılarını olumsuz yönde etkileyebilir (Jangmo vd., 2019).

Bu zorluklar, eğitimcilerin, öğrencilerin çevrimiçi öğrenme ortamlarında daha etkili ve sürdürülebilir bir odaklanma yaklaşımını benimsemelerini gerektirmektedir. Eğitimcilerin ve araştırmacıların bu konuya yönelmelerinin temel nedeni, dikkat eksikliğinin öğrencilerin öğrenme süreçleri üzerindeki olumsuz etkileridir. Video içerikleri, öğrencilerin dikkatini çekmek ve sürdürmek için çeşitli öğretim stratejileri kullanırken, çevrimiçi öğrenme ortamlarının öğrenciler üzerindeki dikkat dağıtıcı etkileri göz ardı edilemez (Dvorsky vd., 2020; Wolraich vd., 2019). Dikkat eksikliği, öğrencilerin öğrenilen bilgileri hatırlama kapasitelerini azaltabilir (Poissant vd., 2019) ve belirlenen öğrenme hedeflerine ulaşmalarını güçleştirebilir (Shah vd., 2021).

### 1.1.1. Dikkatin İzlenmesi

Öğrencilerin bilişsel süreçlerini anlamak amacıyla nörobilim araştırmalarında büyük ilerlemeler kaydedilmektedir. Bu bağlamda, EEG sinyallerinin kullanımı, özellikle dikkatin izlenmesi üzerine yapılan çalışmalarda önemli bir araştırma alanını oluşturmaktadır. EEG, beyindeki elektriksel aktivitenin non-invaziv bir şekilde ölçülmesine olanak tanıyan bir tekniktir. Bunun yanında EEG dışındaki diğer teknikler de bu alanda önemli bilgiler sunmaktadır.

Dikkatin izlenmesinde kullanılan diğer teknikler arasında fonksiyonel manyetik rezonans görüntüleme (fMRI), pozitron emisyon tomografisi (PET), göz izleme teknikleri ve sanal gerçeklik gibi yöntemler bulunmaktadır (Park, Dudchenko, & Donaldson, 2018; Pinilla vd., 2021; Tauriainen, 2022). Bu teknikler, farklı perspektiflerden dikkatle ilgili süreçleri inceleme avantajına sahiptir. Örneğin, fMRI, beyindeki kan akışını ölçerek nöral aktiviteyi haritalandırır ve dikkatle ilişkilendirilen bölgeleri belirlemekte kullanılır (Shi vd., 2020). Göz izleme teknikleri ise göz hareketlerini kaydederek kişinin dikkatini nesnelere nasıl yönlendirdiğini incelemekte kullanılır (Pelgrim, Espinosa, & Buchsbaum, 2023). Sanal gerçeklik, dikkatle ilgili davranışları simüle ederek kontrollü bir ortamda değerlendirme yapma olanağı sunar (Vortmann, Schwenke, & Putze, 2021).

Ancak, bu teknikler genellikle maliyetli, karmaşık ve sınırlı erişilebilirlikleri nedeniyle EEG'nin pratikte daha avantajlı olduğu durumlar bulunmaktadır (Hajebrahimi, Velioglu, &

Bayraktaroglu, 2022; Zhu & Lv, 2023). EEG, gerçek zamanlı veri toplama yeteneği, düşük maliyeti ve taşınabilirliği ile öne çıkmaktadır. Eğitimde dikkatin izlenmesinde kullanıldığında, öğrencilerin öğrenme deneyimlerini geliştirmek ve öğrenme zorluklarını anlamak için önemli bir araçtır (Rupp vd., 2019).

Sonuç olarak, dikkatin izlenmesinde EEG gibi teknikler, eğitimde bireyselleştirilmiş öğrenme deneyimleri sağlamak ve öğrencilerin bilişsel süreçlerini daha iyi anlamak için değerli araçlar sunmaktadır. EEG'nin pratik avantajları, diğer tekniklere göre onu tercih edilebilir kılmaktadır.

Dikkat, bilişsel işlemlerin yönetilmesinde kilit bir rol oynar ve bu süreç, beyin aktivitesinde belirli desenlerle ilişkilidir. EEG, bu desenleri inceleme ve anlama açısından değerli bir araçtır. Özellikle belirli frekans bandındaki EEG bileşenleri dikkatin elektrofizyolojik temsilini oluşturur. Dikkatin odaklanma ve dağılma durumlarında EEG spektral özelliklerindeki değişiklikler incelenmektedir (Park, Dudchenko, & Donaldson, 2018; Tauriainen, 2022).

Dikkatin izlenmesi, öğrenme süreçlerinde uygulama alanı bulmuştur. Örneğin, bir öğrenme görevi sırasında öğrencilerin dikkat düzeyinin izlenmesi, eğitim teknolojilerinin etkinliğini değerlendirmek için kullanılabilir (Shi vd., 2020). Ayrıca, dikkatin izlenmesi, öğrenme zorlukları, dikkat eksikliği ve hiperaktivite bozukluğu (DEHB) gibi durumları anlamak ve bu konularda müdahale stratejileri geliştirmek için önemli bir araştırma alanı oluşturur (Pinilla vd., 2021). EEG tabanlı çalışmalar, bireyler arasındaki dikkat farklılıklarını anlamak, öğrenme ortamlarını optimize etmek ve bilişsel performansı iyileştirmek için değerli bilgiler sunmaktadır (Vortmann, Schwenke, & Putze, 2021). Bu alandaki ilerlemeler, bilişsel süreçlerin daha iyi anlaşılmasına ve bu süreçlere dayalı olarak geliştirilecek özelleştirilmiş müdahalelerin tasarlanmasına olanak tanımaktadır (Hajebrahimi, Velioglu, & Bayraktaroglu, 2022; Pelgrim, Espinosa, & Buchsbaum, 2023; Zhu & Lv, 2023).

## 1.2. Elektroensefalografi (EEG)

Elektroensefalografi sinyali, beyindeki genellikle konik sinir hücrelerinin elektriksel aktivitesini ölçen bir yöntemdir (Elsayed, Zaghloul, & Bayoumi, 2017). EEG, beyin aktivitesini anlamak ve çeşitli bilişsel süreçleri incelemek için kullanılan önemli bir araştırma aracıdır. Elektrotlar aracılığıyla yapılan ölçümler, beyindeki farklı frekanstaki

beyin dalgalarını tespit etmeyi amaçlar ve bu dalgaların kaydedilmesiyle "beyin elektriksel resmi" oluşturulur (Sürmeli, 2010).

Beyin, geçmiş olayları hatırlama, duyusal izlenimleri işleme ve gelecekteki düşünceleri, anıları ve tahminleri oluşturma kapasitesine sahiptir. 7/24 aktif olan beyin, çevresel uyaranları sürekli olarak değerlendirir, filtreler, vurgular ve kişi farkında olmasa bile davranışsal süreçleri kontrol eder. EEG'nin tarihi, Alman psikiyatrist Hans Berger'in 1929'da insan beynindeki elektriksel aktiviteyi ilk kez ölçtüğü döneme dayanır. Berger'in çalışmaları, EEG'nin beyin aktivitesini yakalama kapasitesini ortaya koyarak nörofizyoloji alanında devrim niteliğinde bir adım olarak kabul edilir (Berger, 1929). Gelişen teknolojiyle birlikte, EEG cihazlarının tasarımı ve veri analizi yöntemleri üzerindeki ilerlemeler, bu tekniği daha etkili ve hassas hâle getirmiştir. Özellikle bilgisayar teknolojisinin gelişmesi, EEG verilerinin daha ayrıntılı bir şekilde analiz edilmesine ve beyin aktivitesinin karmaşıklığını anlamaya olanak tanımıştır. Modern EEG araştırmaları, beyin aktivitesini belirli frekans bantlarına ayırarak dikkat, hafıza, duygu durumu gibi bilişsel süreçleri incelemekte ve bu alanda önemli bulgular ortaya koymaktadır (Bridwell vd., 2018; Ouyang vd., 2020).

EEG sinyallerinin ölçülmesi, beyin aktivitelerinin izlenmesinde ve analiz edilmesinde kritik bir rol oynar. EEG sinyalleri, kafatasına yerleştirilen elektrotlar aracılığıyla kaydedilir ve bu elektrotlar, beyindeki nöronal aktiviteleri algılar. Bu ölçümler, hem klinik uygulamalarda hem de bilimsel araştırmalarda kullanılmakta olup, elde edilen sinyaller farklı dalga boylarında analiz edilerek birçok alanda önemli bilgiler sağlar. EEG sinyallerinin analiz edilmesi, bilişsel süreçlerin derinlemesine anlaşılması, nörolojik hastalıkların teşhisi ve tedavisi gibi uygulamalarda büyük önem taşır. Beynin çeşitli bölgelerinden elde edilen elektriksel sinyaller, ölçüm sonucunda belirli formüllerle ifade edilir. Bu formülize etme süreci genellikle Fourier dönüşümü veya başka spektral analiz teknikleri kullanılarak gerçekleştirilir. Fourier dönüşümü, bir sinyalin zaman alanındaki dalgalanmalarını frekans alanındaki bileşenlere dönüştürmeye yarayan matematiksel bir işlemdir. EEG sinyalleri için bu dönüşüm, bir zaman periyodu içindeki frekans bileşenlerini ayırmak anlamına gelir. Böylece, hangi frekansta hangi şiddette elektriksel aktivitenin olduğunu gösteren bir frekans spektrumu elde edilir. Bu spektrum, beyin aktivitelerinin frekans dağılımını görselleştirir ve bu sayede, çeşitli bilişsel durumlar hakkında bilgi sağlar. EEG sinyallerinin spektral analizleri, nörolojik durumların tanısında oldukça faydalıdır. Örneğin, epilepsi gibi nörolojik hastalıkların teşhisinde EEG sinyallerindeki anormal elektriksel aktiviteler belirlenebilir. Aynı zamanda, bilişsel durumların değerlendirilmesinde de kullanılır. Dikkat, motivasyon,

meditasyon ve bilişsel süreçler hakkında bilgi edinilebilir. Bu bilgiler cihazdan alınan delta (0.5- 4 Hz), teta (4-8 Hz), alfa (8-13 Hz), beta (13-30 Hz), ve gama (30 ve üzeri Hz) değerlerinden çıkarılmaktadır (Jackson & Bolger, 2014). EEG cihazından elden edilen delta, teta, alfa, beta ve gama dalgaları bireyin heyecan, korku ve dikkat seviyeleri hakkında bilgi vermektedir (Bazanova & Vernon, 2014). Her sinyal aralığının ilişkili olduğu bilişsel faaliyetler farklı şekillerde gösterilir.

EEG sinyalleri, beynin farklı bilişsel ve fizyolojik durumlarını yansıtan beş ana frekans bandında sınıflandırılır:

### 1.2.1. Delta Bandı (0.5-4 Hz)

Delta dalgaları, en düşük frekanslı ve en yüksek genlikli EEG dalgalarıdır, genellikle derin uyku ve bilinçsizlik durumlarında görülür. Bu dalgalar, beynin dinlenme ve yenilenme süreçleriyle ilişkilidir. Delta dalgaları, derin uyku sırasında baskındır ve beyin hasarı, dikkat eksikliği ve hiperaktivite bozukluğu gibi durumlarda da artış gösterebilir. Araştırmalar, delta dalgalarının özellikle derin uyku sırasında yoğun olduğunu ve bilinçsiz durumlarda önemli rol oynadığını göstermektedir. Dikkat süreçlerinde delta dalgalarının artışı genellikle gözlenmez, bu dalgalar daha çok dinlenme ve yenilenme dönemleriyle ilişkilidir (Markovska-Simoska & Pop-Jordanova, 2018).

### 1.2.2. Teta Bandı (4-8 Hz)

Teta dalgaları, uyanıklık ve uyku arasında, hafif uyku, meditasyon ve derin rahatlama durumlarında ortaya çıkar. Yaratıcılık, hayal kurma ve anıların geri çağrılmasıyla ilişkilidir. Teta aktivitesi çocuklarda ve genç erişkinlerde daha yaygındır. Araştırmalar, teta dalgalarının meditasyon ve derin rahatlama gibi zihinsel durumlar sırasında arttığını ve dikkat süreçleriyle ilişkili olduğunu göstermektedir. Özellikle dikkat eksikliği ve hiperaktivite bozukluğu olan çocuklarda teta dalgalarının belirgin şekilde arttığı gözlemlenmiştir. Ayrıca, teta dalgalarının dikkat gerektiren görevler sırasında artabileceği de bazı çalışmalarda rapor edilmiştir (Da Silva vd., 2022; Newson & Thiagarajan, 2019).

### 1.2.3. Alfa Bandı (8-13 Hz)

Alfa dalgaları, uyanıklık ve rahatlama arasında, gözler kapalıyken ve zihinsel olarak dinlenme durumunda ortaya çıkar. Genellikle oksipital lobda daha belirgindir. Alfa aktivitesi, zihinsel rahatlama ve uyanıklık durumlarıyla ilişkilidir. Alfa dalgaları, zihinsel rahatlama ve meditasyon sırasında artar ve bu durumlar sırasında beyinde belirgin hale gelir. Alfa dalgalarının artışı, zihinsel rahatlama ve meditasyon ile ilişkilendirilir, bu da beyinde sakinleşme ve stresin azalmasıyla ilişkilidir (Bazanova & Vernon, 2014).

### 1.2.4. Beta Bandı (13-30 Hz)

Beta dalgaları, aktif düşünme, problem çözme ve yüksek uyanıklık durumlarında görülür. Bu dalgalar daha hızlı ve düşük genlikli olup, yoğun zihinsel etkinlikler ve konsantrasyon süreçleriyle ilişkilidir. Beta aktivitesi, yüksek zihinsel etkinlikler ve stres durumlarında artar. Yoğun konsantrasyon, problem çözme ve anksiyete gibi durumlar sırasında beyinde belirgin hale gelir. Beta dalgalarının artışı, zihinsel uyanıklık ve dikkat gerektiren durumlarda önemli bir rol oynar (Newson & Thiagarajan, 2019).

### 1.2.5. Gama Bandı (30 Hz ve üzeri)

Gama dalgaları, yüksek frekanslı ve düşük genlikli dalgalardır. Bilinçli algılama, öğrenme ve bellekle ilişkilidir. Gama aktivitesi, beynin farklı bölgeleri arasındaki bilgi entegrasyonunu gösterir ve yüksek bilişsel işlevler, öğrenme, bellek, dikkat ve bilinçli farkındalıkla ilişkilidir. Gama dalgaları, beynin farklı bölgeleri arasındaki senkronizasyonu ve bilgi entegrasyonunu sağlayarak, karmaşık bilişsel görevler sırasında artar. Bu dalgaların artışı, yüksek bilişsel işlevlerin ve bilinçli farkındalığın göstergesidir (Yang vd., 2020).

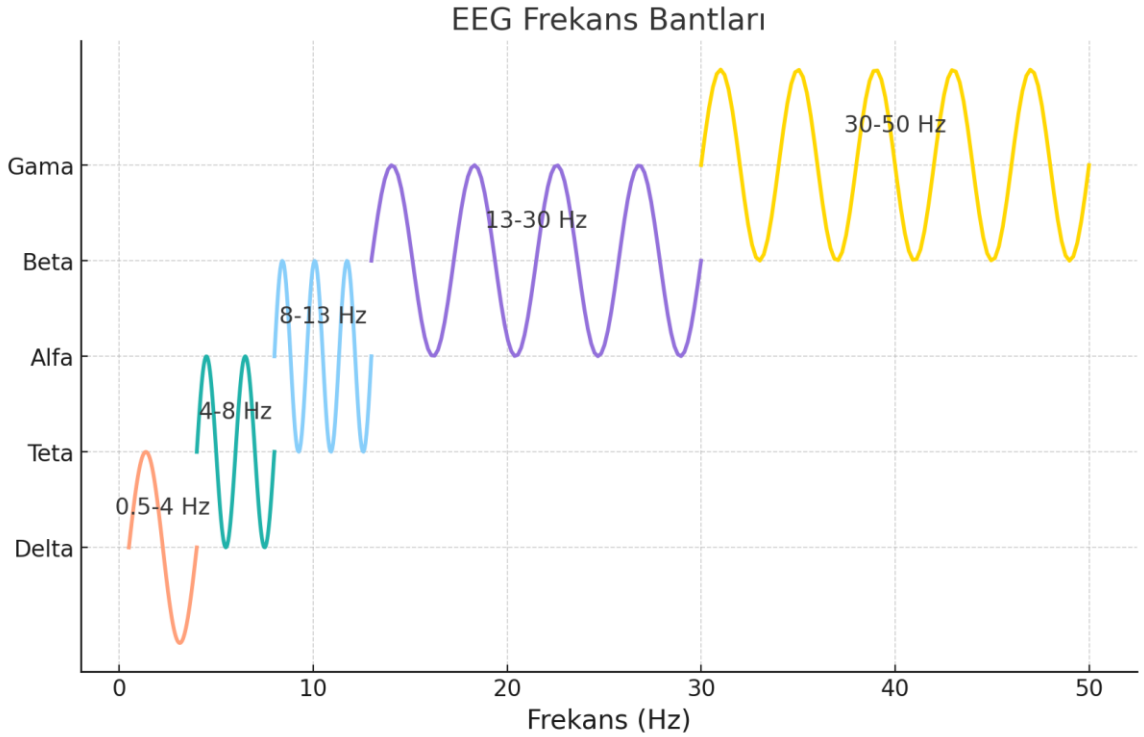


*Şekil 1.* EEG frekans bantları

### 1.3. Veri Madenciliği

Veri madenciliği, büyük veri yığınlarından anlamlı bilgileri ve trendleri ortaya çıkarmak için kullanılan bir yöntemdir. Bu yöntem, verileri çeşitli analitik teknikler kullanarak sınıflandırmak, tahmin etmek ve gruplandırmak için kullanılır. Veri madenciliği, birçok alanda ve farklı amaçlarla kullanılabilir. Örneğin, eğitim alanında öğrenci performansını anlamak, öğrenme modellerini geliştirmek ve öğrenci davranışlarını analiz etmek gibi faydalı uygulamalara sahiptir. Pazarlama alanında müşteri tercihlerini anlamak ve ürünleri tanıtmak için, sağlık alanında ise hastalıkların teşhisi ve tedavi yöntemlerini belirlemek için kullanılabilir. Veri madenciliği, verileri anlamlı bir şekilde yorumlayarak karar verme süreçlerini destekler. Literatürde veri madenciliği için yapılmış çeşitli tanımlar bulunmaktadır. Ganesh (2002), veri madenciliğini, veri tabanlarındaki büyük ve karmaşık veriler arasındaki bilinmeyen örüntüleri ve ilginç ilişkileri keşfetme bilimi olarak tanımlarken; Özkan (2008) ise büyük ölçekli verilerden değerli bilgiyi elde etme işi olarak tanımlamaktadır. Genel olarak, veri madenciliği, büyük veri yığınlarından kullanılabilir verinin çıkarılmasını sağlayan bir yöntemdir. Veri madenciliği, karar sürecini destekleyen ve problemi çözmek için gerekli bilgiyi bulmaya yarayan bir araçtır.

## 1.4. Veri Madenciliği Süreci

Veri tabanında bilgi keşfi, veri madenciliği ile paralel sürece sahiptir. Çeşitli şekillerde depolanan verilerle bu süreçte veri madenciliği yapılarak bilgi yığınları anlamlandırılmaya çalışılır (Ersöz & Ersöz, 2019). Bu süreç veri tabanındaki verileri çeşitli yöntemler ve teknikler kullanarak gerekli bilgileri ortaya çıkarmayı amaçlar. Bu bilgiler, veri tabanındaki verilerin yapısı, dağılımı ve özellikleri hakkında daha detaylı bilgi sağlar, bu da veri madenciliği sürecinde karar verme ve karar destek sistemlerine yardımcı olur.

Veri madenciliği ve veri tabanlarında bilgi keşfi konusunda literatür incelendiğinde, araştırmacılar tarafından çeşitli süreçler oluşturulmuştur. Veri tabanında bilgi keşfi süreci veri temizleme, veri bütünleştirme, veri seçme, veri dönüştürme, veri madenciliği, model değerlendirme ve bilginin sunumu adımlarından oluşmaktadır (Han vd., 2012). Veri tabanlarında bilgi keşfi süreci Şekil 1'de de görüldüğü gibi veri tabanındaki verinin seçimi, ön işleme ve dönüştürme adımlarından sonra veri madenciliği yöntemlerini uygulayarak algoritmalara dayalı örüntülerin değerlendirilerek bilgiye ulaşma sürecini ifade etmektedir (Fayyad vd., 1996).

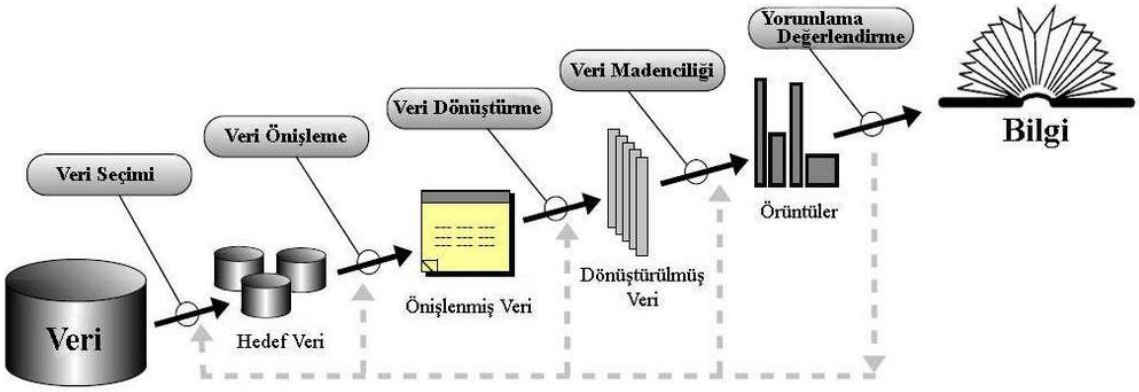


*Şekil 2.* Veri madenciliğinde bilgi keşfi süreci. Fayyad, U., Piatetsky-Shapiro, G., Smyth, P., & Uthurusamy, R. (1996). *Advances in knowledge discovery and data mining.* AAAI/MIT Press.

Fayyad, veri tabanında bilgi keşfi sürecini dört temel adımdan oluşan bir süreç olarak tanımlar. Bu adımlar, veri tabanının incelenmesi, verilerin temizlenmesi ve önişleme işlemlerinin yapılması, verilerin kümeleme, sınıflandırma ve öğrenme teknikleri kullanılarak anlamlı bilgilerin elde edilmesi ve sonuçların değerlendirilmesi ve gösterilmesidir. Veri

madenciliği sürecinin temelini oluşturan bu adımlar veri tabanındaki verileri anlamlı ve kullanışlı bilgilere dönüştürür.

Veri madenciliği, günümüzde büyük veri setlerinden anlamlı bilgiler çıkarmak için kritik bir araç haline gelmiştir. Ancak bu karmaşık süreci etkili bir şekilde yönetmek ve veri madenciliği projelerini daha verimli bir şekilde yönlendirmek amacıyla, Cross-Industry Standard Process for Data Mining (CRISP-DM) süreç modeli geliştirilmiştir. CRISP-DM süreç modeli, veri madenciliği projelerini sistematik ve disiplinli bir şekilde ele alarak, projelerin başarısını artırmayı hedefler; veri madenciliği süreçlerini daha şeffaf ve tekrarlanabilir hale getirir, böylece iş hedeflerine ulaşmayı kolaylaştırır. CRISP-DM süreç modeli, işi anlama, veriyi anlama, veri hazırlama, modelleme, değerlendirme ve dağıtım olmak üzere altı temel adımdan oluşur (Chapman vd., 2000; Ersöz & Ersöz, 2019).

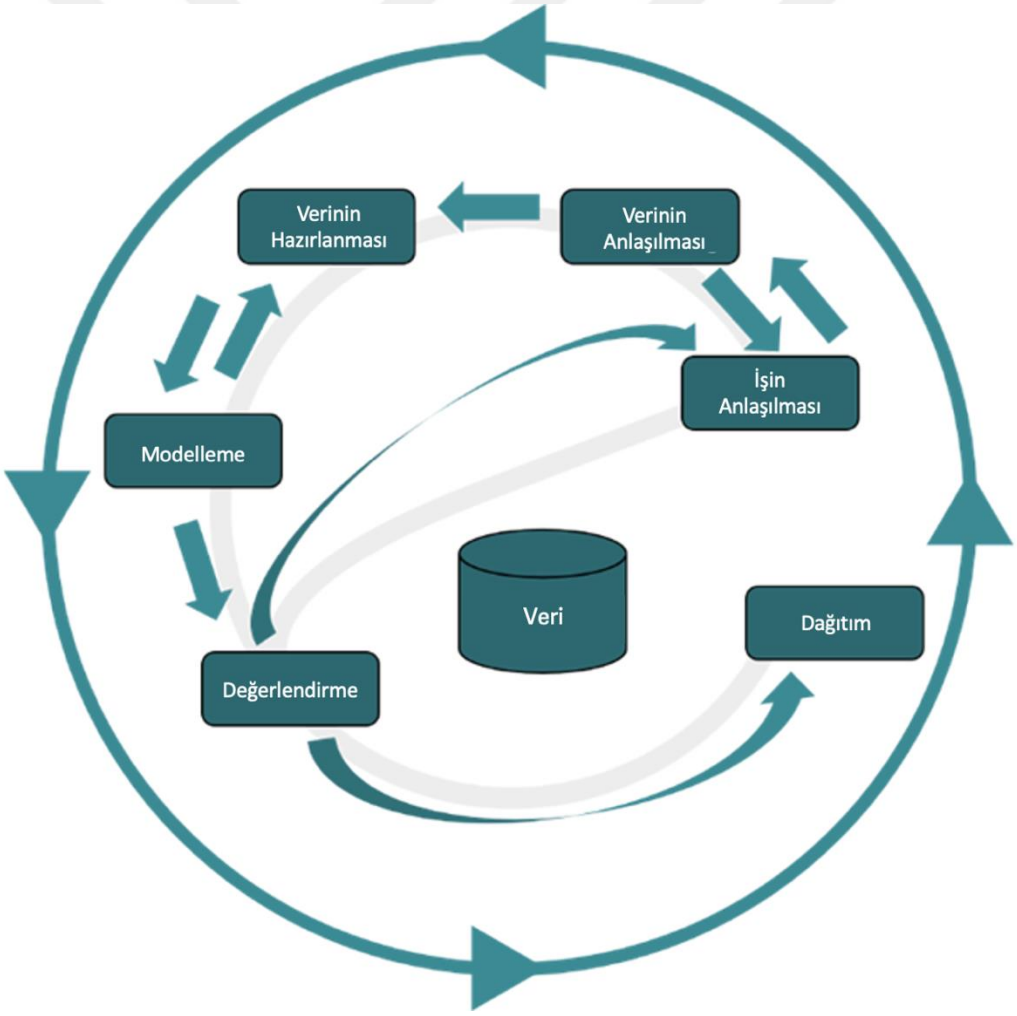


*Şekil 3.* CRISP-DM modelinin aşamaları (IBM SPSS Modeler CRISP-DM Guide, 2000, s. 1)

İşi anlama aşaması, araştırmanın hedeflerini ve gereksinimlerini anlamakla başlar. Bu aşamada problemi tanımlamak, başarı kriterlerini belirlemek ve araştırma planını oluşturmak önemlidir. İşin anlaşılması, araştırmanın başlangıcında iş hedeflerinin netleştirilmesini ve veri madenciliği hedeflerinin iş ihtiyaçları ile hizalanmasını sağlar (Shearer, 2000). Veri anlama aşamasında, mevcut verilerin toplanması, incelenmesi ve kalitesinin değerlendirilmesi gerçekleştirilir. Veri keşfi, veri görselleştirme ve temel istatistiksel analizler bu aşamada yapılır. Bu aşama, veri kaynaklarının tanımlanmasını, veri yapısının anlaşılmasını ve verilerin genel kalitesinin değerlendirilmesini içerir (Chapman et al., 2000). Veri hazırlama aşamasında, veri madenciliği modeli için verilerin temizlenmesi, dönüştürülmesi ve uygun formatta hazırlanması işlemleri yapılır. Bu aşama genellikle en çok zaman alan aşamalardan biridir ve eksik verilerin tamamlanması, aykırı değerlerin ele alınması ve veri normalizasyonu gibi işlemler yapılır (Wirth & Hipp, 2000). Modelin güvenirliği ve bilginin kalitesini artırmada veri temizleme adımının çok önemli olduğu vurgulanmaktadır (Ersöz, 2019). Verilerin dönüştürülmesi sürecinde verileri modele uygun hale getirmek için düzeltme, birleştirme, normalleştirme ve genelleştirme adımları uygulanır. Verilerin indirgenmesi, değişken sayısının fazla olup gereksiz verilerin azaltılması amacıyla faktör analizi, temel bileşenler analizi gibi yöntemlerle boyut indirgeme, veri küpü, örnekleme, veri sıkılaştırma, kesikli hale getirme, nitelik birleştirme gibi teknikler mevcuttur (Ersöz, 2019). Modelleme aşamasında, çeşitli modelleme teknikleri kullanılarak veriler üzerinde analizler yapılır. Model seçimi, model parametrelerinin ayarlanması ve modelin eğitilmesi bu aşamanın ana bileşenleridir. Modelleme sürecinde, farklı algoritmalar ve teknikler kullanılarak verilerin analiz edilmesi ve tahmin modellerinin oluşturulması hedeflenir (Ersöz, 2019). Değerlendirme aşamasında, modelin performansı değerlendirilir ve iş gereksinimlerine uygun olup olmadığı kontrol edilir. Modelin doğruluğu, hassasiyeti ve diğer performans metrikleri gözden geçirilir ve modelin iş hedeflerine ne kadar iyi uyduğunu ve beklenen performansı gösterip göstermediğini anlamak için çeşitli değerlendirme metrikleri kullanılır (Chapman vd., 2000). Son olarak, dağıtım aşaması modelin üretime alınması ve iş süreçlerine entegrasyonunu içerir. Bu aşama, modelin nasıl kullanılacağı, bakımının nasıl yapılacağı ve sonuçlarının nasıl raporlanacağı ile ilgilidir. Dağıtım aşaması, modelin canlı sisteme alınmasını ve iş süreçlerine entegre edilmesini sağlar (Wirth & Hipp, 2000). Bu aşamada değişkenler arasındaki farklılıkları gösteren grafiklerden yararlanılabilir (Ersöz, 2019).

## 1.5. Veri Madenciliği Modelleri

Veri madenciliği modelleri, büyük veri setlerinden anlamlı ve yararlı bilgiler çıkarmak amacıyla kullanılan algoritmalar ve tekniklerdir. Dunham (2003)'e göre, Şekil 3'te de görüldüğü gibi, tahmin edici ve tanımlayıcı olmak üzere iki gruba ayrılmaktadır. Tahmin edici modeller, sınıflandırma, regresyon, zaman serisi analizi ve tahmin yöntemlerinden oluşurken; tanımlayıcı modeller ise kümeleme, özetleme, birliktelik kuralları ve dizi tanıtma yöntemlerini içermektedir.

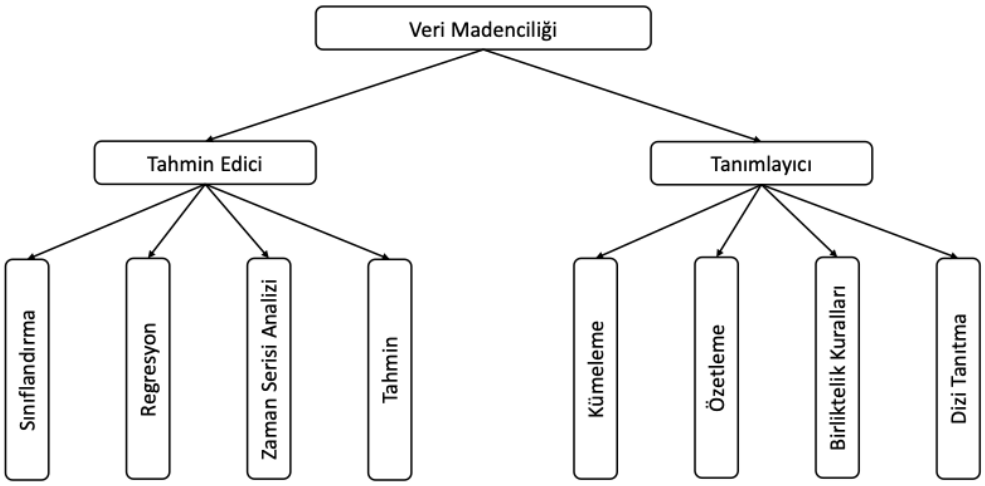


*Şekil 4.* Veri madenciliği görevleri ve modelleri Dunham, M.H. (2003)'den uyarlanmıştır.

Tahmin edici modeller, bilinen verilerden yola çıkarak bir model oluşturmayı ve bu model sayesinde bilinmeyen veri kümelerinin sonuçlarını tahmin etmeyi amaçlar. Diğer yandan, tanımlayıcı modeller, mevcut verilerdeki örüntüleri tanımlayarak karar verme süreçlerinde rehberlik sağlar (Dunham, 2003). Veri Madenciliği modelleri fonksiyonlarına göre sınıflandırma, kümeleme ve birliktelik kuralları olmak üzere üç kategoride toplanır (Akpınar, 2017).

### 1.5.1. Sınıflandırma

Veri madenciliğinde sınıflandırma, veri noktalarını belirli kategorilere veya sınıflara ayırmak için kullanılan bir süreçtir. Bu süreç, sınıfların önceden belirlendiği ve bu nedenle denetimli öğrenme olarak adlandırıldığı bir yöntemdir (Dunham, 2003). Sınıflandırma modelleri, genellikle etiketli veri setleri üzerinde çalışır. Sınıflandırma işlemi model eğitimi ve testi olmak üzere iki aşamaya ayrılır. Eğitim seti, öğrenme algoritmaları kullanılarak işlenir ve bu algoritmalar veri setinin örüntülerini öğrenir. Öğrenme aşaması tamamlandıktan sonra, modelin doğruluğu ve genelleme yeteneği test seti üzerinde değerlendirilir. Bu aşamada, modelin öğrendiği bilgi, sınıfları gizlenmiş test verisi üzerinde uygulanır ve modelin performansı çeşitli değerlendirme metrikleri ile ölçülür (Kotsiantis, 2007). Tahmin edici ya da kestirimci bir yöntem olan sınıflandırma yöntemi (Han & Kamber, 2012) için çeşitli algoritmalar geliştirilmiştir. Başlıca algoritmalar arasında Bayes Sınıflandırma Algoritması, C5.0, Karar ve Regresyon Ağaçları (C&RT), CHAID (Chi-squared Automatic Interaction Detector), Mantıksal Regresyon (MR), Lojistik Regresyon, k-En Yakın Komşu (KNN), Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (ANN) ve Rastgele Orman (RF) yer almaktadır (Ersöz, 2009). Çalışma kapsamında sınıflandırmaya dayalı yöntemlerden Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları kullanılmaktadır.

#### *1.5.1.1. Bayes Sınıflandırma Algoritması*

Bayes sınıflandırma algoritması, istatistiksel öğrenme teorisine dayanan ve Bayes teoremini kullanarak sınıflandırma yapan bir algoritmadır. Bu algoritma, özellikle metin sınıflandırma ve tıbbi teşhis gibi uygulamalarda yaygın olarak kullanılır. Bayes sınıflandırma, her bir sınıfa ait olma olasılıklarını hesaplar ve en yüksek olasılığa sahip sınıfı seçer. Naive Bayes olarak bilinen bir versiyonu, özellikler arasındaki bağımsızlık varsayımı ile basitleştirilmiş bir model sunar. Naive Bayes sınıflandırıcısı, özelliklerin (veya bağımsız değişkenlerin) sınıfa koşullu olasılıklarını kullanarak çalışır. Temel formülü Thomas Bayes'in teoremine dayanmaktadır (Han, Kamber & Pei, 2012).

$$P(Y|X) = \frac{P(X|Y) * P(Y)}{P(X)} \tag{1.1}$$

Burada *P(Y|X), X* özellik vektörüne göre *Y* sınıfının olasılığı. Bu, *X* özellik vektörü verildiğinde, verinin *Y* sınıfına ait olma olasılığıdır. Bu değer, sınıflandırma işleminin sonucunu belirler; yani, veri noktasının hangi sınıfa ait olduğunu tahmin etmek için kullanılır. *P(X|Y), Y* sınıfına göre *X* özellik vektörünün olasılığı. Bu, verinin *Y* sınıfına ait olduğu bilindiğinde, *X* özellik vektörünün gözlemlenme olasılığıdır. Bu, eğitim verilerinden öğrenilen koşullu olasılıklardır ve her özellik için hesaplanır. *P(Y), Y* hipotezinin ön olasılığıdır ve herhangi bir gözlem yapılmadan önce *Y* hipotezinin doğru olma olasılığıdır. *P(X)* ise *X* gözleminin olasılığı olup *X*'in tüm olası hipotezler altında gerçekleşme olasılığıdır. Bayes sınıflandırıcıları, eğitim veri setindeki her sınıf için ön olasılıkları *(P(Y))* ve her bir özelliğin sınıfa koşullu olasılıklarını *(P(X|Y))* hesaplar. Test aşamasında ise, verilen bir X özellik vektörü için yukarıdaki formül kullanılarak en yüksek olasılığa sahip sınıf tahmin edilir (Dunham, 2003).

Bayes algoritmasının avantajları arasında basitliği, hızlı çalışması ve küçük veri setlerinde bile yüksek doğruluk sunabilmesi yer alır. Ayrıca, özelliklerin (kelimelerin) birbirinden bağımsız olduğu varsayımının genellikle yeterince doğru olduğu ve büyük veri setlerinde oldukça iyi performans gösterdiği anlamına gelir (Rish, 2001). Bayes sınıflandırma, özellikle metin sınıflandırma gibi uygulamalarda yaygın olarak kullanılmaktadır. Metin sınıflandırmada, kelimeler arasındaki bağımsızlık varsayımı genellikle yeterli doğrulukta sonuçlar vermektedir. Bunun yanı sıra, tıbbi teşhis uygulamalarında da etkili sonuçlar elde etmektedir (Kononenko, 1990).

#### *1.5.1.2. Lojistik Regresyon*

Lojistik regresyon, veri madenciliği ve makine öğrenimi alanlarında sıkça kullanılan bir sınıflandırma yöntemidir. Temel amacı, bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi modellemektir (Han, Kamber, & Pei, 2012). Lojistik regresyon modeli, bağımlı değişkenin (y) belirli bir sınıfa ait olma olasılığını bağımsız değişkenlere (x) bağlı olarak nasıl değiştiğini anlamamızı sağlamaktadır. Bu model, denklem 1.2'de gösterilen lojistik fonksiyon denklemini temel alır (Hosmer, Lemeshow, & Sturdivant, 2013).

$$P(y = 1|x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \cdots + \beta_n x_n)}} \quad (1.2)$$

Burada $\beta_0$ sabit terim (*intercept*), $\beta_1$, $\beta_2$, …, $\beta_n$ katsayılar (*coefficients*) *ve* $x_1$, $x_2$, …, $x_n$ bağımsız değişkenlerdir (Menard, 2002, s. 45).

Lojistik fonksiyon, bağımlı değişkenin 1 olma olasılığını verir ve bu olasılığı denklem 1.3'deki logit fonksiyonuyla ifade edebiliriz.

$$logit(P) = log\left(\frac{P}{1-P}\right) = \beta_0 + \beta_1 x_1 + \cdots + \beta_n x_n \tag{1.3}$$

Bu formül, bağımlı değişkenin log-odds'unu (logit) bağımsız değişkenlerin doğrusal kombinasyonu olarak ifade eder (Wooldridge, 2016). Lojistik regresyon modelini eğitmek için maksimum olabilirlik tahmini (Maximum Likelihood Estimation, MLE) kullanılır. MLE, modelin parametrelerini (katsayıları) en iyi şekilde tahmin eder. MLE, parametrelerin log-likelihood fonksiyonunu maksimize ederek çalışır.

$$L(\beta) = \prod_{i=1}^{N} P(y_i|x_i;\beta) \tag{1.4}$$

Log-likelihood fonksiyonu denklem 1.5 ile ifade edilir.

$$\ell(\beta) = \sum_{i=1}^{N} [y_i log P(y_i|x_i;\beta) + (1-y_i)\log\,(1-P(y_i|x_i;\beta))] \tag{1.5}$$

Bu formül, modelin tahminlerini gerçeğe en yakın şekilde yapacak katsayıları bulmamızı sağlar (Draper & Smith, 1998, s. 78). Lojistik regresyonun avantajları arasında basitliği ve yorumlanabilirliği yer alır. Modelin katsayıları, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini doğrudan gösterir. Ayrıca, eğitim süresi genellikle hızlıdır ve modelin performansı kolayca değerlendirilir (Han, Kamber, & Pei, 2012, s. 239). Ancak, modelin doğruluğu ve güvenilirliği, veri setinin özelliklerine ve bağımsız değişkenlerin lineer olmayan etkilerini modelleyememe durumuna bağlıdır (Weisberg, 2005).

#### *1.5.1.3. C5.0*

C5.0 algoritması, Ross Quinlan tarafından geliştirilen ve veri madenciliği ile makine öğreniminde yaygın olarak kullanılan bir karar ağacı sınıflandırma algoritmasıdır. Bu algoritma, ID3 (Iterative Dichotomiser 3) ve C4.5 algoritmalarının gelişmiş bir versiyonudur ve daha yüksek doğruluk, daha düşük hesaplama maliyeti ve daha iyi model performansı sunar (Quinlan, 1986; Quinlan, 1993; Wendler & Gröttrup, 2021). C5.0 algoritması, veri setindeki her bir özelliğin belirli sınıflara ayrılmasında maksimum bilgi kazancı sağlayan bölünme noktalarını belirleyerek bir karar ağacı oluşturur. Bu bölünme kriteri, bilgi kazancını (information gain) hesaplamada entropi kavramını kullanır. Entropi, belirsizliğin bir ölçüsüdür ve denklem 1.6 ile hesaplanmaktadır.

$$H(p_1, p_2, \dots, p_s) = \sum_{i=1}^{s} (p_i \log\left(\frac{1}{p_i}\right)) \tag{1.6}$$

Denklemdeki $p_i$, sınıf $i$'nin olasılığıdır (Dunham, 2003).

C5.0 algoritması, bilgi kazancının aksine, kazanım oranı (gain ratio) adı verilen bir kriter kullanarak her bölümün niceliğini de dikkate alır. Kazanım oranı denklem 1.7'deki gibi hesaplanmaktadır.

$$Gain\ Ratio(D, S) = \frac{Gain(D, S)}{H\left(\frac{|D_1|}{|D|}, \dots, \frac{|D_s|}{|D|}\right)} \tag{1.7}$$

Burada $|D_i|$, $D_i$ alt bölümündeki veri sayısını ve |D| ise toplam veri sayısını temsil etmektedir (Dunham, 2003, s.101).

C5.0 algoritması, maksimum bilgi kazancını sağlayan en iyi bölme kriterine dayalı olarak karar ağacını oluşturur. Ayrıca, modelin karmaşıklığını azaltmak ve aşırı öğrenmeyi (overfitting) önlemek için budama işlemleri uygular. Budama, ağacın yapraklarını birleştirerek daha basit ve genelleştirilebilir bir model elde etmeyi sağlar (Crawford, 1989).

#### *1.5.1.4. CHAID (Chi-squared Automatic Interaction Detector)*

CHAID, Kass (1980) tarafından geliştirilen ve ki-kare ($x^2$) istatistiğine dayanan bir karar ağacı algoritmasıdır (Dunham, 2003). Bu algoritma, tahmin edici değişkenlerin kategorik olması gerektiğini varsayar. Eğer tahmin edici değişkenler sürekli ise, algoritma bu değişkenleri otomatik olarak istatistiksel benzerliklerine göre kategorilere ayırır (Wendler & Gröttrup, 2021). CHAID algoritması, veri kümesini bağımsız değişkenler bazında, bağımlı değişkene en fazla bilgi sağlayacak şekilde bölmek için ki-kare testini kullanır. Bu bölme işlemi, bağımsız değişkenlerin her bir kategorisinin bağımlı değişkenle olan ilişkisini ölçer ve en anlamlı ilişkileri temel alarak veri kümesini alt gruplara ayırmaktadır. Ki-kare testi, CHAID algoritmasının temel bileşenlerinden biridir ve kategorik bağımsız değişkenler arasındaki ilişkileri analiz etmek için kullanılır. Ki-kare testi, gözlemlenen frekanslar ile beklenen frekanslar arasındaki farkı ölçer ve denklem 1.8 ile hesaplanmaktadır. Burada $o_i$, gözlenen frekans ve $e_i$, beklenen frekans olarak formülize edilmiştir (Giudici, 2003).

$$X^2 = \sum \frac{(o_i - e_i)^2}{e_i} \tag{1.8}$$

Bu formül, her kategori için hesaplanan farkların karesinin beklenen frekansa bölünmesi ve bu değerlerin toplamını ifade eder. Ki-kare testi, kategorik bağımsız değişkenler için en uygun bölme noktalarını belirlemek amacıyla kullanılmaktadır (Kass, 1980). CHAID algoritması, bağımlı değişken sürekli olduğunda ise F testini kullanılmaktadır. F testi, gruplar arasındaki varyansın gruplar içi varyansa oranını ölçer ve denklem x'deki gibi hesaplanır. Denklemdeki $n$, toplam değeri; $k$, grup sayısını; $\bar{x}_i$, grup i'nin ortalamasını; $\bar{x}$, genel ortalamayı; $n_i$, grup i'deki gözlem sayısını; ${s_i}^2$ ise grup i'nin varyansını temsil etmektedir (Peck, Olsen & Devore, 2008).

$$F = \frac{(n-k)\sum n_i\,(\bar{x}_i - \bar{x})^2}{(k-1)\sum (n_i - 1){s_i}^2} \tag{1.9}$$

Bu formül, gruplararası kareler toplamını (between-group sum of squares) gruplariçi (hata) kareler toplamına (within-group sum of squares) böler. F testi, gruplar arasındaki farklılıkların istatistiksel anlamlılığını belirlemek için kullanılır. CHAID algoritmasında

bölme kriteri olarak Bonferroni düzeltilmiş p değeri kullanılır (Kass, 1980). Bu algoritmada, bağımsız değişkenlerin kategorileri arasında anlamlı bir fark bulunmadığında bu kategoriler birleştirilir. Birleştirme işlemi, ki-kare testine dayalı olarak en az anlamlı fark gösteren kategorilerin birleştirilmesiyle gerçekleştirilir (Kass, 1980).

CHAID algoritması, belirli bir anlamlılık seviyesi elde edilene veya belirli bir minimum örnek sayısına ulaşılana kadar bölme işlemini sürdürür. Bu, aşırı öğrenmeyi (overfitting) önlemek ve daha genelleştirilebilir bir model elde etmek için önemlidir (Biggs, De Ville, & Suen, 1991). CHAID algoritmasında budama işlemi yapılmaz (Rokach & Maimon, 2015; Wendler & Gröttrup, 2021), ancak istatistiksel testler kullanılarak ağacın fazla büyümesi önlenir (Dunham, 2003).

CHAID algoritması, özellikle pazar araştırmaları, müşteri segmentasyonu, anket analizleri ve tıbbi teşhis gibi alanlarda yaygın olarak kullanılmaktadır. Algoritma, veri setlerindeki karmaşık ilişkileri anlamaya ve önemli kararlar almaya yardımcı olur.

#### *1.5.1.5. Yapay Sinir Ağları (YSA)*

YSA, biyolojik sinir sistemlerinden esinlenerek geliştirilmiş, çok katmanlı yapılarla öğrenme gerçekleştiren güçlü bir makine öğrenimi yöntemidir (Haykin, 1999). YSA, veriler arasındaki karmaşık ilişkileri modellemek ve tahmin etmek için kullanılmaktadır. YSA'ların temel yapı taşları, yapay nöronlar veya düğümler olup, bu nöronlar giriş katmanı, bir veya daha fazla gizli katman ve çıkış katmanı halinde organize edilmiştir (Goodfellow, Bengio, & Courville, 2016). Yapay sinir ağlarının temel yapısı, bir nöronun giriş sinyallerini alıp, bunları ağırlıklandırarak ve aktivasyon fonksiyonu kullanarak bir çıkış üreten matematiksel bir modeldir. Temel bir yapay nöronun matematiksel modeli denklem 1.10'daki gibidir. Burada $x_i$, i. giriş değerini; $w_i$, i. giriş için ağırlığı; $b$, bias (sapma) terimini; $f$, aktivasyon fonksiyonunu ve $y$, nöronun çıkış değerini temsil etmektedir.

$$y = f\left(\sum_{i=1}^{n} w_i\, x_i + b\right) \tag{1.10}$$

Aktivasyon fonksiyonu, yapay sinir ağlarında nöronların ürettiği çıkışları belirler. En yaygın kullanılan aktivasyon fonksiyonları doğrusal aktivasyon fonksiyonu ($f(x)=x$), sigmoid

aktivasyon fonksiyonu $\left(f(x) = \frac{1}{1+e^{-x}}\right)$, hyperbolic tangent (tanh) fonksiyonu $\left(f(x) = \tanh(x) = \frac{2}{1+e^{-2x}} - 1\right)$ ve ReLU (Rectified Linear Unit) fonksiyonu $(f(x) = \max(0, x))$ olarak sıralanabilir. Aktivasyon fonksiyonları, ağın doğrusal olmayan ilişkileri öğrenmesine yardımcı olmaktadır (Goodfellow, Bengio, & Courville, 2016).

Yapay sinir ağları genellikle ileri besleme (feedforward) ve geri yayılım (backpropagation) algoritmaları kullanılarak eğitilir. İleri besleme, giriş verisinin ağ boyunca ileri doğru akışını ve çıkışların hesaplanmasını içerir. Çıkış katmanında, ağın tahminleri ile gerçek değerler arasındaki hata hesaplanır. Bu hata, ağın ağırlıklarını güncellemek için kullanılır. Geri yayılım, bu hatayı minimize etmek için ağırlıkları optimize eden bir algoritmadır. Bu işlem, zincir kuralı kullanılarak hata türevlerinin hesaplanmasını ve ağırlıkların güncellenmesini içermektedir. Geri yayılım algoritmasında, j. nöronun hata terimi denkem 1.11 ile hesapanmaktadır. Burada $\delta_j$, j; nöronun hata terimini; *E*, hata fonksiyonunu (genellikle ortalama kare hata, MSE) ve $z_j$, j; nöronun ağırlıklandırılmış girişini temsil etmektedir.

$$\delta_j = \frac{\partial \mathrm{E}}{\partial_{z_j}} \mathrm{f}'(z_j)$$

(1.11)

Yapay sinir ağlarında en yaygın kullanılan hata fonksiyonu ortalama kare hata (MSE) fonksiyonudur ve denklem 1.12'deki gibi hesaplanmaktadır. Buradaki $y_i$, gerçek değerleri ve $\hat{y}_i$ ise tahmin değerlerini temsil etmektedir.

$$E = \frac{1}{2}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

(1.12)

Radial Basis Function (*RBF*), yapay sinir ağlarında yaygın olarak kullanılan bir aktivasyon fonksiyonudur. RBF, giriş verilerini belirli bir merkeze göre değerlendirir ve genellikle örtük katman nöronları tarafından kullanılan bir fonksiyon türüdür. RBF'nin temel amacı, giriş uzayındaki verilere belirli bir uzaklığa göre cevap vermektir. RBF'nin temel özelliklerinden biri, merkezden uzaklaştıkça fonksiyonun değerinin azalmasıdır. Bu fonksiyon genellikle Gaussian fonksiyonu, Çoklu Kuadratik fonksiyonu veya Çoklu Ters Kuadratik fonksiyonu

gibi çeşitli biçimlerde olabilir. En yaygın kullanılan RBF türü Gaussian RBF'dir (Broomhead & Lowe, 1988). Denklem 1.13'teki gibi ifade edilmektedir.

$$\phi(x) = exp\left(-\frac{\|x - c\|^2}{2\sigma^2}\right) \tag{1.13}$$

Burada; $\phi(x)$, $x$ giriş vektörüne karşılık gelen RBF'nin çıkışını; $c$, RBF'nin merkezi olan vektörü; $\sigma$, fonksiyonun yayılma genişliğini kontrol eden bir parametreyi ve $\|x - c\|$ ise $x$ ile merkez $c$ arasındaki Öklidyen mesafeyi temsil etmektedir (Bishop, 2006).

Yapay sinir ağlarının eğitimi, genellikle geniş veri setleri kullanılarak yapılır ve model, bu veriler üzerinde birçok kez geçiş yapar. Her geçişte model, hata oranını azaltmak için kendini günceller. Bu sürece iterasyonlar denir ve eğitim, bu iterasyonların tekrarlanması ile gerçekleştirilir. Yapay sinir ağlarının eğitim süreci boyunca, modelin ağırlıkları ve bias terimleri optimize edilerek ağın tahmin performansı artırılır. Bias, modelin giriş verilerine uyguladığı sabit bir değerdir ve bu değer, modelin daha esnek bir şekilde öğrenmesini sağlar. Başka bir deyişle, bias terimi modelin belirli girişlere karşı daha doğru tahminler yapmasına yardımcı olur. Geri yayılım algoritması, her iterasyonda ağırlıkları güncelleyerek hata fonksiyonunu minimize eder (LeCun, Bengio, & Hinton, 2015).

### 1.5.2. Sınıflandırma Model Performansını Değerlendirme

Sınıflandırma modelleri kullanılırken model performansının değerlendirilmesi için çeşitli metrikler kullanılmaktadır (Wendler & Gröttrup, 2021). Bu metrikler doğruluk (*accuracy*), duyarlılık (*sensitivity*), özgüllük (*specificity*), hassaslık (*precision*) ve F puanı olarak sıralanabilir (Hossin & Sulaiman, 2015). Pozitif öngörü değeri (*PPV*), negatif öngörü değeri (*NPV*) ve ROC eğrisi altındaki alan (*AUC*) ölçütleri de sınıflandırma modellerinin etkinliğini ve güvenilirliğini değerlendirmek için önemlidir (Hauser vd., 2014). Bunların yanında, modelin tahmin ettiği sınıflarla gerçek sınıfları karşılaştırarak doğru ve yanlış sınıflandırmaların sayısını gösteren karışıklık matrisi (*confusion matrix*) de performans değerlendirmesinde kullanılmaktadır (Sammut & Webb, 2011). Matrisin her satırı, gerçek değerleri ifade ederken, her sütun ise tahmin edilen değerleri temsil etmektedir. İki sınıflı bir karışıklık matrisi ve alacağı değerler Tablo 1'de verilmiştir.

Tablo 1.
*Karışıklık Matrisi*

| | | Tahmin Edilen Sınıf | |
|---|---|---|---|
| | | Evet | Hayır |
| Gerçek Sınıf | Evet | TP | FN |
| | Hayır | FP | TN |

Tablo 1'deki karışıklık matrisinde geçen TP (*true positive*), sınıflandırıcı tarafından pozitif sınıfa ait verilerden kaç tanesinin doğru şekilde sınıflandırıldığını temsil etmektedir. TN (*true negative),* sınıflandırıcı tarafından negatif sınıfa ait verilerden kaç tanesinin doğru şekilde sınıflandırıldığını temsil etmektedir. FP (*false positive*), gerçekte negatif sınıfa ait olan bir verinin sınıflandırma sonucunda pozitif sınıf olarak etiketlenmesidir. FN (false negative) ise gerçekte pozitif sınıfa ait olan bir verinin sınıflandırma sonucunda negatif sınıf olarak etiketlenmesidir (Alan & Karabatak, 2020).

Karışıklık matrisi yardımı ile sınıflandırma performansını belirlemek için kullanılan metrikler ise açıklamaları ile beraber aşağıda verilmektedir.

Doğruluk (*accuracy*), modelin genel olarak ne kadar doğru tahmin yaptığını gösterir ve denklem 1.14'deki şekilde hesaplanmaktadır (Hossin & Sulaiman, 2015).

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \tag{1.14}$$

Duyarlılık (*sensitivity*), modelin pozitif sınıfları ne kadar doğru tanımlayabildiğini gösterir ve denklem 1.15'teki şekilde hesaplanmaktadır (Hossin & Sulaiman, 2015).

$$Duyarlılık = \frac{TP}{TP + FN} \tag{1.15}$$

Özgüllük (*specificity*), modelin negatif sınıfları ne kadar doğru tanımlayabildiğini gösterir ve denklem 1.16'daki şekilde hesaplanmaktadır (Hossin & Sulaiman, 2015).

$$\text{Özgüllük} = \frac{TN}{TN + FP}$$

(1.16)

Hassaslık (*precision*) doğru tahmin edilen pozitif örneklerin sayısının tahmin edilen tüm pozitif örneklerin sayısına oranını gösteren bir ölçüdür ve denklem 1.17'deki şekilde hesaplanmaktadır (Hossin & Sulaiman, 2015).

$$Hassaslık = \frac{TP}{TP + FP}$$

(1.17)

F puanı, hassaslık ve duyarlılığın harmonik ortalamasıdır ve denklem 1.18'deki şekilde hesaplanmaktadır. Bu metrik, dengesiz veri kümelerinde model performansını değerlendirirken kullanışlı bulunmaktadır (Hossin & Sulaiman, 2015).

$$F = 2x\frac{Hassaslık\ x\ Duyarlılık}{Hassaslık + Duyarlılık}$$

1.18

Pozitif Öngörü Değeri (*PPV*), bir modelin pozitif tahminlerinin ne kadar doğru olduğunu göstermektedir. PPV, modelin pozitif sınıfa ait olarak tahmin ettiği örneklerin gerçekten pozitif olup olmadığını ölçmektedir. Matematiksel olarak denklem 1.19 ile ifade edilmektedir (Alan & Karabatak, 2020).

$$PPV = \frac{TP}{TP + FP}$$

1.19

Negatif Öngörü Değeri (*NPV*), bir modelin negatif tahminlerinin ne kadar doğru olduğunu göstermektedir. NPV, modelin negatif sınıfa ait olarak tahmin ettiği örneklerin gerçekten negatif olup olmadığını ölçmektedir. Matematiksel olarak denklem 1.20 ile ifade edilmektedir (Alan & Karabatak, 2020).

$$NPV = \frac{TN}{TN + FN}$$

(1.20)

ROC Eğrisi Altındaki Alan (*Under Area Curve- AUC*), modelin pozitif ve negatif sınıfları ayırt etme yeteneğini ölçen bir metriktir. ROC eğrisi, duyarlılığın yanlış pozitif oranına (1 - özgüllük) karşı grafiğini belirtmektedir. AUC, bu eğrinin altında kalan alanı temsil edip ve modelin genel performansını özetlemektedir. AUC değeri 0.5 ile 1 arasında değişir; 1 mükemmel ayrım gücünü, 0.5 ise rastgele tahmini ifade etmektedir. Yüksek bir AUC değeri, modelin pozitif ve negatif sınıfları doğru bir şekilde ayırt edebildiğini göstermektedir (Alan & Karabatak, 2020).

Veri madenciliğinde sınıflama modellerinin değerlendirilmesi, modelin performansını doğru anlamak için kritik öneme sahiptir. Dengeli veri setlerinde doğruluk, hassaslık, duyarlılık ve F puanı genellikle iyi göstergelerdir (Pamina vd., 2019). Dengesiz veri setlerinde ise doğruluk yanıltıcı olabilmektedir, bu nedenle hassaslık, duyarlılık ve F puanı daha güvenilir metriklerdir. Ayrıca, ROC eğrisi altındaki alan, modelin genel ayırt etme kapasitesini değerlendirmek için kullanışlıdır (Hossin & Sulaiman, 2015). Yanlış pozitiflerin maliyetli olduğu durumlarda hassaslık, yanlış negatiflerin maliyetli olduğu durumlarda ise duyarlılık önemlidir (Ullah vd., 2019). Genel performansı değerlendirmek için F puanı ve ROC eğrisi altındaki alan en iyi göstergelerdir. İyi performans için doğruluk %85 ve üzeri, hassaslık ve duyarlılık %70 ve üzeri, F puanı 0.7 ve üzeri, AUC ise 0.8 ve üzeri değerlere sahip olmalıdır (Jain vd., 2021). Bu metrikler, model performansını kapsamlı bir şekilde değerlendirmek için birlikte kullanılmalıdır.

### 1.5.3. Kümeleme

Kümeleme teknikleri, veri setlerini benzer özelliklere sahip alt gruplara ayırmak için kullanılmaktadır. Kümeleme modelleri, verilerin doğal yapısını keşfetmek amacıyla etiketlenmemiş veriler üzerinde çalışmaktadır. En yaygın kullanılan kümeleme algoritmalarından biri, K-Ortalamalar (*K-Means*) algoritmasıdır. K-Ortalamalar, verileri k adet küme merkezine en yakın olacak şekilde gruplar. Algoritma, küme merkezlerini iteratif olarak günceller ve her veri noktasını en yakın merkeze atar. K-Ortalamalar algoritmasının matematiksel ifadesi denklem 1.21 ile ifade edilmektedir.

$$J = \sum_{i=1}^{k} \sum_{x \in C_i} \|x - \mu_i\|^2$$

(1.21)

Burada; *J,* toplam hata fonksiyonu; k, küme sayısı; $C_i$, *i.* küme; *x*, veri noktası ve $\mu_i$, *i.* kümenin merkezini temsil etmektedir. K-Ortalamalar algoritması, hesaplama maliyetinin yüksek olması nedeniyle büyük veri setlerinde verimliliği artırmak için çeşitli optimizasyon teknikleri kullanır (MacQueen, 1967).

Hiyerarşik kümeleme ise verileri iç içe geçmiş hiyerarşik bir yapıda gruplar. Hiyerarşik kümeleme, birleştirici (*agglomerative*) ve bölücü (*divisive*) yaklaşımlar olmak üzere iki temel yaklaşım kullanır. Birleştirici yöntem, her bir veri noktasını başlangıçta kendi kümesi olarak kabul eder ve benzer kümeleri iteratif olarak birleştirir. Hiyerarşik kümelemenin matematiksel ifadesi ise denklem 1.22 ile ifade edilmektedir.

$$d(C_i, C_j) = min_{x \in C_i, y \in C_j} d(x, y)$$

(1.22)

Burada; $d(C_i, C_j)$, *i.* ve *j.* kümeler arasındaki mesafeyi $d(x, y)$ ise *x* ve *y* veri noktaları arasındaki mesafeyi temsil etmektedir (Murtagh & Contreras, 2012).

DBSCAN (*Density-Based Spatial Clustering of Applications with Noise*) algoritması, yoğunluk bazlı bir kümeleme algoritmasıdır. Bu algoritma, yoğun bölgelerdeki veri noktalarını küme olarak tanımlar ve düşük yoğunluklu alanlardaki noktaları gürültü olarak kabul etmektedir. DBSCAN algoritmasının temel bileşenleri Eps (küme oluşturmak için belirlenen maksimum mesafe) ve MinPts (bir kümenin oluşabilmesi için gerekli minimum veri noktası sayısı) olarak tanımlanır. DBSCAN algoritmasının çalışma adımları, her veri noktası için komşuluk bilgileri hesaplanması, Eps ve MinPts kriterlerine göre yoğun bölgelerin belirlenmesi ve yoğun bölgelerin birleştirilerek kümelerin oluşturulması şeklindedir (Ester vd., 1996).

### 1.5.4. Birliktelik

Birliktelik kuralları, büyük veri setlerinde belirli öğelerin birlikte ortaya çıkma olasılıklarını analiz etmeyi amaçlayan tekniklerdir. Bu kurallar, müşteri davranışlarını anlamak ve stratejik kararlar almak için önemli ipuçları sağlar. Apriori algoritması, sık öğe kümelerini ve bu kümeler arasındaki ilişki kurallarını keşfetmeyi sağlar. Apriori algoritmasının çalışma adımları, ilk aşamada tüm öğe kümelerinin taranması ve minimum destek değerini karşılayan öğelerin belirlenmesi, daha sonra bu sık öğe kümeleri kullanılarak aday öğe kümelerinin oluşturulması, aday küme içindeki her öğe kümesi için destek değerinin hesaplanması ve minimum destek değerini karşılayanların belirlenmesi ve son olarak minimum destek ve minimum güven değerlerini karşılayan öğe kümeleri kullanılarak ilişki kurallarının oluşturulması şeklindedir. Apriori algoritmasının temel bileşenleri destek (*support*) ve güven (*confidence*) değerleridir. Destek, belirli bir öğe kümesinin tüm işlemler içindeki yüzdesi olarak hesaplanır ve güven, bir öğe kümesinin belirli bir diğer öğe kümesiyle birlikte bulunma olasılığını ifade eder (Agrawal & Srikant, 1994).

FP-Growth (Frequent Pattern Growth) algoritması, Apriori algoritmasına alternatif olarak geliştirilmiş ve sık öğe kümelerini bulmak için daha verimli bir yol sunan bir algoritmadır. FP-Growth, veri setlerini tekrar tekrar taramak yerine, veri setini bir defa tarayarak sık öğe kümelerini bulur. FP-Growth algoritmasının temel bileşeni, Frekanslı Desen Ağaçları (FP-trees) olarak adlandırılan bir veri yapısıdır. FP-Growth algoritmasının çalışma adımları, veri seti taranarak öğelerin frekanslarına göre sıralanmış bir FP-tree oluşturulması, FP-tree üzerinde sık öğe kümelerinin minimum destek değeri kullanılarak bulunması ve sık öğe kümeleri kullanılarak daha büyük öğe kümelerinin oluşturulması ve minimum destek değeri karşılayanların belirlenmesi şeklindedir (Han vd., 2000).

## 1.6. Problem Durumu

Günümüz eğitim sistemlerinde, öğrencilerin dikkat seviyelerini ve bilişsel performanslarını doğru bir şekilde değerlendirmek, öğretim süreçlerinin etkinliğini artırmak için kritik bir öneme sahiptir. Ancak, geleneksel değerlendirme yöntemleri, öğrencilerin dikkat seviyelerini ve bilişsel yüklerini objektif ve sürekli bir şekilde izlemekte yetersiz kalmaktadır. Bu durum, öğretmenlerin öğrencilerin öğrenme süreçlerini ve dikkat durumlarını anlık olarak izleyip, müdahale etme imkanını sınırlamaktadır. Multimedya öğrenme ortamlarında, öğrencilerin dikkat seviyelerinin ve bilişsel performanslarının

değerlendirilmesi, öğrenme materyallerinin etkinliğini ve öğrencilerin katılımını artırmak için önemli bir ihtiyaçtır. Bu bağlamda, EEG (Elektroensefalografi) sinyalleri, öğrencilerin dikkat seviyelerini objektif ve sürekli bir şekilde izlemek için umut vadeden bir araç olarak ortaya çıkmıştır. EEG, beyin aktivitelerini ölçerek dikkat ve bilişsel süreçler hakkında anlık ve doğru veriler sunabilmektedir. Araştırmanın temel problemi, multimedya öğrenme sırasında EEG sinyalleri ve veri madenciliği teknikleri kullanılarak öğrencilerin dikkat seviyeleri ve bilişsel performanslarının nasıl değerlendirilebileceği üzerine odaklanmaktadır. Bu sorunun çözümü, eğitimde yeni ve daha etkili öğretim stratejilerinin geliştirilmesine katkı sağlayacaktır. Öğrencilerin dikkat seviyelerinin doğru bir şekilde değerlendirilmesi, öğretmenlerin öğretim yöntemlerini bireysel öğrenci ihtiyaçlarına göre uyarlamalarını ve öğrenme materyallerini daha etkili hale getirmelerini mümkün kılacaktır. Bu bağlamda, EEG tabanlı dikkat değerlendirme sistemlerinin geliştirilmesi, eğitim teknolojilerinin etkinliğini artıracak ve öğrenci başarısını olumlu yönde etkileyecektir. Aynı zamanda, bu tür sistemler, dikkat eksikliği ve hiperaktivite bozukluğu gibi dikkat problemleri olan öğrencilerin belirlenmesine ve uygun müdahale stratejilerinin geliştirilmesine yardımcı olacaktır.

### 1.7. Araştırmanın Amacı ve Önemi

Bu çalışma, video izlerken EEG sinyalleri kaydedilen öğrencilerin dikkat seviyelerini belirlemeye çalışmaktadır. Bu amaçla, öğrencilerden izledikleri videonun ardından yöneltilen iki soruyu doğru cevaplayıp cevaplayamamaları ile videoyu izlerken çekilen EEG sinyalleri arasındaki ilişkinin belirlenmesi amaçlanmıştır. Çalışmanın amacı, EEG sinyal tespiti ve sınıflandırması kullanarak öğrencilerin dikkatli olma durumlarının bilişsel durumlarla ilişkisini belirlemektir. Öğrencilerin dikkatli olup olmadığı belirlenirken, EEG sinyalleri ve veri madenciliği sınıflandırma metotları kullanılmıştır.

Bu çalışma, günümüz öğrenme teknolojilerinin önündeki zorlukları aşma potansiyeline sahip önemli bir çalışmadır. EEG sinyalleri aracılığıyla elde edilen verilerin detaylı analizi, bireylerin zihinsel aktivitelerini daha kesin bir şekilde anlamamızı sağlar. Bu, eğitim alanında öğretim süreçlerinin geliştirilmesi ve eğitim kalitesinin artırılması için kritik bir rehberlik sunabilir. EEG tabanlı zihinsel aktivite analizinin öğrenme stratejilerinin geliştirilmesinde önemli bir araç olduğunu göstermiştir (Lim vd., 2019). Öğrenme stratejilerinden olan aktif öğrenmede EEG, öğrencilerin dikkat seviyelerini ve zorlandıkları

anları tespit edebilirken, öz-düzenleyici öğrenmede öğrencilerin motivasyon ve stres düzeylerini izleyebilmektedir. Tekrar ve uygulama stratejilerinde EEG, hangi yöntemlerin daha etkili olduğunu belirlerken, görselleştirme ve zihin haritalarında beynin nasıl tepki verdiğini analiz eder. İşbirlikçi öğrenmede ise EEG, grup çalışmalarının beyin aktivitelerine olan etkisini inceleyerek, öğrenme süreçlerinin optimize edilmesine katkıda bulunur. Sınıf ortamında EEG uygulamaları, öğrencilerin taşınabilir ve kablosuz EEG cihazları kullanarak ders esnasında beyin aktivitelerini izlemelerini sağlar. Öğretmenler, bu EEG verilerini gerçek zamanlı olarak analiz ederek, ders materyallerini ve öğretim yöntemlerini anlık olarak ayarlayabilmektedirler. Ayrıca, EEG verileri öğrencilerin bireysel öğrenme ihtiyaçlarına göre özelleştirilmiş öğrenme stratejilerinin geliştirilmesine yardımcı olur (Klimesch, 1999; Luck, 2014). Dolayısıyla, bu çalışma da akademik literatürdeki bu önemli çalışmalara ek olarak bu boşluğu doldurma potansiyeline sahiptir.

Öğrencilerin dikkat durumlarını izlemek, eğitmen ve öğrenciler arasında yüz yüze etkileşimin olmaması nedeniyle uzaktan öğrenme gibi uygulamalar için özellikle yararlıdır. Öğretmenler ve öğrenciler arasındaki gerçek yüz yüze iletişim uzaktan eğitimde imkânsız olduğundan, öğrencilerin öğrenme durumunu değerlendirmenin zorluğu çevrimiçi eğitimlerde daha fazladır. Bu nedenle araştırmacılar EEG sinyalleri, öğrenme ve konsantrasyon arasındaki ilişkiyi incelemeye başlamışlardır. Ayrıca, bu araştırma öğrencilerin öğrenme süreçlerini daha etkili bir şekilde yönlendirmek için ipuçları sunabilir. Öğrencilerin dikkat seviyelerinin bilişsel becerileri üzerindeki etkilerini anlamak, öğretmenlerin öğretim stratejilerini optimize etmelerine yardımcı olabilir. Bu doğrultuda, dikkat seviyelerinin öğrenci başarısı üzerindeki etkisi incelenerek, bu tür analizlerin eğitimdeki önemi vurgulanmaktadır (Kim vd., 2018).

Son olarak, bu çalışma mevcut öğrenme teknolojilerindeki eksiklikleri belirleyerek bu alandaki bilimsel literatürü zenginleştirmektedir. EEG sinyalleri aracılığıyla elde edilen verilerin ayrıntılı analizi, öğrenme teknolojilerindeki gelişmeler için temel oluşturabilir. Bu doğrultuda, Liu ve ekibinin (2017) EEG verilerinin eğitim teknolojilerinde nasıl kullanılabileceğini gösteren çalışması da bu araştırmanın potansiyel önemini vurgulamaktadır. Bu çalışma da, eğitim alanındaki en son gelişmeleri şekillendirmede önemli bir rol oynayacaktır.

## 1.8. Araştırma Soruları

EEG sinyalleri ve veri madenciliği teknikleri kullanılarak öğrencilerin dikkat seviyeleri ve bilişsel görevi tamamlamaları nasıl değerlendirilebilir?

1. Öğrencilerin birinci soruya verdikleri cevapları belirlemede Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları yöntemlerinin önem düzeylerine göre sıralaması ve başarım istatistikleri nasıldır?
2. Öğrencilerin ikinci soruya verdikleri cevapları belirlemede Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları yöntemlerinin önem düzeylerine göre sıralaması ve başarım istatistikleri nasıldır?

## 1.9. Araştırmanın Sayıltıları

1. EEG sinyalleri, öğrencilerin dikkat seviyelerini doğru bir şekilde yansıtabilmektedir.
2. Video izleme sonrası yöneltilen sorular başka herhangi bir ön bilgiye gerek olmadan sadece videoyu dikkatli bir şekilde izleyenlerin yanıtlayabileceği şekilde tasarlanmıştır.

## 1.10. Araştırmanın Sınırlılıkları

Araştırmanın örneklemi, Eğitim Fakültesi lisans öğrencileri arasından gönüllülük esasına göre seçilen 29 öğrenciyle sınırlıdır ve küçük bir veri kümesi üzerinde çalışılmıştır.

# BÖLÜM II

# İLGİLİ ARAŞTIRMALAR

Bu bölümde, tez çalışmasının temelini oluşturan literatürdeki önemli araştırmalar ele alınmıştır. Araştırma konusuyla ilgili temel kavramlar ve bu kavramlar çerçevesinde yapılan önceki çalışmalar incelenmiş ve bu çalışmaların bulguları, metodolojik yaklaşımları ve elde edilen sonuçları belirtilmiştir.

## 2.1. Öğrenci Dikkati ve Bilişsel Beceriler Arasındaki İlişki

Duncan ve Magnuson'un (2011) yaptığı çalışma erken çocukluk dönemindeki başarı becerileri, dikkat becerileri ve davranış problemleri arasındaki ilişkileri incelemektedir. Çalışmanın amacı, bu becerilerin uzun vadeli eğitim ve akademik başarı üzerindeki etkilerini belirlemektir. 500 çocuk üzerinde yapılan bu araştırma, erken dönemde dikkat becerileri yüksek olan çocukların, akademik başarılarının da yüksek olduğunu göstermektedir. Dikkat ve akademik başarı arasındaki korelasyon 0.69 gibi yüksek bir değer olarak bulunmuştur. Çalışma, erken dönemde dikkat becerilerinin geliştirilmesinin, uzun vadede eğitim başarısını artırabileceğini göstermektedir. Bu bulgular, eğitim politikalarının erken müdahale ve dikkat geliştirme programlarına odaklanması gerektiğini vurgulamaktadır.

Hanushek ve Woessmann'ın (2012) çalışması, eğitim kalitesinin ekonomik büyümeye katkısını ve öğrenci dikkat becerileri ile bilişsel beceriler arasındaki ilişkiyi incelemektedir. Araştırma, PISA ve TIMSS gibi uluslararası değerlendirme programlarından elde edilen öğrenci performans verilerini kullanarak, dikkat becerilerinin bilişsel test sonuçlarıyla güçlü bir şekilde ilişkili olduğunu bulmuştur. Çalışmada kullanılan betimsel istatistikler, korelasyon ve regresyon analizleri ile boylamsal analizler, okul ve öğretmen kalitesinin öğrenci dikkat ve bilişsel becerileri üzerinde önemli bir etkisi olduğunu göstermiştir.

Sonuçlar, yüksek dikkat seviyelerine sahip öğrencilerin daha yüksek bilişsel performans sergilediğini ve bu durumun uzun vadede ekonomik büyümeye katkı sağladığını ortaya koymaktadır. Araştırma, eğitim politikalarının ve okul kalitesinin artırılmasının öğrenci dikkat becerilerini ve bilişsel performanslarını geliştireceğini ve böylece ekonomik kalkınmayı destekleyeceğini önermektedir.

McClelland vd. (2013), çalışmasında anaokulu çağındaki dikkat süresi ve kararlılığının 25 yaşındaki eğitim sonuçları üzerindeki etkilerini incelemektedir. Araştırmanın amacı, erken dönemdeki dikkat becerilerinin uzun vadeli eğitim başarısı üzerindeki etkilerini anlamaktır. 400 çocuk üzerinde gerçekleştirilen bu çalışmada, çocukların dikkat süreleri ve kararlılık düzeyleri ölçülmüş ve bu veriler 25 yaşındaki eğitim başarılarıyla karşılaştırılmıştır. Sonuçlar, erken dönemde dikkat süresi yüksek olan çocukların, yetişkinlikte daha yüksek eğitim başarılarına sahip olduğunu göstermektedir. Bu bulgular, dikkat becerilerinin erken dönemde geliştirilmesinin uzun vadeli eğitim ve kariyer başarısı için kritik olduğunu ortaya koymaktadır.

West, Kraft, Finn ve Martin (2016) çalışmasında, Boston'daki 300 öğrencinin bilişsel olmayan becerilerini (dikkat, öz düzenleme, motivasyon ve sosyal beceriler) ölçmüş ve bu becerilerin akademik performansa olan etkilerini incelemiştir. Çalışma, betimsel istatistikler ve korelasyon analizleri kullanarak bu becerilerin genel dağılımını ve akademik başarıyla olan ilişkilerini belirlemiştir. Çoklu regresyon analizleri, okul kalitesi ve sosyo-ekonomik durum gibi faktörlerin kontrol edilmesiyle, bilişsel olmayan becerilerin bağımsız olarak akademik başarı üzerindeki etkilerini ölçmüştür. Ayrıca, faktör analizi kullanılarak bu becerilerin belirli faktörler altında nasıl gruplandığı ve bu faktörlerin akademik başarı üzerindeki etkileri incelenmiştir. Bulgular, dikkat ve öz düzenleme becerilerinin yüksek olduğu öğrencilerin akademik başarılarının da yüksek olduğunu göstermiştir. Özellikle dikkat becerilerinin, akademik performans üzerinde güçlü bir etkisi olduğu bulunmuştur. Çalışma ayrıca, okul ve öğretmen kalitesinin, öğrencilerin bilişsel olmayan becerilerini geliştirmede kritik bir rol oynadığını ortaya koymuştur. Araştırmacılar, okulların ve öğretmenlerin, öğrencilerin bu becerilerini geliştirmeye yönelik programlar uygulamalarını ve bu şekilde öğrencilerin genel akademik performansını artırmalarını önermektedir. Bu bulgular, eğitim politikalarının ve programlarının sadece bilişsel değil, bilişsel olmayan becerileri de geliştirmeye odaklanması gerektiğini vurgulamaktadır.

Eckstein vd. (2017) çalışmasında dikkat ve bilişsel gelişim arasındaki ilişkiyi anlamak için ileri teknolojileri kullanmışlardır. Çalışmanın amacı, dikkat ve bilişsel süreçlerin nasıl

etkileştiğini daha iyi anlamaktır. Araştırmada kullanılan fMRI (fonksiyonel Manyetik Rezonans Görüntüleme) ve kortikal stimülasyon yöntemleri, beynin belirli bölgelerinin aktivitesini ölçerek ve manipüle ederek dikkat ve bilişsel süreçler hakkında derinlemesine bilgi sağlar. İleri düzey teknolojilerle desteklenen bu çalışma, göz bebeği hareketleri ve dikkat odaklanma süreleri gibi verilerle dikkat ve bilişsel beceriler arasındaki güçlü bağları ortaya koymaktadır. Araştırma, 120 öğrencinin katılımıyla gerçekleştirilmiştir ve katılımcıların dikkat düzeyleri ile bilişsel performansları arasındaki ilişkiler detaylı olarak analiz edilmiştir. Bulgular, dikkat süresinin artmasının bilişsel görevlerdeki başarıyı artırdığını göstermektedir. Çalışmanın önemi, eğitim ve nörobilim alanında dikkat ve bilişsel gelişim konusundaki anlayışımızı genişletmesidir.

Öğrencilerin dikkat seviyelerini beyin dalgaları sensörleri kullanarak değerlendirmek ve bu seviyelerin bilişsel yük ve öğrenme performansı üzerindeki etkilerini incelemek amacıyla Chen, Wang ve Yu (2017) bu çalışmayı gerçekleştirilmiştir. Araştırmaya 100 öğrenci katılmış, beyin dalgası sensörleriyle dikkat seviyeleri sürekli olarak izlenmiş ve öğrenme performansları çeşitli testlerle ölçülmüştür. Çalışmada, dikkat seviyelerinin yüksek olduğu dönemlerde öğrencilerin öğrenme performanslarının da yüksek olduğu bulunmuş; düşük dikkat seviyelerinin ise artan bilişsel yük ile ilişkili olduğu belirlenmiştir. Veriler, betimsel istatistikler, korelasyon ve regresyon analizleri ile değerlendirilmiş, dikkat izleme sistemlerinin eğitimde kullanımı konusunda önemli bulgular sunulmuştur. Çalışma, dikkat becerilerinin eğitim programlarına entegre edilmesi gerektiğini ve etkileşimli öğrenme materyallerinin öğrencilerin dikkat ve performansını artırdığını göstermektedir.

## 2.2. EEG Sinyalleri ile Dikkat Seviyelerinin Analizi

Xu, vd. (2023) dikkat seviyelerinin tanınmasına yönelik çok seviyeli bir yaklaşım önermektedir. Dört farklı dikkat seviyesi (yüksek, orta, düşük, ve dışa yönelik olmayan) oluşturulmuştur ve 10 EEG kanalından toplamda 10 özellik (zaman alanı ölçümleri, örnek entropi, ve frekans bandı enerji oranları) çıkarılmıştır. Çalışma, SVM sınıflandırıcısı kullanılarak dört farklı dikkat durumunu %88,7 tanıma doğruluğu ile sınıflandırmıştır. Daha sonra, orijinal özellik setinden yüksek ayırt edici güce sahip optimal özellik alt kümesini seçmek için sıralı-ileri-seçim yöntemi kullanılmıştır. Sonuçlar, filtrelenmiş özellik alt kümeleri kullanılarak sınıflandırma doğruluğunun %94,1'e yükseltilebildiğini göstermiştir.

Günümüzdeki mevcut öğrenme teknolojileri, öğrencilerin zihinsel eylemlerini doğrudan değerlendirecek bir mekanizmaya sahip değillerdir. Öğrenciler bilişsel eylemler sırasındayken beyinlerinde birçok farklı durum meydana gelebilir. Örneğin; derin düşünceler içerisine girebilirler, dikkat dağınıklığı yaşayabilirler, bir problemi çözmeye çalışırken çıkmaza girebilirler. Bu gibi durumların değerlendirilmesinin zorluğunu ele almak amacıyla, Mills ve diğerleri (2017), öğrenme sırasında EEG tabanlı bilişsel yük tespit cihazlarının kullanımını önermektedir. 12 kişiden oluşan 9. sınıf öğrencileriyle yapılan çalışmada, akıllı bir ders verme sisteminde deneysel olarak öğrencilerin bilişsel eylemleri EEG tabanlı ölçümlerle değerlendirilmiştir. EEG cihazı kullanılarak 90 dakikalık oturumlar boyunca öğrencilerin zihinsel durumları modellenmiştir ve bu deney sırasında veri toplanmıştır. Akıllı öğrenme ortamları, sinirbilim ve giyilebilir EEG algılamadaki ilerlemelerden yararlanarak, EEG'nin öğrenme sırasında bilişsel durumları izlemek için uygun bir yöntem olabileceğine dair ilk kanıtları sağlayan bu çalışma, öğrenme teknolojisi ile öğrenen arasındaki döngüyü kapatmaya yönelik bir çalışmadır.

Lundqvist ve arkadaşları (2016), beta dalgalarının (13-30 Hz) kısa süreli bellek görevlerinde bilişsel kontrol üzerindeki etkilerini incelemiştir. Araştırmaya 30 sağlıklı yetişkin katılmıştır. Katılımcılar, kısa süreli bellek görevlerini tamamlamış ve bu süreçte EEG kayıtları alınmıştır. Çalışma, özellikle beta dalga patlamalarının dikkat ve görev yönetimindeki rolünü incelemiştir. Zaman-frekans analizi kullanılarak, beta dalgalarının göreve bağlı aktivasyonları incelenmiş ve bu patlamaların bilişsel kontrol süreçlerinde kritik bir rol oynadığı belirlenmiştir. Beta patlamaları, bilgi işleme sırasında ortaya çıkan kısa süreli güçlü aktivasyonlar olarak tanımlanmış ve bu patlamaların, dikkat ve görev yönetiminde önemli bir role sahip olduğu bulunmuştur. Araştırmanın sonuçları, beta dalgalarının beyin bölgeleri arasında bilgi akışını düzenlemede kritik bir rol oynadığını ortaya koymuştur.

Miller ve arkadaşları (2014), gama dalgalarının (30-100 Hz) bilişsel süreçler üzerindeki etkileri incelenmiştir. Araştırmaya 25 sağlıklı yetişkin katılmıştır. Katılımcılara çeşitli bilişsel görevler verilmiş ve EEG kayıtları alınmıştır. Çalışmada, gama dalgalarının özellikle algısal entegrasyon ve duyusal bilgi işlemede kritik bir rol oynadığı bulunmuştur. Zaman-frekans analizi ve kaynak lokalizasyon teknikleri kullanılarak, gama dalgalarının farklı beyin bölgeleri arasındaki senkronizasyonu nasıl etkilediği incelenmiştir. Bulgular, gama dalgalarının duyusal bilgilerin hızlı işlenmesi ve bilişsel görevlerin verimli bir şekilde

gerçekleştirilmesinde önemli olduğunu ortaya koymuştur. Bu dalgalar, özellikle karmaşık bilişsel görevler sırasında artan aktivasyon göstermiştir.

Liu, Chiang, & Chu (2013), insanların dikkat seviyelerini belirlemek için mobil sensörlerle elde edilen EEG sinyallerinin kullanımını incelemişlerdir. Bu çalışmanın temel amacı, mobil sensörlerle toplanan EEG verilerinin analizi yoluyla insanların dikkat seviyelerini belirlemektir. Bu amaçla, öğrencilerden alınan EEG sinyalleri, öznitelik çıkarımı ve sınıflandırma teknikleri kullanılarak detaylı bir analize tabi tutulmuştur. Yapılan analizler sonucunda, mobil sensörler aracılığıyla elde edilen EEG verilerinin, insanların dikkat seviyelerini belirleme konusunda önemli bir potansiyele sahip olduğu gözlemlenmiştir. Öğrencilerin dikkatli olup olmadığını en iyi gösteren özelliklerin kombinasyonunu belirlemek amacıyla bu özellikleri hesaplamak ve analiz etmek için bir destek vektör makinesi (SVM) sınıflandırıcısı kullanılmıştır. Deney sonuçlarına göre, bu çalışmada önerilen yöntem %76,82'ye varan bir sınıflandırma doğruluğu sağlamaktadır. Mobil sensörlerden alınan EEG verilerinin doğru işlenmesi ve analizi ile insanların dikkat seviyeleri belirlenmiştir. Bu bulgu, özellikle eğitim ve öğretim süreçlerinde dikkat seviyelerinin izlenmesi ve değerlendirilmesi için potansiyel bir araç olarak öne çıkmaktadır. Ayrıca, bu çalışma, mobil sensörlerin EEG verileriyle birleştirilmesinin, bilişsel süreçlerin anlaşılması ve gelecekteki teknolojik gelişmeler için önemli bir adım olduğunu vurgulamaktadır.

Harmony ve arkadaşları (1996) EEG delta aktivitesinin içsel işleme süreçlerine dikkat gösterirken nasıl değiştiğini araştırmıştır. Özellikle zorlayıcı ve dikkat gerektiren görevler sırasında delta ve Teta dalgalarında artış gözlemlenmiştir. Katılımcı sayıları ve elde edilen sonuçlar, bu dalga boylarının dikkati yansıtma potansiyelini göstermektedir. Araştırma, delta (0.5-4 Hz) ve Teta (4-8 Hz) dalga boylarına odaklanmış ve katılımcılar mental görevler sırasında EEG kayıtları alınarak izlenmiştir. Bulgular, zor ve dikkat gerektiren görevler sırasında delta dalgalarında önemli bir artış olduğunu ve delta aktivitesinin bilişsel yükle ilişkili olduğunu ortaya koymuştur. Çalışmaya 20 sağlıklı yetişkin katılmış ve sonuçlar, delta dalgalarının dikkat ve bilişsel yükle yakından ilişkili olduğunu ve bu dalgaların dikkat gerektiren içsel işleme süreçlerinde önemli rol oynadığını tespit etmiştir.

Bunun yanında Knyazev (2007), motivasyon, duygu ve bu süreçlerin inhibitör kontrolünün beyin osilasyonlarındaki yansımalarını incelemiştir. Araştırma, beta, teta ve gama dalga boylarına odaklanmış ve EEG verileri kullanılarak bu dalga boylarının bilişsel ve duygusal süreçlerle nasıl ilişkili olduğu analiz edilmiştir. Bulgular, motivasyon ve duygusal süreçler

sırasında beta ve teta dalgalarının aktivasyonunda artış olduğunu ve özellikle teta dalgalarının inhibisyon kontrolü ile ilişkili olduğunu göstermiştir. Çalışmaya 50 sağlıklı yetişkin katılmış ve sonuçlar, delta ve teta dalgalarının duygusal ve motivasyonel süreçleryle ilişkili olduğunu ortaya koymuştur.

Farklı dalga boylarında yapılan çalışmalar da mevcuttur. Li ve diğerleri (2010) ve Klimesh (1996), yalnızca alfa ve gama bant dalgalarını kullanarak konsantrasyon sınıflandırması için özellikler çıkarmıştır. Bu iki bant dalgasının odaklanmaya dair belirleyici olabileceği düşünülmüştür. Szafir ve Mutlu (2012) çalışması ise alfa, beta ve gama bant dalgalarına dayanarak konsantrasyon seviyesi indeksi olarak yaygın kabul gören bir EEG sinyalleri ölçütü önermektedir. Bu çalışma, EEG sinyallerini kullanarak insan-robot etkileşimini anlamayı ve kullanıcıların dikkat ve duygusal durumlarını izleyerek bu etkileşimi iyileştirmeyi amaçlamaktadır. Çalışma, alfa, beta, ve gama dalga boylarına odaklanmıştır. EEG verileri, katılımcıların robotlarla etkileşim sırasında bu dalga boylarındaki değişiklikleri izlemek için kullanılmıştır. Deneyde, 20 sağlıklı yetişkin katılımcı yer almış ve her biri bir robotla etkileşime geçmiştir. Katılımcılar, robotun belirli görevleri yerine getirdiği ve katılımcıların bu süreçteki tepkilerini ve dikkat seviyelerini ölçen çeşitli senaryolara maruz bırakılmıştır. EEG verileri, katılımcıların dikkat düzeylerini ve duygusal tepkilerini belirlemek için analiz edilmiştir. Alfa dalgalarının rahatlama ve düşük dikkat durumlarıyla ilişkili olduğu, beta dalgalarının ise yüksek dikkat ve aktif bilişsel süreçlerle ilişkili olduğu bulunmuştur. Gama dalgaları, dikkat kontrolü ve çalışma belleği süreçleriyle bağlantılı olarak analiz edilmiştir. Çalışmanın sonuçları, EEG sinyallerinin insan-robot etkileşiminde kullanıcıların dikkat ve duygusal durumlarını izlemek ve iyileştirmek için etkili bir araç olduğunu göstermiştir.

### 2.3. EEG Sinyallerinin Veri Madenciliğinde Analizi

Chiang ve diğerlerinin (2018) yaptığı çalışma, EEG tabanlı dikkat algılama modelinin değerlendirilmesi ve öğrenme dikkatini artırma üzerine odaklanmaktadır. EEG verileri kullanılarak, öğrencilerin dikkat seviyelerini belirlemek için Bayes Ağları ve diğer makine öğrenimi algoritmaları (Karar Ağacı, Destek Vektör Makinesi, Naive Bayes) kullanılmıştır. Araştırmada 810 kayıt kullanılmış ve bu kayıtlar modelin eğitimi için kullanılmıştır. Bayes Ağı modeli, dikkat seviyelerini doğru bir şekilde sınıflandırmak için kullanılmış ve diğer algoritmalarla karşılaştırıldığında yüksek performans göstermiştir. Bayes Ağı modeli, dikkat

seviyelerini belirlemede %87 doğruluk oranı elde etmiştir. Bu, modelin dikkat seviyelerini doğru bir şekilde sınıflandırmada oldukça etkili olduğunu gösterip, EEG verileri ile dikkat seviyelerinin belirlenmesinde etkili bir araç olduğunu ortaya koymaktadır.

Ni, Wang ve Liu'nun (2020) çalışmasında, EEG sinyalleri kullanılarak çok modlu öğrenme ortamlarında öğrencilerin dikkat ve rahatlama seviyeleri analiz edilmiştir. Toplam 30 üniversite öğrencisinin katılımıyla gerçekleştirilen çalışmada, EEG sinyallerinden zaman ve frekans alanında özellikler çıkarılmış ve Korelasyon Tabanlı Özellik Seçimi (CFS) yöntemi ile yüksek ayırt edici güce sahip özellikler seçilmiştir. Sınıflandırma için Destek Vektör Makineleri (SVM) ve K-En Yakın Komşu (KNN) algoritmaları kullanılmıştır. SVM ile %89.5, KNN ile %87.3 doğruluk oranı elde edilmiştir. Bulgular, yüksek dikkat seviyelerinin öğrenme performansını olumlu etkilediğini, rahatlama seviyelerinin ise dikkatle ters orantılı olduğunu göstermiştir. Özellikle alfa dalgası aktivitesinin yüksek olduğu dönemlerde dikkat seviyelerinin düşük olduğu belirlenmiştir. Çalışma, EEG tabanlı sistemlerin eğitimde dikkat seviyelerini izleyerek öğrenme performansını artırmada nasıl kullanılabileceğini ortaya koymaktadır.

Ghasemi ve diğerlerinin (2022) yaptığı çalışmanın amacı, EEG sinyallerindeki olay ilişkili potansiyeller kullanarak dikkat eksikliği ve hiperaktivite bozukluğunu tespit etmektir. Çalışmada, delta ve teta dalgaları gibi düşük frekanslı EEG bileşenlerinin hiperaktivite bozukluğu tanısında önemli rol oynadığı bulunmuştur. Toplamda 60 katılımcı (30 hiperaktivite bozukluğu olan ve 30 sağlıklı birey) üzerinde yapılan çalışmada, EEG verileri toplanmış ve analiz edilmiştir. Veriler üzerinde Bayes Ağları, Destek Vektör Makineleri (SVM), K-En Yakın Komşu (KNN) algoritmaları kullanılmıştır. Özellik çıkarımı sürecinde, ERP bileşenleri ile ilgili zaman ve frekans alanındaki özellikler seçilmiştir. Bayes Ağı kullanılarak yapılan sınıflandırma sonucunda %85, SVM modeliyle %94,3 ve KNN modeliyle %91,6 doğruluk oranı elde edilmiştir. Sonuçlar, delta ve teta dalgalarının güç artışının hiperaktivite bozukluğu olan bireylerde belirgin olduğunu ve bu özelliklerin tanı süreçlerinde etkili bir şekilde kullanılabileceğini göstermektedir. Bu bulgular, EEG sinyallerinin hiperaktivite bozukluğu tanısında önemli bir araç olabileceğini ve makine öğrenimi yöntemleri ile yüksek doğruluk oranları elde edilebileceğini ortaya koymaktadır.

Yapılan araştırmalar, öğrencilerin dikkat seviyeleri ile bilişsel beceriler arasında güçlü bir ilişki olduğunu göstermektedir. Dikkat becerilerinin erken yaşlarda geliştirilmesi, uzun

vadede akademik başarıyı artırmaktadır. Eğitim kalitesinin ve öğretmen niteliklerinin bu becerilerin geliştirilmesinde kritik bir rol oynadığı bulunmuştur. EEG sinyalleri kullanılarak dikkat seviyelerinin izlenmesi ve analiz edilmesi, dikkat seviyelerinin öğrenme performansını nasıl etkilediğini ortaya koymaktadır. EEG tabanlı sistemler, öğrencilerin dikkat seviyelerini doğru bir şekilde izleyerek öğrenme süreçlerini iyileştirme potansiyeline sahiptir. Veri madenciliği yöntemleri, EEG sinyallerini analiz ederek dikkat seviyelerini yüksek doğruluk oranları ile sınıflandırmada etkili olduğunu kanıtlamaktadır. Özellikle delta ve teta dalgalarının dikkat ve bilişsel yük ile ilişkili olduğu, bu dalgaların dikkat seviyelerini yansıtma potansiyelinin yüksek olduğu belirlenmiştir. Genel olarak, bu çalışmalar EEG sinyalleri ve veri madenciliği tekniklerinin dikkat izleme ve eğitimde bilişsel süreçlerin değerlendirilmesi için güçlü araçlar olduğunu ortaya koymaktadır.

# BÖLÜM III

# YÖNTEM

Bu bölümde, ilk olarak araştırmada yer alan katılımcılar hakkında bilgilendirme yapılmış ardından veri toplamada kullanılan araçlar ile devam edilmiştir. Son olarak, araştırma sorularına cevap bulabilmek adına yapılan veri işleme, yöntem ve analizler verilerek bölüm sonlandırılmıştır.

Bu araştırmada nicel araştırma yöntemlerinden genel tarama modellerinden ilişkisel tarama modeli kullanılmaktadır. Genel tarama modelinde, çok sayıda elemandan oluşan bir evrende, evren hakkında genel bir yargıya varmak için evrenin tümü ya da ondan alınacak bir grup örnek ya da örneklem üzerinde tarama yapılmaktadır. İlişkisel tarama modeli, iki ve daha çok sayıdaki değişken arasında birlikte değişimin varlığını belirlemeyi amaçlayan tarama yaklaşımına denir. İlişkisel tarama modelinde, değişkenlerin birlikte değişip değişmediği; değişme varsa bunun nasıl olduğu saptanmaya çalışılır (Karasar, 2011).

Bu araştırma yöntemi, EEG verilerini kullanarak dikkat seviyelerini ölçmeye yönelik hazırlanmıştır. İlişkisel tarama modeliyle öğrencilerin dikkat düzeyleri ile doğru cevap verme eğilimleri arasındaki ilişki incelenmiştir. Gönüllü katılımcılardan elde edilen EEG verileri, veri madenciliği teknikleriyle analiz edilmiş, böylece öğrencilerin bilişsel performansları ile dikkat süreçleri arasında anlamlı ilişkiler saptanmaya çalışılmıştır. Küçük bir veri setine dayanan bu çalışma, özellikle dikkat süreçlerinin video tabanlı öğrenme bağlamında nasıl değiştiğini anlamaya katkıda bulunmaktadır.

## 3.1. Çalışma Grubu

Veriler çalışma için gönüllü olan 29 eğitim fakültesi lisans öğrencisinden (4 erkek, 21 kadın) toplanmıştır. Katılımcıların yaşları 19-23 arasında değişmektedir. Katılımcıların hepsi sağ

elini kullanmaktadır ve deneyde izletilen filmi daha önce izlememişlerdir. Dört katılımcıya ait veri, veri kalitesinin düşük olması ve veride kopmalar olması nedeniyle çalışma dışında bırakılmıştır. Deneylere başlamadan önce, her katılımcıya yapılacak görevlerin deneysel prosedürleri hakkında ayrıntılı açıklama içeren bir onam formu verilmiştir. (Etik Kurul Belgesi Ek 1'de verilmiştir.)

### 3.2. Veri Toplama Araçları

Araştırmada kullanılan EEG verileri, uluslararası 10-10 sistemine uygun şekilde, 0,5 kHz örnekleme frekansıyla, 8 elektrot kullanılarak İMotions 8 cihazıyla toplanmıştır. İMotions 8, yüksek dinamik çözünürlüğü (24 bit, 0,05 uV) ve örnekleme oranı ile hassas sistemlerden biridir ve 0-125 Hz bant genişliği sunmaktadır (*iMotions*, n.d.).

Beynin çeşitli bölgeleri EEG sinyalleri ürettiğinden, beynin elektromanyetik aktivitesi geleneksel olarak elektrotların kafatasındaki 37 farklı konuma bağlanmasını içeren uluslararası 10 - 10 elektrot yerleştirme sistemi kullanılarak toplanmaktadır (Soler vd., 2017). Bu yöntem EEG sinyallerinin gözlemlenmesini kolaylaştırsa da öğrencilerde uygulanması pratik değildir. Bir kişinin duyguları, zihinsel durumu ve dikkati beynin ön bölgesindeki çeşitli bölümler tarafından yönetildiğinden, sadece bu bölgeden gelen EEG sinyallerini gözlemlemek, öğrencilerin dikkatli olup olmadığını belirlemek için daha uygundur (Liu vd., 2013). Bu nedenle, çalışmada uygun beyin sinyalleri Şekil 5'te görünen 8 kanallı *İMotions 8 Channels* cihazı ile 10-10 sistemine uygun olarak toplanmıştır.




*Şekil 5.* Giyilebilir elektrofizyoloji sensör sistemi. iMotions. (n.d.). *İMotions 8*. iMotions. https://imotions.com/products/hardware/iMotions-8/

Çalışmaya katılan gönüllülere İki Dil Bir Bavul filminden alınan, bir video kesiti izletilmiştir. İki Dil Bir Bavul, öğrencilerle aynı dili konuşamayan bir öğretmenle sınıf arasında yaşanan olayları anlatmaktadır. Film, 2008 yapımı Türk filmi olup yeni mezun olmuş bir sınıf öğretmeninin, Şanlıurfa'da bir köy ilkokuluna atanmasını ve orada Türkçe bilmeyen öğrencileriyle geçirdiği bir yılını anlatmaktadır. Adana Altın Koza Film Festivali'nde En İyi Film ve Büyük Jüri Özel Ödülü, Antalya Altın Portakal Film Festivali'nde En İyi İlk Film Ödülü ve Abu Dabi Uluslararası Ortadoğu Film Festivali'nde En İyi Ortadoğu Belgeseli ödülü dahil olmak üzere birçok festivalde çeşitli dallarda ödül kazanan bir filmdir (Wikipedia, 2023). Bu filmin seçilmesinin sebebi, hem eğitimle ilgili bir film olması hem de filmin doğrudan öğretici veya bilgilendirici bir yaklaşımla yapılmamasıdır. Yani, seyirciye belirli bilgileri aktarmayı hedeflememektedir. Film, eğitim sistemine ve özellikle Türkiye'nin kırsal bölgelerindeki eğitim sorunlarına dikkat çekerken, aynı zamanda bireysel hikayeler ve deneyimler üzerinden duygusal bir yolculuk sunar. İki Dil Bir Bavul, bilgi aktarımı yerine, karakterlerin yaşadıkları ve hissettikleri üzerinden seyirciye ulaşmayı amaçlayan bir filmdir.

Bu çalışma bağlamında kaydedilen EEG aktivitesi ile katılımcıların izledikleri video kesitinde geçen anlatıya ne kadar dikkatlerini verdikleri çalışılmıştır. Veri analizleri 1 dakika uzunluğundaki bir videoda geçen olaylara ilişkin soru soran iki ayrı madde üzerinden yapılmıştır. Zaman serisi olarak kaydedilen ham EEG verileri salise serileri şeklinde elde edilmiştir. Video izleme süresi tüm öğrenciler için sabit tutulmuş olsa da, öğrencilerin her bir madde üzerinde geçirdiği süre arttıkça toplanan EEG verisi de artmaktadır. Katılımcıların soruları yanıtlamaları için belirli bir süre kısıtlaması getirilmemiştir. Maddeler şu şekildedir: "Veli toplantısını yönetirken/düzenlerken öğretmenin asıl amacı ne olabilir?" ve "Görselde izlediğiniz öğretmen davranışını en iyi yansıtan seçenek hangisidir?" Maddeler ve seçenekler aşağıda verildiği gibidir.

Veli toplantısını yönetirken/düzenlerken öğretmenin asıl amacı ne olabilir?

a) Öğrencilerin başarı durumlarını velilerle paylaşmak
b) Öğrencileri şikâyet etmek
c) Velilerin sorumluluk almasını sağlamak
d) Yaşadığı sorunları paylaşmak
e) Kendini tanıtmak

Görselde izlediğiniz öğretmen davranışını en iyi yansıtan seçenek hangisidir?

a) Öğretmen, veliler ile iletişiminde saygısız davranmıştır.
b) Öğretmen, velilerle iletişiminde genel olarak saygısız davranmamıştır, ancak bazı davranışları saygısız olarak yorumlanmaya açıktır.
c) Öğretmen, velilerle iletişiminde saygılı davranmıştır.
d) Öğretmen, velilerle iletişiminde çok saygılı davranmıştır. Sözlü ve sözsüz iletişiminde, velilerin kültürel yaklaşım, düşünce ve görüşlerine saygı duyduğunu açıkça ortaya koymuştur.

Maddeler katılımcıların verdikleri cevabın işaret ettiği dikkati ölçmeye yönelik hazırlanmıştır. Videoyu dikkatli bir şekilde izleyen öğrencinin sorulan iki soruyu da doğru olarak cevaplaması beklenmektedir.

### 3.3. Deney Ortamının Hazırlanması ve Deney Düzeneğinin Kurulması

Deneyin başlangıcında, gerekli tüm donanımların kurulumu gerçekleştirilmiştir. Deneyde kullanılan donanımlar arasında göz izleme cihazı ve elektroensefalografi (EEG) yer almaktadır. Deney ortamı, ayrıca entegre iki monitörün bağlı olduğu bir bilgisayarı içermektedir. Bu monitörlerden biri öğrenci, diğeri ise araştırmacı tarafından kullanılmak üzere tasarlanmıştır. Monitörlerin konumlandırılması, öğrenci ve araştırmacının karşılıklı oturabileceği şekilde, arka arkaya gelecek biçimde yapılmıştır. Araştırmacının bulunduğu alan, deneyin izlenmesi, başlatılması, durdurulması ve sonlandırılması gibi kritik süreçlerin yönetildiği bir kontrol merkezi işlevi görmektedir. Bu alan, deneysel sürecin denetlenmesi ve idaresi için yapılandırılmıştır. Öğrencinin bulunduğu alanda ise yalnızca sorular ve videolar gibi deneysel uyaranlar yer almakta olup, bu tasarım öğrencinin dikkatinin deneysel uyaranlar üzerine yoğunlaşmasını sağlamaktadır. Bu düzenleme, araştırmacı ve öğrenci ekranlarında gösterilen içeriklerin farklılaşmasını mümkün kılarak deneyin güvenirliğini artırmaktadır.

Deney kurulumu tamamlandıktan sonra, öğrencilere deney düzenekleri ve prosedür hakkında kapsamlı bir bilgilendirme yapılmıştır. Öğrenciler, deneyde kullanılacak cihazların nasıl bağlanacağı ve deney esnasında karşılaşacakları senaryolar ile deney sürecinde izlemeleri gereken davranışlar konusunda detaylı şekilde bilgilendirilmiştir. Öğrenciler, çalışmada gönüllü olarak yer almayı kabul ettiklerini resmi olarak beyan eden onam formlarını imzalamışlardır. Onam alınmasının ardından, cihazların öğrencilere bağlanması ve kalibrasyon sürecine geçilmiştir. Kalibrasyon aşamasında, cihazların doğru ve kesintisiz veri sağlayıp sağlamadığı kontrol edilmiştir. Gerekli kontrollerin tamamlanmasının ardından, deneye uygunluğu ilgili cihazlardan alınan sinyallerin tutarlılığı ve doğruluğu tespit edilen öğrencilerle deney süreci başlatılmıştır; uygunluğu teyit edilmeyen adaylar ise veri toplama sürecine dahil edilmemiştir.

Veri toplama süreci deneyde yer alan tüm maddeler katılımcılar tarafından cevaplandığında sonlandırılmış ve katılımcılardan cihazlar çıkarılmıştır. Bu prosedür, deneyin bilimsel geçerliği ve katılımcıların rahatlığı açısından büyük önem taşımaktadır.

### 3.4. Verilerin İşlenmesi

Çalışma IBM SPSS Modeler yazılımı (Ersöz & Ersöz, 2019) ve veri madenciliği sürecinde Cross-Industry Standard Process for Data Mining (CRISP-DM) metodolojisi kullanılarak

yapılmıştır. Bu metodoloji; işi anlama, veriyi anlama, veri hazırlama, modelleme, değerlendirme ve dağıtım adımlarından oluşmaktadır (Chapman vd., 2000; Ersöz & Ersöz, 2019).

Analizler, EEG sinyallerinin toplanması, Hızlı Fourier Dönüşümü ile öznitelik çıkarma ve SPSS Modeller ile sınıflandırma bölümleriyle ilişkilendirilerek açıklanmıştır. Veri madenciliği analizi yapmadan önce ham veriler düzenlenmeli, eksik veriler silinmeli, değişkenler yapılarına göre değerlendirilmelidir (Maimon ve Rokach, 2005). Bu işlemlere veri önişleme adı verilir. Veri önişleme verinin analiz edilmesini engelleyecek problemlerin temizlenmesi, veri yapısının anlaşılmasını daha kolay kılacak işlemlerdir.

Öğrencilerden, EEG verisinin yanısıra Empati ve Karakter Güçleri ölçeği gibi ölçeklerden de veri toplanmıştır (Kahraman, 2020). Bu ölçeklerden elde edilen veriler doğrultusunda 4 kişinin uç değer olduğu belirlenerek çalışmadan çıkarılmıştır. Bu sebeple analiz adımları 29 yerine 25 öğrenci üzerinden yürütülmüştür.

Öz nitelik çıkarımı, R programlama dili üzerinden Hızlı Fourier Dönüşümü kullanılarak, iMotions yazılımı ile otomatik olarak yapılmıştır (Farnsworth, 2019). Sıfır faz gecikmeli bant geçiren, yani frekansları belirli bir aralıkta ileten ve o aralığın dışındaki frekansları zayıflatan bir filtre kullanılarak, düşük ve yüksek frekanslar filtrelenmiştir. Buradaki frekans 0,5–100 Hz aralığındadır. Sinyalin bozulmasını önlemek için varsayılan değer 0,5 ve 45 Hz olarak seçilmiştir. EEG dosyasında ortalama değerleri geçersiz kılabilecek bir ani artış veya başka bir yapay olgu bulunan denemeleri yok saymak için artefakt reddi yapılmıştır. Artefakt, bilimsel bağlamda, özellikle biyomedikal sinyal işleme ve görüntüleme alanlarında, asıl veri veya sinyalin içine karışan istenmeyen parazitler veya bozulmalar anlamına gelir (Nolan vd., 2010). Bu bozulmalar, çeşitli dış kaynaklar veya cihazların neden olduğu hatalar sonucu oluşur ve verinin doğruluğunu ve güvenilirliğini etkileyebilir. Özellikle EEG gibi hassas ölçümlerde, artefaktlar genellikle göz kırpışları, kas hareketleri, kalp atışları gibi vücuttan kaynaklanan doğal sinyaller; güç hatları, elektronik cihazlar gibi dış ortamdaki elektromanyetik parazitler veya elektrodlardaki gevşemeler, hareketler, cihazların kendisinden doğan hatalardan kaynaklı olabilir. Artefakt reddi, EEG verisinden artefaktların tanımlanıp çıkarılması sürecini ifade etmektedir. Bu artefaktların çıkarılması, EEG verisinin doğru bir şekilde yorumlanmasını ve yanıltıcı sonuçları önlemeyi sağlamıştır. Artefaktların tanımlanıp çıkarılmasında, manuel inceleme, otomatik algılama algoritmaları ve bağımsız bileşen analizi gibi birçok metot kullanılabilmektedir (Makeig, 1996). Reddetme aralığı, kabul edilebilir minimum ve maksimum uV seviyelerine göre

seçilmektedir. Bu çalışmada, 120 uV eşik parametresine dayalı artefakt reddi yapılmıştır. Mutlak değeri bu eşiğin üzerinde olan veri noktaları aykırı değer olarak kabul edilmiş ve analiz için kullanılmamıştır. Kalite kontrolü olarak, kaldırılan verilerin yüzdesi hesaplanmış ve görüntülenmiştir. Burada yüksek yüzde, zayıf sinyal anlamına gelmektedir. Varsayılan eşik değeri (120 uV) yetişkin bir insanın tipik EEG sinyal genliğini (10-100 uV) korumak için seçilmiştir (Niedermeyer ve da Silva, 2005). İlgili sinyalin analizine bağlı olarak parametrenin uyarlanması gerekmektedir. Ardından, Hızlı Fourier Dönüşümü kullanılarak Güç Spektral Yoğunluğu (Power Spectral Density-PSD) hesaplanmıştır. Ortaya çıkan frekanslar [0, Fn] aralığındadır, buradaki Fn 0,5 örnekleme oranını temsil eden Nyquist oranıdır. Başka bir deyişle, filtrelenmiş sinyal 1 saniyelik hamming pencerelerine (0,5 saniyelik bir örtüşmeyle) parçalanır. Belirli bir 1 saniyelik pencere için veri noktaları geçersizse (yani bir yapı olarak kabul edilirse), zaman serisi hesaplamadan çıkarılır (Guerreo vd., 2005).

İlgili frekanslar [Delta (1-3 Hz), Teta (4-7 Hz), Alfa (8-12 Hz), Beta (13-25 Hz) ve Gama (26-40 Hz)] genelinde PSD tahmininin ortalaması alınarak güç bandı hesaplanarak değerler dB birimine dönüştürülmüştür. Tüm uyaran süresi boyunca PSD tahmininin ortalaması alınarak (ilgili güç bantları içinde ortalaması alındıktan sonra) ve ardından Desibel dB birimine dönüştürülen günlük kullanılarak her mevcut kanalın Ortalama Spektral Güç değerlerinin hesaplanması gerçekleştirilmiştir. Seçilen elektrot kümesi hesaplamasının, seçilen kanallar (Ch1, Ch2, Ch3, Ch4, Ch5, Ch6, Ch7, Ch8) boyunca PSD tahmininin (ilgili güç bantları içinde ortalaması alındıktan sonra) ortalaması alınarak seçilen elektrot kümesinin Ortalama Spektral Gücü değerleri daha sonra birime dönüştürülüp mevcut her kanal için 0 - 45 Hz frekans aralığında Spektral Güç çizilmiştir. Değerler Desibel (dB) birimindedir.

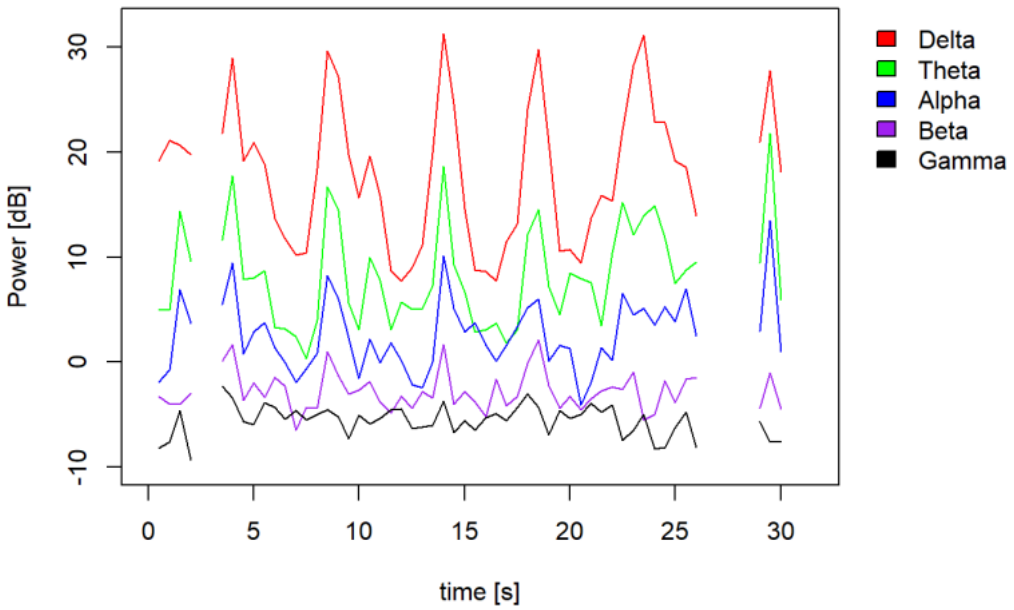


*Şekil 6.* EEG verisinin işlenmesi sonrasındaki dalga boyları grafiği

Şekil 6'daki grafik, EEG verilerinden elde edilen farklı frekans bantlarındaki güç spektral yoğunluklarının (PSD) zaman içerisindeki değişimini göstermektedir. Grafik, EEG sinyallerindeki Delta, Teta, Alpha, Beta ve Gama dalgalarının zaman içinde nasıl değiştiğini dB (desibel) cinsinden ifade ederek beynin farklı durumlarda nasıl tepki verdiğini incelemeye olanak tanımaktadır.

### 3.5. Veri Analizi

EEG verilerindeki örüntüleri belirlemek için genellikle makine öğrenme algoritmaları kullanılmaktadır (Bhatt vd., 2023). Bu çalışmada, EEG sinyalleri işlendikten sonra ham veri elde edilmiştir. Veri sistematik ve kontrollü bir ortamda toplandığından, sinyallerin ilgili bölümlerinden çıkarılan özellikler, soruya doğru cevap verip verilmemesine göre 1,0 olarak adlandırılan iki varsayılan kategoriye ayrılmıştır. Bu nedenle, bu çalışma için sınıflandırma yöntemleri geliştirmek için denetimli öğrenme yöntemi kullanılmıştır. Bu çalışmada beş farklı makine öğrenmesi algoritması uygulanmış olup bunlar Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağlarıdır. Bayes ağ öğrenmesi, bir olayın oluşumunda birden fazla faktör varsa, bu faktörler arasından en etkili olanını bulmaya yarayan bir öğrenme yöntemidir (Hackerman vd., 1995). Lojistik Regresyon, bağımlı değişkenin ikili olduğu durumlarda kullanılan ve bağımsız değişkenlerin etkisini değerlendiren bir istatistiksel yöntemdir (Hosmer vd., 2013). C5.0, karar ağaçlarının oluşturulmasında kullanılan ve doğruluk oranını artırmak için veri kümesini farklı alt

kümelere bölen bir algoritmadır (Quinlan, 1993). CHAID, veri madenciliği ve keşifsel veri analizi süreçlerinde değişkenler arasındaki ilişkileri belirlemek için ki-kare testi istatistiklerini kullanan bir sınıflandırma yöntemidir (Kass, 1980). Yapay Sinir Ağları ise, biyolojik sinir ağlarından esinlenerek geliştirilen ve öğrenme, sınıflandırma gibi görevlerde kullanılan bir modeldir (LeCun vd., 2015). Bu algoritmaların ortak özelliği, hepsinin sınıflandırma ve tahmin problemlerinde yüksek doğruluk ve genelleme yeteneği sunmalarıdır, bu yüzden bu araştırma için seçilmişlerdir. Bu çalışma, çeşitli makine öğrenmesi algoritmalarının etkinliğini ve kalite ölçümlerini karşılaştırmalı olarak incelemektedir. Çalışmada verilerin %80'i eğitim verisi ve %20'si test veri kullanılmıştır. Eğitim verisi toplam 20 katılımcı üzerinden gerçekleştirilmişken test verisi ise 5 katılımcı üzerinden gerçekleştirilmiştir. Analiz için kullanılan EEG sinyalleri katılımcılardan video izlerken elde edilen sinyallerle yapılmıştır. Video izleme sonrasında sorulan her iki madde için sırasıyla yukarıda ismi geçen makine öğrenmesi algoritmaları uygulanmıştır. Bu çalışma, eğitim ve test gruplarına ilişkin tanımlayıcı istatistikleri sunarak her iki grubun demografik ve psikofizyolojik profillerini karşılaştırmayı amaçlamaktadır. Tablo 2 ve 3'te tanımlayıcı istatistikler, grupların frekans ve yüzde dağılımlarının yanı sıra, dalga boyları değişkenlerinin ortalama ve standart sapma değerlerini içermektedir.

Tablo 2.
*Tanımlayıcı İstatistikler 1*

| | Frekans (n) | Yüzde (%) |
|---|---|---|
| Cinsiyet | | |
| Kadın | 21 | 84 |
| Erkek | 4 | 16 |
| Birinci Soru | | |
| 0 | 11 | 44 |
| 1 | 14 | 56 |
| İkinci Soru | | |
| 0 | 9 | 36 |
| 1 | 16 | 64 |

Tablo 2'de, değişkenlerin frekans ve yüzde dağılımı sunulmaktadır. Kadın katılımcıların sayısı 21 (%84) olup, erkek katılımcıların sayısı 4 (%16) olarak belirtilmiştir. Bu, çalışmaya katılanların büyük çoğunluğunun kadın olduğunu göstermektedir. Birinci soruya verilen

yanıtların dağılımı incelendiğinde, soruyu yanlış cevaplayanların sayısı 11 (%44), soruyu doğru yanıtlayanların sayısı ise 14 (%56) olarak gözlemlenmiştir. Bu durumda, katılımcıların çoğunluğunun soruyu doğru cevapladığı gözlenmiştir. İkinci soruya verilen yanıtların dağılımı ise "0" için 9 kişi (%36), "1" için 16 kişi (%64) olarak dağılım göstermektedir. Aynı şekilde, bu da ikinci soruya çoğunluğun doğru cevap verdiğini göstermektedir. Testin genel başarısını değerlendirmek adına güçlük indeksi de hesaplanmıştır. Hesaplanan değerler ışığında, hem Birinci Soru ($p$=0.56) hem de İkinci Soru ($p$=0.64) orta zorluk düzeyinde yer almaktadır. Bu durum, soruların katılımcıların büyük çoğunluğu tarafından anlaşılabilir olduğunu, ancak bir kısmının sorular üzerinde zorlandığını göstermektedir. Ayrıca her iki sorunun güçlük indekslerinin birbirine yakın olması, testin zorluk seviyesinin dengeli dağıldığını ortaya koymaktadır.

Genel olarak, bu tablo tanımlayıcı istatistiklerle çalışmanın katılımcı profili ve sorulara verilen yanıtların dağılımı hakkında bilgi vermektedir. Çalışmada kadın katılımcıların çoğunlukta olduğu ve birinci ile ikinci soruya büyük ölçüde doğru cevap verildiği gözlemlenmektedir.

Tablo 3.
*Tanımlayıcı İstatistikler 2*

| | Ortalama | S. sapma |
|---|---|---|
| Mean PSD Ch1 Delta (dB) | 20,14 | 1,52 |
| Mean PSD Ch1 Theta (dB) | 11,25 | 1,32 |
| Mean PSD Ch1 Alpha (dB) | 5,09 | 1,78 |
| Mean PSD Ch1 Beta (dB) | 0,49 | 3,58 |
| Mean PSD Ch1 Gama (dB) | -2,44 | 4,13 |
| Mean PSD Ch2 Delta (dB) | 17,42 | 2,19 |
| Mean PSD Ch2 Theta (dB) | 8,93 | 2,39 |
| Mean PSD Ch2 Alpha (dB) | 2,76 | 2,14 |
| Mean PSD Ch2 Beta (dB) | -0,58 | 3,18 |
| Mean PSD Ch2 Gama (dB) | -3,07 | 3,88 |
| Mean PSD Ch3 Delta (dB) | 17,11 | 1,96 |
| Mean PSD Ch3 Theta (dB) | 9,21 | 2,41 |
| Mean PSD Ch3 Alpha (dB) | 4,16 | 2,9 |
| Mean PSD Ch3 Beta (dB) | -0,72 | 2,64 |
| Mean PSD Ch3 Gama (dB) | -4,1 | 3,25 |
| Mean PSD Ch4 Delta (dB) | 15,19 | 3,04 |

| | | |
|---|---|---|
| Mean PSD Ch4 Theta (dB) | 7,61 | 3,09 |
| Mean PSD Ch4 Alpha (dB) | 3,01 | 3,16 |
| Mean PSD Ch4 Beta (dB) | -1,47 | 2,77 |
| Mean PSD Ch4 Gama (dB) | -4,89 | 3,33 |
| Mean PSD Ch5 Delta (dB) | 15,08 | 1,88 |
| Mean PSD Ch5 Theta (dB) | 7,66 | 2,07 |
| Mean PSD Ch5 Alpha (dB) | 5,21 | 3,26 |
| Mean PSD Ch5 Beta (dB) | -0,95 | 1,78 |
| Mean PSD Ch5 Gama (dB) | -4,71 | 2,13 |
| Mean PSD Ch6 Delta (dB) | 13,8 | 2,27 |
| Mean PSD Ch6 Theta (dB) | 6,67 | 2,53 |
| Mean PSD Ch6 Alpha (dB) | 3,99 | 3,62 |
| Mean PSD Ch6 Beta (dB) | -2,0 | 2,0 |
| Mean PSD Ch6 Gama (dB) | -5,55 | 2,46 |
| Mean PSD Ch7 Delta (dB) | 14,0 | 2,03 |
| Mean PSD Ch7 Theta (dB) | 6,98 | 2,14 |
| Mean PSD Ch7 Alpha (dB) | 5,02 | 3,07 |
| Mean PSD Ch7 Beta (dB) | -0,81 | 1,82 |
| Mean PSD Ch7 Gama (dB) | -4,78 | 2,12 |
| Mean PSD Ch8 Delta (dB) | 12,97 | 2,65 |
| Mean PSD Ch8 Theta (dB) | 5,91 | 2,45 |
| Mean PSD Ch8 Alpha (dB) | 3,69 | 3,53 |
| Mean PSD Ch8 Beta (dB) | -1,71 | 2,08 |
| Mean PSD Ch8 Gama (dB) | -5,21 | 2,4 |

Tablo3’te, farklı kanallardan elde edilen güç spektral yoğunluğu (PSD) değerlerinin ortalamalarını ve standart sapmalarını içermektedir. Bu değerler, beyin dalgalarının farklı frekans bantlarında (Delta, Theta, Alpha, Beta, Gama) nasıl dağıldığını gösterir. Her bir frekans bandı, beyindeki farklı aktivitelerle ilişkilidir. Tabloda görüldüğü üzere, Delta bandı tüm kanallarda pozitif değerlere sahiptir. En yüksek ortalama değerler Ch1 ve Ch3 kanallarında gözlemlenmiştir. Bu, bu kanalların daha fazla Delta aktivitesi içerdiğini gösterir. Teta bandı değerleri de tüm kanallarda pozitif olarak gözlemlenmiştir. Ch2 ve Ch3 kanallarında en yüksek ortalama değerlere sahiptir. Bu kanalların, Theta dalgalarının daha fazla temsil edildiği yerler olduğu söylenebilir. Alfa bandı değerleri genellikle pozitif olup, Ch6 ve Ch7 kanallarında en yüksek ortalamalarla temsil edilir. Bu durum, bu kanallarda

Alpha dalgalarının yoğun olduğunu gösterir. Beta bandı değerleri bazı kanallarda negatif, bazı kanallarda ise pozitif olarak gözlemlenmiştir. Negatif değerler, o bölgelerde daha düşük beta aktivitesini gösterir. Özellikle Ch4 ve Ch8 kanallarında negatif ortalamalar dikkat çekicidir. Gama bandı değerleri çoğunlukla negatif olup, bu durum bu frekans bandının diğerlerine kıyasla daha düşük bir güç spektral yoğunluğuna sahip olduğunu gösterir. Özellikle Ch7 ve Ch8 kanallarında oldukça düşük değerler gözlemlenmiştir. Tablo 3, farklı beyin bölgelerindeki dalga aktivitelerinin spektral yoğunluğunun kanal bazında nasıl farklılık gösterdiğini ortaya koymaktadır. Standart sapmaların geniş bir yelpazede değişim göstermesi, bu değerlerin bireyler arasında önemli farklılıklar gösterebileceğini işaret eder. Bu da, belirli bir frekans bandında her bireyin farklı bir spektral yoğunluk gösterebileceği anlamına gelir. Bu çeşitlilik, beyin dalgası aktivitelerinin kişiye özgü olduğunu ve bu tür analizlerde bireyler arası farkların göz önünde bulundurulması gerektiğini vurgular. Bu bulgular, çalışmanın ilerleyen aşamalarında yapılacak daha derinlemesine analizler için bir temel oluşturmakta olup, gruplar arasındaki farkların potansiyel nedenlerini araştırmak için yol gösterici niteliktedir. Analizlerin devamında, bu değişkenlerin birbirleriyle olan ilişkileri ve olası etkileri detaylı bir şekilde incelenecektir

# BÖLÜM IV

# BULGULAR

Araştırmanın amacı ve alt problemleri doğrultusunda elde edilen bulgular bu bölümde verilmiştir. EEG sinyallerinden elde edilen veriler alt problemler ve yöntemler doğrultusunda ayrı ayrı incelenmiş ve model performansları karşılaştırılmıştır.

## 4.1. Öğrencilerin Birinci Soruya Verdikleri Cevapları Belirlemede Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları Yöntemlerinin Sınıflandırma Performansları Ne Düzeydedir?

Bu araştırma sorusu, öğrencilerin birinci soruya verdikleri yanıtları doğru bir şekilde tahmin etmek için kullanılan farklı sınıflandırma algoritmalarının performanslarını karşılaştırmayı amaçlamaktadır. Bu sayede hangi algoritmanın en yüksek doğruluğu sağladığı ve belirli durumlarda en etkili yöntem olduğu belirlenebilecektir.

### 4.1.1. Bayes Sınıflandırma Algoritmasına İlişkin Bulgular

Bayes Sınıflandırma Algoritmasına göre öğrencilerin birinci soruya verdikleri cevapların sınıflandırılmasıyla ilişkili değişkenlerin önem düzeylerine göre sıralaması ve başarım istatistikleri nasıldır?

Bayes sınıflandırma algoritmasında birinci soruya ait en önemli parametrelerin önem dereceleri Tablo 4'te sunulmuştur.

Tablo 4.
*Birinci Soru İçin Oluşturulmuş Bayes sınıflandırma Algoritmasına Ait Parametrelerin Önem Dereceleri*

| Parametreler | Önem (%) |
|---|---|
| Mean PSD Ch6 Beta (dB) | 12,50 |
| Mean PSD Ch6 Alpha (dB) | 7,50 |
| Mean PSD Ch6 Gama (dB) | 6,25 |
| Mean PSD Ch2 Beta (dB) | 5,00 |
| Mean PSD Ch6 Theta (dB) | 3,75 |
| Mean PSD Ch4 Theta (dB) | 3,75 |
| Mean PSD Ch3 Theta (dB) | 1,25 |

En yüksek önem derecesine sahip parametre, %12,50 ile Mean PSD Ch6 Beta (dB) olarak belirlenmiştir. Bu, Ch6 kanalından elde edilen beta dalgalarının modelin doğruluğu üzerinde büyük bir etkiye sahip olduğunu göstermektedir. İkinci en önemli parametre, %7,50 ile Mean PSD Ch6 Alpha (dB)'dir. Alpha dalgaları, genellikle uyanıklık ve dinlenme ile ilişkilidir ve bu parametrenin yüksek önem derecesi, modelin bilişsel durumları tanımlamada etkili olduğunu ortaya koymaktadır. Üçüncü sırada %6,25 ile Mean PSD Ch6 Gama (dB) bulunmaktadır. Gama dalgalarının, genellikle yüksek düzeyde bilişsel fonksiyonlarla ilişkilendirildiği ve bu parametrenin modelin performansı üzerinde önemli bir rol oynadığı anlaşılmaktadır. Dördüncü sırada ise %5,00 ile Mean PSD Ch2 Beta (dB) yer almaktadır. Bu, beta dalgalarının başka bir kanaldan (Ch2) elde edilen verileriyle modelin doğruluğuna önemli katkılar sağladığını göstermektedir. Beşinci sırada %3,75 ile Mean PSD Ch6 Theta (dB) ve Mean PSD Ch4 Theta (dB) bulunmaktadır. Theta dalgaları, genellikle hafif uyku veya meditasyon durumları ile ilişkilidir ve bu parametrelerin önemi, modelin bu tür durumları tanımlamada etkili olduğunu göstermektedir. Altıncı sırada %1,25 ile Mean PSD Ch3 Theta (dB) yer almakta olup, bu parametrenin düşük ancak anlamlı bir etkisi olduğunu göstermektedir. Sonuç olarak, analizde en iyi performansı gösteren parametre, Mean PSD Ch6 Beta (dB) olmuştur. Bu, Ch6 kanalındaki beta dalgalarının modelin doğruluğunu optimize etmede en kritik rolü oynadığını ortaya koymaktadır.

Bayes Sınıflandırma Algoritması modelinin performansını değerlendirmek amacıyla oluşturulan Karışıklık matrisi Tablo 5'te sunulmuştur. Bu matriste, modelin doğru ve yanlış tahminleri test ve eğitim verisi için detaylı bir şekilde yer almaktadır.

Tablo 5.
*Birinci Soru İçin Oluşturulmuş Bayes sınıflandırma Algoritmasına Ait Karışıklık Matrisi*

| | | Tahmini | | TP | TN | FP | FN |
|---|---|---|---|---|---|---|---|
| | Gerçek | 0 | 1 | | | | |
| Test | 0 | 3 | 0 | 2 | 3 | 0 | 0 |
| | 1 | 0 | 2 | | | | |
| Eğitim | 0 | 10 | 3 | 7 | 10 | 0 | 3 |
| | 1 | 0 | 7 | | | | |

Elde edilen sonuçlar modelin test verisinde oldukça iyi performans gösterdiğini göstermektedir. Model, test verisinde tüm pozitif ve negatif örnekleri doğru bir şekilde sınıflandırmaktadır. Eğitim verisinde ise, model çoğunlukla doğru sınıflandırmalar yapmıştır. Yalnızca 3 yanlış negatif tahmin bulunmaktadır bu da modelin bazı pozitif sınıfları negatif olarak tahmin ettiğini göstermektedir. Bunun yanında, hiçbir yanlış pozitif tahmin yapmamıştır ve negatif sınıfların tümünü doğru tahmin etmiştir. Sonuç olarak, Bayes Sınıflandırma Algoritması modelinin hedef değişkeni başarıyla tahmin edebileceğini, özellikle negatif sınıfları doğru bir şekilde ayırt edebildiğini göstermektedir.

Bayes Sınıflandırma Algoritması modelinin performansını değerlendirmek amacıyla oluşturulan başarım istatistikleri Tablo 6'da sunulmuştur. Modelin performansı hem eğitim hem de test verisi üzerinde değerlendirilmiştir.

Tablo 6.
*Birinci Soru İçin Oluşturulmuş Bayes Sınıflandırma Algoritmasına Ait Başarım İstatistikleri*

| | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1 puanı(%) | PPV(%) | NPV(%) | AUC(%) |
|---|---|---|---|---|---|---|---|
| Test | 100,0 | 100,0 | 100,0 | 100,0 | 100,0 | 100,0 | 1,000 |
| Eğitim | 85,0 | 70,0 | 100,0 | 82,4 | 100,0 | 76,9 | 0,900 |

Elde edilen sonuçlara göre, test verisinde model, Doğruluk oranı %100 olarak belirlenmiştir. Bu sonuç, modelin test verisinde hiçbir hatalı tahmin yapmadığını ve hem pozitif hem de negatif sınıfları mükemmel bir şekilde ayırt ettiğini göstermektedir. Duyarlılık ve Özgüllük değerleri de %100 olarak tespit edilmiştir, bu da modelin hem gerçek pozitif hem de gerçek

negatif örnekleri doğru bir şekilde sınıflandırdığını ifade etmektedir. Modelin F1 puanı %100, pozitif kestirim değeri ve negatif kestirim değeri %100 olarak bulunmuştur. Son olarak, AUC değeri 1.00 olarak hesaplanmış ve modelin pozitif ve negatif sınıfları ayırt etme yeteneğinin mükemmel olduğu kanıtlanmıştır. Eğitim verisi üzerinde yapılan değerlendirmede ise, modelin Doğruluk oranı %85,0 olarak belirlenmiştir, bu da modelin bazı hatalı tahminler yaptığını göstermektedir. Duyarlılık %70,0 olarak tespit edilmiş, yani modelin pozitif örneklerin %30'unu yanlış negatif olarak sınıflandırdığı anlaşılmıştır. Buna karşın, Özgüllük değeri %100 olarak bulunmuş ve modelin negatif sınıfları doğru bir şekilde tanımladığı gözlemlenmiştir. Modelin eğitim verisi üzerindeki F1 puanı %82,4 olarak hesaplanmış, bu da genel performansın yüksek olduğunu, ancak test verisi kadar iyi olmadığını ortaya koymuştur. Pozitif kestirim değeri %100 olarak belirlenmiş, ancak negatif kestirim değeri %76,9 olarak hesaplanmıştır, bu da modelin negatif tahminlerinde bazı hatalar yaptığını göstermektedir. AUC değeri ise 0,90 olarak bulunmuş, bu da modelin pozitif ve negatif sınıfları ayırt etme yeteneğinin test verisine kıyasla daha düşük olduğunu işaret etmektedir. Genel olarak, Bayes Sınıflandırma Algoritması modeli test verisinde mükemmel bir performans sergilemiş, ancak eğitim verisinde bazı iyileştirmeler gerektiren sonuçlar ortaya koymuştur.

### 4.1.2. Lojistik Regresyon Yöntemine İlişkin Bulgular

Lojistik Regresyon yöntemine göre öğrencilerin birinci soruya verdikleri cevapların sınıflandırılmasıyla ilişkili değişkenlerin önem düzeylerine göre sıralaması ve başarım istatistikleri nasıldır?

Birinci soru için oluşturulan Lojistik Regresyon yöntemine ait modelde en önemli olan 10 parametrenin önem dereceleri Tablo 7'de sunulmuştur.

Tablo 7.
*Birinci Soru İçin Oluşturulmuş Lojistik Regresyon Yöntemine Ait Parametrelerin Önem Dereceleri*

| Parametreler | Önem Yüzdesi(%) |
|---|---|
| Mean PSD Ch8 Gama (dB) | 8,29 |
| Mean PSD Ch6 Teta (dB) | 7,04 |
| Mean PSD Ch6 Gama (dB) | 6,15 |
| Mean PSD Ch6 Alfa (dB) | 4,31 |
| Mean PSD Ch7 Gama (dB) | 4,09 |
| Mean PSD Ch8 Teta (dB) | 3,67 |
| Mean PSD Ch4 Gama (dB) | 3,46 |
| Mean PSD Ch6 Beta (dB) | 3,27 |
| Mean PSD Ch1 Alfa (dB) | 3,21 |
| Mean PSD Ch8 Delta (dB) | 3,14 |

Tablo 7'ye göre, en yüksek önem derecesine sahip parametre, %8,29 ile Mean PSD Ch8 Gama (dB) olarak bulunmuştur. Bu parametreyi %7,04 ile Mean PSD Ch6 Teta (dB) takip etmektedir. Üçüncü sırada %6,15 ile Mean PSD Ch6 Gama (dB) yer almaktadır. Dördüncü sırada %4,31 ile Mean PSD Ch6 Alfa (dB) bulunurken, beşinci sırada %4,09 ile Mean PSD Ch7 Gama (dB) gelmektedir. Altıncı sırada %3,67 ile Mean PSD Ch8 Teta (dB) yer almakta olup, yedinci sırada %3,46 önem derecesiyle Mean PSD Ch4 Gama (dB) ve sekizinci sırada %3,27 ile Mean PSD Ch6 Beta (dB) bulunmaktadır. Dokuzuncu sırada %3,21 ile Mean PSD Ch1 Alfa (dB) yer alırken, onuncu sırada %3,14 ile Mean PSD Ch8 Delta (dB) bulunmaktadır. Bu bulgular, lojistik regresyon modelinde Gama ve Teta dalgalarının özellikle önemli olduğunu ve bu frekans bantlarındaki güç spektral yoğunluğu (PSD) ölçümlerinin modelin performansı üzerinde belirgin bir etkiye sahip olduğunu ortaya koymaktadır.

Lojistik Regresyon modelinin performansını değerlendirmek amacıyla oluşturulan Karışıklık matrisi Tablo 8'de sunulmuştur.

Tablo 8.
*Birinci Soru İçin Oluşturulmuş Lojistik Regresyon Yöntemine Ait Karışıklık Matrisi*

| | | Tahmini | | TP | TN | FP | FN |
|---|---|---|---|---|---|---|---|
| | Gerçek | 0 | 1 | | | | |
| Test | 0 | 1 | 0 | 2 | 1 | 0 | 2 |
| | 1 | 2 | 2 | | | | |
| Eğitim | 0 | 10 | 0 | 10 | 10 | 0 | 0 |
| | 1 | 0 | 10 | | | | |

Tablo 8 incelendiğinde, test verisi için elde edilen karışıklık matrisinde, modelin 2 pozitif sınıfı doğru sınıflandırdığını, ancak 2 negatif örneği yanlış bir şekilde pozitif olarak tahmin ettiğini ortaya koymaktadır. Test verisinde model, yalnızca 1 negatif sınıfı doğru tanımlayabilmiş ve bu da modelin negatif sınıfları ayırt etmede zorluk çektiğini göstermektedir. Eğitim verisinde ise karışıklık matrisi incelendiğinde, model tüm örnekleri doğru bir şekilde sınıflandırarak 10 pozitif ve 10 negatif sınıfı tamamen doğru tahmin etmiştir. Bu durum, modelin eğitim verisi üzerinde mükemmel bir performans sergilediğini göstermektedir. Model, eğitim verisi üzerinde oldukça başarılı bir performans sergilemiş olmasına karşın, test verisi üzerinde daha zayıf bir performans göstermiştir. Eğitim verisinde herhangi bir hata yapmayan model, test verisinde ise yanlış pozitif tahminlerde bulunmuş ve negatif sınıfları doğru bir şekilde ayırt etmede zorlanmıştır.

Lojistik Regresyon modelinin performansını değerlendirmek amacıyla oluşturulan başarım istatistikleri Tablo 9'da sunulmuştur.

Tablo 9.
*Birinci Soru İçin Oluşturulmuş Lojistik Regresyon Yöntemine Ait Başarım İstatistikleri*

| | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1 puanı(%) | PPV(%) | NPV(%) | AUC(%) |
|---|---|---|---|---|---|---|---|
| Test | 60,0 | 50,0 | 100,0 | 66,7 | 100,0 | 33,3 | 1,000 |
| Eğitim | 100,0 | 100,0 | 100,0 | 100,0 | 100,0 | 100,0 | 1,000 |

Tablo 9'da sunulan başarım istatistiklerine göre, lojistik regresyon modelinin eğitim verisi üzerinde mükemmel bir performans sergilediği görülmektedir. Eğitim verisinde model, %100 doğruluk, %100 duyarlılık, %100 özgüllük, %100 F1 puanı, %100 PPV ve %100 NPV ile birlikte AUC değeri olarak da 1,000 elde etmiştir. Bu sonuçlar, modelin eğitim verisi

üzerinde tüm sınıflandırma görevlerini hatasız bir şekilde yerine getirdiğini göstermektedir. Ancak, modelin test verisinde daha düşük bir performans sergilediği dikkat çekmektedir. Test verisinde doğruluk %60,0, duyarlılık %50,0, F1 puanı %66,7, ve NPV %33,3 olarak hesaplanmıştır. Bu sonuçlar, modelin test verisinde negatif sınıfları ayırt etmede zorluk yaşadığını ve genelleme yeteneğinin sınırlı olabileceğini ortaya koymaktadır. Özgüllük ve PPV değerlerinin %100,0 ve AUC değerinin 1,000 olması, modelin pozitif sınıfları doğru şekilde ayırt edebildiğini göstermektedir, ancak bu yeterli olmamış ve genel performansı düşürmüştür. Bu sonuçlar, modelin test verisi üzerinde iyileştirilmesi gerektiğini ve gerçek dünya verilerinde daha iyi performans gösterebilmesi için daha fazla düzenlemeye ihtiyaç duyduğunu işaret etmektedir.

### 4.1.3. C5.0 Yöntemine İlişkin Bulgular

C5.0 yöntemine göre öğrencilerin birinci soruya verdikleri cevapların sınıflandırılmasıyla ilişkili değişkenlerin önem düzeylerine göre sıralaması ve başarım istatistikleri nasıldır?

Birinci soru için oluşturulan C5.0 yöntemine ait modelde en önemli olan parametrelerin önem dereceleri Tablo 10'da sunulmuştur.

Tablo 10.
*Birinci Soru İçin Oluşturulmuş C5.0 Yöntemine Ait Parametrelerin Önem Dereceleri*

| Parametreler | Önem(%) |
|---|---|
| Mean PSD Ch8 Gama (dB) | 56,0 |
| Mean PSD Ch7 Beta (dB) | 31,8 |
| Mean PSD Ch3 Gama (dB) | 12,0 |

Tablo 10 incelendiğinde, en yüksek önem derecesine sahip parametre, %56,0 ile Mean PSD Ch8 Gama (dB) olarak belirlenmiştir. Bu, Ch8 kanalından elde edilen Gama dalgalarının modelin doğruluğu üzerinde büyük bir etkiye sahip olduğunu göstermektedir. İkinci en önemli parametre, %31,8 ile Mean PSD Ch7 Beta (dB)'dir. Beta dalgaları, genellikle uyanıklık ve aktif düşünme ile ilişkilidir ve bu parametrenin yüksek önem derecesi, modelin bilişsel durumları tanımlamada etkili olduğunu ortaya koymaktadır. Üçüncü sırada %12,0 ile Mean PSD Ch3 Gama (dB) bulunmaktadır. Gama dalgalarının, genellikle yüksek düzeyde bilişsel fonksiyonlarla ilişkilendirildiği ve bu parametrenin modelin performansı üzerinde önemli bir rol oynadığı anlaşılmaktadır. Sonuç olarak, bu analizde en iyi performansı gösteren parametre, Mean PSD Ch8 Gama (dB) olmuştur. Bu, Ch8 kanalındaki Gama dalgalarının modelin doğruluğunu optimize etmede en kritik rolü oynadığını ortaya koymaktadır.

C5.0 modelinin performansını değerlendirmek amacıyla oluşturulan Karışıklık matrisi Tablo 11'de sunulmuştur.

Tablo 11.
*Birinci Soru İçin Oluşturulmuş C5.0 Yöntemine Ait Karışıklık Matrisi*

| | | Tahmini | | TP | TN | FP | FN |
|---|---|---|---|---|---|---|---|
| | Gerçek | 0 | 1 | | | | |
| Test | 0 | 1 | 2 | 2 | 1 | 2 | 0 |
| | 1 | 0 | 2 | | | | |
| Eğitim | 0 | 10 | 0 | 10 | 10 | 0 | 0 |
| | 1 | 0 | 10 | | | | |

Tablo 11 incelendiğinde, test verisi üzerinde model, pozitif sınıfa ait iki örneğin tamamını doğru bir şekilde sınıflandırmış, ancak negatif sınıfa ait iki örneği yanlış bir şekilde pozitif olarak tahmin etmiştir. Buna karşılık, negatif sınıfa ait bir örnek doğru bir şekilde negatif olarak sınıflandırılmıştır. Bu durum, modelin negatif sınıfları ayırt etmede bazı zorluklar yaşadığını göstermektedir. Eğitim verisi üzerinde ise model, tüm pozitif ve negatif sınıfları doğru bir şekilde sınıflandırmış ve hiçbir hata yapmamıştır. Bu sonuçlar, modelin eğitim verisi üzerinde mükemmel bir performans sergilediğini ancak test verisi üzerinde bazı sınıflandırma hataları yaptığını ortaya koymaktadır. Bu durum, modelin eğitim verisine çok iyi uyum sağladığını ancak yeni verilere genel uygulanabilirlikte sorun yaşayabileceğini düşündürmektedir.

C5.0 modelinin performansını değerlendirmek amacıyla oluşturulan başarım istatistikleri Tablo 12'de sunulmuştur.

Tablo 12.
*Birinci Soru İçin Oluşturulmuş C5.0 Yöntemine Ait Başarım İstatistikleri*

| | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1 puanı(%) | PPV(%) | NPV(%) | AUC(%) |
|---|---|---|---|---|---|---|---|
| Test | 60,0 | 100,0 | 33,3 | 66,7 | 50,0 | 100,0 | 0,667 |
| Eğitim | 100,0 | 100,0 | 100,0 | 100,0 | 100,0 | 100,0 | 1,000 |

C5.0 algoritması modelinin hem eğitim hem de test verisi üzerindeki performansı arasında belirgin farklar bulunmaktadır. Eğitim verisi üzerinde model, %100 doğruluk oranı ile mükemmel bir performans sergilemiştir. Model, tüm pozitif ve negatif sınıfları doğru bir şekilde sınıflandırmış, hiçbir yanlış pozitif veya yanlış negatif tahmin yapmamıştır. Bu da

modelin eğitim verisi üzerinde tam uyum sağladığını ve herhangi bir hatalı tahmin yapmadığını göstermektedir. Duyarlılık, özgüllük, F1 skoru, pozitif kestirim değeri (PPV), negatif kestirim değeri (NPV) ve AUC değerleri %100.0 olarak hesaplanmıştır. Buna karşılık, modelin test verisi üzerindeki performansı, eğitim verisine göre daha düşük kalmıştır. Test verisinde modelin doğruluk oranı %60.0 olarak belirlenmiş ve bu oran modelin bazı sınıflandırma hataları yaptığını göstermiştir. Model, pozitif sınıfları tanımlamada başarılı olmuş (%100.0 duyarlılık), ancak negatif sınıfları tanımlamada (%33.3 özgüllük) zorluklar yaşamıştır. Test verisi üzerindeki F1 skoru %66.7, pozitif kestirim değeri %50.0 ve negatif kestirim değeri %100.0 olarak belirlenmiştir. AUC değeri ise 0.667 olarak hesaplanmış, bu da modelin pozitif ve negatif sınıfları ayırt etme yeteneğinin orta düzeyde olduğunu göstermektedir. Bu sonuçlar, C5.0 algoritmasının eğitim verisi üzerinde mükemmel bir performans sergilediğini, ancak test verisi üzerinde bu performansı sürdüremediğini göstermektedir. Eğitim verisi üzerinde model tüm sınıfları doğru bir şekilde sınıflandırırken, test verisi üzerinde negatif sınıfları ayırt etmede zorluk yaşamış ve bazı hatalar yapmıştır. Bu durum, modelin eğitim verisine aşırı uyum sağladığını (overfitting) ve test verisi üzerinde genelleme yeteneğinin sınırlı olabileceğini işaret etmektedir. Modelin özellikle negatif sınıfları daha iyi tanımlayabilmesi için iyileştirilmesi gerekmektedir.

### 4.1.4. CHAID Yöntemine İlişkin Bulgular

CHAID yöntemine göre öğrencilerin birinci soruya verdikleri cevapların sınıflandırılmasıyla ilişkili değişkenlerin önem düzeylerine göre sıralaması ve başarım istatistikleri nasıldır?

Birinci soru için oluşturulan CHAID yöntemine ait modelde en önemli olan parametrelerin önem dereceleri Tablo 13'de sunulmuştur.

Tablo 13.
*Birinci Soru İçin Oluşturulmuş CHAID Yöntemine Ait Parametrelerin Önem Dereceleri*

| Parametreler | Önem(%) |
|---|---|
| Mean PSD Ch8 Gama (dB) | 53,8 |
| Mean PSD Ch7 Beta (dB) | 33,9 |
| Mean PSD Ch3 Gama (dB) | 12,1 |

Tablo 13'e göre, en yüksek önem derecesine sahip parametre, %53,8 ile Mean PSD Ch8 Gama (dB) olarak belirlenmiştir. Bu, Ch8 kanalından elde edilen Gama dalgalarının modelin doğruluğu üzerinde büyük bir etkiye sahip olduğunu göstermektedir. İkinci en önemli

parametre, %33,9 ile Mean PSD Ch7 Beta (dB)'dir. Beta dalgaları, genellikle uyanıklık ve aktif düşünme ile ilişkilidir ve bu parametrenin yüksek önem derecesi, modelin bilişsel durumları tanımlamada etkili olduğunu ortaya koymaktadır. Üçüncü sırada %12,1 ile Mean PSD Ch3 Gama (dB) bulunmaktadır. Gama dalgalarının, genellikle yüksek düzeyde bilişsel fonksiyonlarla ilişkilendirildiği ve bu parametrenin modelin performansı üzerinde önemli bir rol oynadığı anlaşılmaktadır. Sonuç olarak, bu analizde en iyi performansı gösteren parametre, Mean PSD Ch8 Gama (dB) olmuştur. Bu, Ch8 kanalındaki Gama dalgalarının modelin doğruluğunu optimize etmede en kritik rolü oynadığını ortaya koymaktadır.

CHAID karar ağacı modelinin performansını değerlendirmek amacıyla oluşturulan Karışıklık matrisi Tablo 14'te sunulmuştur.

Tablo 14.
*Birinci Soru İçin Oluşturulmuş CHAID Yöntemine Ait Karışıklık Matrisi*

| | | Tahmini | | TP | TN | FP | FN |
|---|---|---|---|---|---|---|---|
| | Gerçek | 0 | 1 | | | | |
| Test | 0 | 0 | 1 | 3 | 0 | 1 | 1 |
| | 1 | 1 | 3 | | | | |
| Eğitim | 0 | 10 | 0 | 10 | 10 | 0 | 0 |
| | 1 | 0 | 10 | | | | |

Tablo 14 incelenerek, CHAID karar ağacı algoritması ile oluşturulan karışıklık matrisinin test ve eğitim verisi üzerindeki performansı değerlendirilmiştir. Test verisinde model, pozitif sınıfa ait 3 örneğin yalnızca 1'ini doğru sınıflandırmış, 2 negatif örneği ise yanlış bir şekilde pozitif olarak tahmin etmiştir. Buna karşılık, 1 negatif sınıf doğru bir şekilde tahmin edilmiştir. Bu durum, modelin pozitif sınıfları belirlemede bir miktar başarı sağladığını, ancak negatif sınıfları ayırt etmede zorlandığını göstermektedir. Eğitim verisine bakıldığında ise modelin tüm örnekleri doğru bir şekilde sınıflandırdığı ve 10 pozitif ile 10 negatif sınıfın tamamını doğru tahmin ettiği görülmektedir. Bu sonuç, modelin eğitim verisi üzerinde mükemmel bir performans sergilediğini ortaya koymaktadır. Ancak, eğitim verisinde hata yapmayan modelin test verisi üzerindeki performansındaki düşüş, modelin aşırı öğrenme (overfitting) yapmış olabileceğini ve bu nedenle yeni verilere genel uygulanabilirlikte sorun yaşayabileceğini düşündürmektedir.

CHAID yönteminin performansını değerlendirmek amacıyla birinci soru için oluşturulan başarım istatistikleri Tablo 15'te sunulmuştur

Tablo 15.
*Birinci Soru İçin Oluşturulmuş CHAID Yöntemine Ait Başarım İstatistikleri*

| | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1 puanı(%) | PPV(%) | NPV(%) | AUC(%) |
|---|---|---|---|---|---|---|---|
| Test | 60,0 | 75,0 | 0,0 | 75,0 | 75,0 | 0,0 | 0,375 |
| Eğitim | 100,0 | 100,0 | 100,0 | 100,0 | 100,0 | 100,0 | 1,000 |

Tablo 15'e göre, CHAID modeli, eğitim verisi üzerinde %100 doğruluk oranı ile mükemmel bir performans sergilemiştir. Model, tüm pozitif ve negatif sınıfları doğru bir şekilde sınıflandırmış, hiçbir yanlış pozitif veya yanlış negatif tahmin yapmamıştır. Eğitim verisinde duyarlılık, özgüllük, F1 skoru, pozitif kestirim değeri (PPV), negatif kestirim değeri (NPV) ve AUC değerlerinin hepsi %100.0 olarak hesaplanmıştır, bu da modelin eğitim verisine tam olarak uyum sağladığını göstermektedir. Ancak, test verisi üzerindeki performans, eğitim verisine göre oldukça düşüktür. Modelin doğruluk oranı %60.0, duyarlılık %75.0 ve özgüllük %0.0 olarak belirlenmiştir. Bu, modelin negatif sınıfları ayırt etmede yetersiz olduğunu göstermektedir. F1 skoru ve pozitif kestirim değeri %75.0 olarak bulunmuş, ancak negatif kestirim değeri %0.0 olarak hesaplanmıştır. AUC değeri ise %37.5 olarak belirlenmiştir, bu da modelin pozitif ve negatif sınıfları ayırt etme yeteneğinin düşük olduğunu göstermektedir. Bu sonuçlar, CHAID modelinin eğitim verisi üzerinde mükemmel bir performans sergilediğini ancak test verisi üzerinde bu performansı sürdüremediğini göstermektedir. Model, eğitim verisine aşırı uyum sağlamış olabilir (overfitting), bu da test verisinde genelleme yeteneğinin düşük olmasına neden olmuştur. Modelin özellikle negatif sınıfları daha iyi tanımlayabilmesi için iyileştirilmesi gerekmektedir.

### 4.1.5. Yapay Sinir Ağları Yöntemine İlişkin Bulgular

Yapay Sinir Ağları yöntemine göre öğrencilerin birinci soruya verdikleri cevapların sınıflandırılmasıyla ilişkili değişkenlerin önem düzeylerine göre sıralaması ve başarım istatistikleri nasıldır?

Birinci soru için oluşturulan Yapay Sinir ağları yöntemine ait modelde en önemli olan parametrelerin önem dereceleri Tablo 16'da sunulmuştur

Tablo 16.
*Birinci Soru İçin Oluşturulmuş Yapay Sinir Ağları Yöntemine Ait Parametrelerin Önem Dereceleri*

| Parametreler | Önem (%) |
|---|---|
| Mean PSD Ch7 Delta (dB) | 5,57 |
| Mean PSD Ch7 Teta (dB) | 5,20 |
| Mean PSD Ch8 Delta (dB) | 4,18 |
| Mean PSD Ch4 Delta (dB) | 3,94 |
| Mean PSD Ch7 Alpha (dB) | 3,67 |
| Mean PSD Ch3 Teta (dB) | 3,52 |
| Mean PSD Ch5 Alpha (dB) | 3,36 |
| Mean PSD Ch5 Teta (dB) | 3,36 |
| Mean PSD Ch5 Beta (dB) | 3,30 |
| Mean PSD Ch4 Teta (dB) | 3,23 |

Tablo 16 incelendiğinde, en yüksek önem derecesine sahip parametre, %5.57 ile Mean PSD Ch7 Delta (dB) olarak bulunmuştur. Bu parametreyi %5.20 ile Mean PSD Ch7 Teta (dB) takip etmektedir. Üçüncü sırada %4.18 ile Mean PSD Ch8 Delta (dB) yer almaktadır. Dördüncü sırada %3.94 ile Mean PSD Ch4 Delta (dB) bulunurken, beşinci sırada %3.67 ile Mean PSD Ch7 Alpha (dB) gelmektedir. Altıncı sırada %3.52 ile Mean PSD Ch3 Teta (dB) yer almakta olup, yedinci sırada %3.36 önem derecesiyle Mean PSD Ch5 Alpha (dB) ve sekizinci sırada yine %3.36 ile Mean PSD Ch5 Teta (dB) bulunmaktadır. Dokuzuncu sırada %3.30 ile Mean PSD Ch5 Beta (dB) yer alırken, onuncu ve son sırada %3.23 ile Mean PSD Ch4 Teta (dB) bulunmaktadır. Bu bulgular, Yapay Sinir Ağları yönteminde Delta ve Teta dalgalarının özellikle önemli olduğunu ve bu frekans bantlarındaki güç spektral yoğunluğu (PSD) ölçümlerinin modelin performansı üzerinde belirgin bir etkiye sahip olduğunu ortaya koymaktadır. Bu parametrelerin dikkate alınması, modelin geliştirilmesi ve optimize edilmesi açısından kritik öneme sahiptir.

Yapay Sinir Ağları modelinin performansını değerlendirmek amacıyla oluşturulan Karışıklık matrisi Tablo 17'de sunulmuştur.

Tablo 17.
*Birinci Soru İçin Oluşturulmuş Yapay Sinir Ağları Yöntemine Ait Karışıklık Matrisi*

| | | Tahmini | | TP | TN | FP | FN |
|---|---|---|---|---|---|---|---|
| | Gerçek | 0 | 1 | | | | |
| Test | 0 | 2 | 1 | 2 | 2 | 1 | 0 |
| | 1 | 0 | 2 | | | | |
| Eğitim | 0 | 0 | 10 | 10 | 0 | 10 | 0 |
| | 1 | 0 | 10 | | | | |

Tablo 17'ye göre, eğitim verisi üzerinde modelin negatif sınıfları ayırt etme yeteneği tamamen yetersizdir, çünkü tüm negatif sınıfları pozitif olarak tahmin etmektedir. Test verisi üzerinde ise model daha dengeli bir performans sergilemektedir. Hem pozitif hem de negatif sınıfları ayırt edebilmekte, ancak yine de bazı hatalar yapmaktadır. Bu tür bir model, özellikle gerçek dünya uygulamalarında negatif sınıfların doğru bir şekilde tanımlanmasının kritik olduğu durumlarda risk taşıyabilir. Modelin daha iyi genelleme yapabilmesi ve negatif sınıfları daha doğru bir şekilde tanımlayabilmesi için iyileştirilmesi gerekmektedir.

Yapay Sinir Ağları algoritmasının performansını değerlendirmek amacıyla oluşturulan başarım istatistikleri Tablo 18'de sunulmuştur

Tablo 18.
*Birinci Soru İçin Oluşturulmuş Yapay Sinir Ağları Yöntemine Ait Başarım İstatistikleri*

| | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1 puanı(%) | PPV(%) | NPV(%) | AUC(%) |
|---|---|---|---|---|---|---|---|
| Test | 80,0 | 100,0 | 66,7 | 80,0 | 66,7 | 100,0 | 0,500 |
| Eğitim | 50,0 | 100,0 | 0,0 | 66,7 | 50,0 | 0,0 | 0,500 |

Tablo 18'deki Yapay Sinir Ağları modelinin hem eğitim hem de test verisi üzerindeki performansını incelediğimizde, eğitim verisi üzerinde modelin doğruluk oranı %50,0 olarak hesaplanmıştır, bu da modelin eğitim verisi üzerinde sadece yarı yarıya doğru tahminler yaptığını göstermektedir. Modelin duyarlılığı %100 olup, tüm pozitif örnekleri doğru bir şekilde tanımladığı görülmektedir. Ancak, özgüllük değeri %0,0 olarak belirlenmiş ve bu durum, modelin negatif sınıfları ayırt etmede tamamen yetersiz olduğunu göstermektedir. F1 puanı %66,7 olarak hesaplanmış olup, modelin pozitif sınıfları tanımlama performansını

özetlemekte, ancak özgüllükteki yetersizlik nedeniyle mükemmel olmaktan uzaktır. Pozitif kestirim değeri %50,0 olarak belirlenmiş ve modelin pozitif tahminlerinin yalnızca yarısının doğru olduğunu göstermektedir. Negatif kestirim değeri %0,0 olarak hesaplanmış olup, modelin negatif tahminlerinin hiçbirinin doğru olmadığını göstermektedir. AUC değeri ise 0,50 olarak hesaplanmış ve modelin pozitif ve negatif sınıfları ayırt etme yeteneğinin tamamen rastgele olduğunu işaret etmektedir. Test verisi üzerinde ise modelin doğruluk oranı %80,0 olarak hesaplanmıştır ve bu, modelin test verisi üzerinde çoğunlukla doğru tahminler yaptığını göstermektedir. Modelin duyarlılığı %100 olarak belirlenmiş olup, test verisindeki tüm pozitif sınıfları doğru bir şekilde tanımladığı görülmektedir. Özgüllük değeri %66,7 olarak hesaplanmış ve modelin negatif sınıfları ayırt etmede eğitim verisine göre daha başarılı olduğunu göstermektedir. F1 puanı %80,0 olarak belirlenmiş ve modelin test verisi üzerinde pozitif sınıfları tanımlamada dengeli bir performans sergilediği görülmektedir. Pozitif kestirim değeri %66,7 olarak hesaplanmış olup, modelin pozitif tahminlerinin %66.7'sinin doğru olduğunu göstermektedir. Negatif kestirim değeri %100 olarak hesaplanmış ve modelin negatif tahminlerinin tümünün doğru olduğunu göstermektedir. Ancak, AUC değeri 0,50 olarak hesaplanmış olup, bu da modelin sınıflandırma yeteneğinin test verisi üzerinde tamamen rastgele olduğunu göstermektedir. Genel olarak, eğitim verisi üzerinde modelin özgüllük ve negatif kestirim değeri düşük olduğu için negatif sınıfları tanımlamada başarısız olduğu görülmektedir. Bu durum, modelin eğitim verisinde aşırı uyum sağladığını ve negatif sınıfları ayırt edemediğini gösterir. Test verisi üzerinde modelin doğruluk oranı ve diğer performans metrikleri daha yüksek olmakla birlikte, AUC değerinin düşük olması, modelin sınıflandırma yeteneğinin hala yeterince güçlü olmadığını işaret etmektedir. Bu sonuçlar, modelin negatif sınıfları daha iyi ayırt edebilmesi için ek iyileştirmeler ve yeniden eğitim gerektirdiğini göstermektedir. Özellikle modelin genel genelleme yeteneğinin artırılması gerektiği açıktır.

## 4.2. Birinci Soruya Ait Verileri Sınıflandırmada Model Performansına İlişkin Bulgular

Birinci sorunun cevaplanmasıyla elde edilen verilerin sınıflandırmada Bayes sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları yöntemlerinin performansları modellerin doğruluk, duyarlılık, özgüllük ve F1 puanlarıyla incelenerek model performanslarını gösteren değerler eğitim ve test verisi olarak ikiye ayrılarak Şekil 9 ve Şekil 10'da karşılaştırılmıştır.

### 4.2.1. Birinci Soruya Ait Test Verisinin Sınıflandırılmasında Model Performanslarının Karşılaştırılması

Şekil 7'de, birinci soru için test verisi kullanılarak yapılan sınıflandırma algoritmalarının performansını göstermektedir. Doğruluk, Duyarlılık, Özgüllük ve F Puanı olmak üzere dört farklı metrik üzerinden karşılaştırmaktadır. Grafik, Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları algoritmalarının bu metriklerdeki performansını göstermektedir.

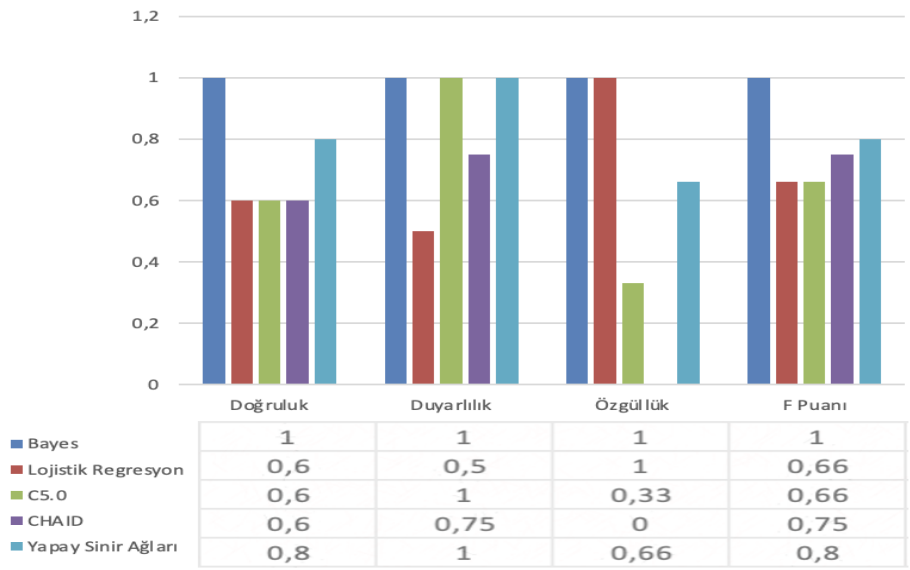


*Şekil 7.* Birinci soruya ait sınıflandırma algoritmalarının test verisi üzerindeki performans karşılaştırması

Şekil 7'ye baktığımızda, Bayes sınıflandırma algoritması tüm metriklerde en yüksek performansı göstermiştir. Doğruluk, duyarlılık, özgüllük ve F puanı metriklerinde 1,00 değeriyle maksimum performansa ulaşmıştır. Bu, Bayes algoritmasının test verisi üzerinde oldukça iyi genelleme yeteneğine sahip olduğunu ve doğru sınıflandırmalar yapma konusunda başarılı olduğunu göstermektedir. Lojistik Regresyon yöntemi, doğruluk ve özgüllük metriklerinde sırasıyla 0,6 ve 1,00 gibi kabul edilebilir performans sergilemesine rağmen, duyarlılıkta 0,5 gibi düşük bir değer göstermiştir. Bu, Lojistik Regresyonun pozitif sınıfları tanımlamada yeterince başarılı olmadığını, ancak genel sınıflandırma performansının yine de makul olduğunu ifade eder. F puanı metriği ise 0,66 olarak hesaplanmıştır, bu da modelin genel performansını ortaya koyar. C5.0 yöntemi, duyarlılık metriğinde 1,00 değeriyle mükemmel bir performans sergilemiştir. Ancak, özgüllükte yalnızca 0,33 gibi düşük bir değerle sınırlı kalmış, bu da C5.0'ın pozitif sınıfları doğru bir

şekilde tanımlarken negatif sınıfları tanımlamada zayıf kaldığını göstermektedir. Bu nedenle, C5.0 algoritmasının F puanı 0,66 olarak belirlenmiştir. CHAID algoritması, duyarlılıkta 0,75 ve doğrulukta 0,60 gibi orta seviyede performans sergilemiştir. Ancak, özgüllük metriğinde 0,00 puan alarak negatif sınıfları tamamen yanlış sınıflandırmıştır, bu da CHAID'in genel performansını ciddi şekilde olumsuz etkilemiştir. F puanı ise 0,75 olarak hesaplanmıştır. Yapay Sinir Ağları yöntemi, 0,80 doğruluk, 1,00 duyarlılık ve 0,80 F puanı metriklerinde oldukça yüksek bir performans göstermiştir. Ancak, özgüllük metriğinde 0,66 değeriyle diğer metriklere kıyasla daha düşük bir performans sergilemiştir. Bu durum, Yapay Sinir Ağlarının genel olarak iyi bir sınıflandırma modeli olduğunu, ancak negatif sınıfların doğru tanımlanmasında diğer metriklere göre daha zayıf kaldığını ortaya koymaktadır. Bu bulgular, algoritmaların performanslarını değerlendirirken tek bir metrik yerine birden fazla metriğin dikkate alınmasının önemini vurgulamaktadır. Han ve diğerleri (2012), sınıf dağılımının dengesiz olduğu veri setlerinde doğruluk yerine duyarlılık, özgüllük ve F puanı gibi metriklerin daha güvenilir sonuçlar verebileceğini öne sürmektedir. Bu nedenle, Bayes algoritması, tüm kriterlerdeki üstün performansı ile bu veri seti üzerinde en iyi sınıflandırma algoritması olarak öne çıkmaktadır.

### 4.2.2. Birinci Soruya Ait Eğitim Verisinin Sınıflandırılmasında Model Performanslarının Karşılaştırılması

Şekil 8'de, eğitim verisi kullanılarak yapılan sınıflandırma algoritmalarının performansını göstermektedir. Doğruluk, Duyarlılık, Özgüllük ve F Puanı olmak üzere dört farklı metrik üzerinden karşılaştırmaktadır. Grafik, Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları algoritmalarının bu metriklerdeki performansını göstermektedir.

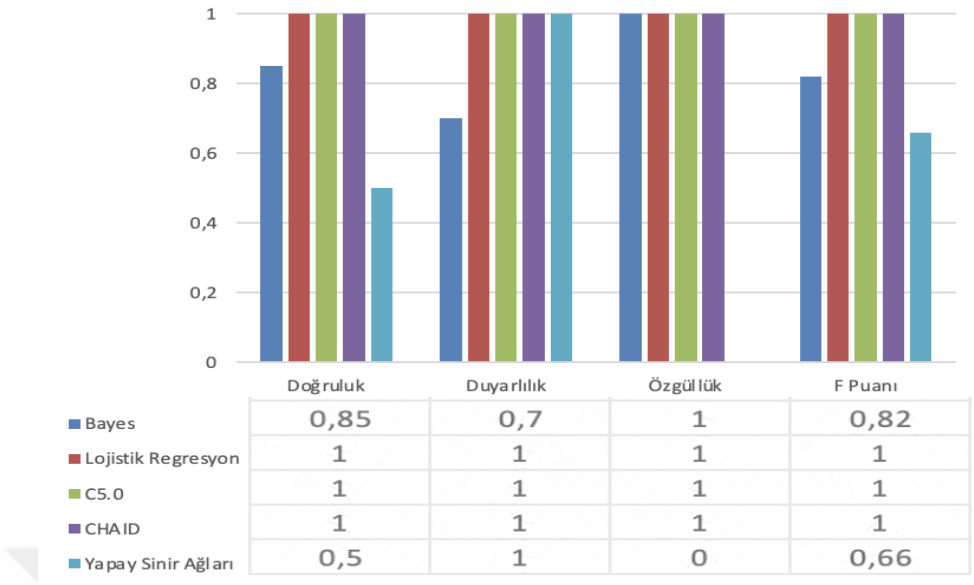


| | Doğruluk | Duyarlılık | Özgüllük | F Puanı |
|---|---|---|---|---|
| Bayes | 0,85 | 0,7 | 1 | 0,82 |
| Lojistik Regresyon | 1 | 1 | 1 | 1 |
| C5.0 | 1 | 1 | 1 | 1 |
| CHAID | 1 | 1 | 1 | 1 |
| Yapay Sinir Ağları | 0,5 | 1 | 0 | 0,66 |

*Şekil 8.* Birinci soruya ait sınıflandırma algoritmalarının eğitim verisi üzerindeki performans karşılaştırması

Şekil 8'deki verilere göre, Lojistik Regresyon, C5.0, ve CHAID algoritmaları doğruluk (1,00), duyarlılık (1,00), özgüllük (1,00) ve F puanı (1,00) metriklerinde maksimum performans sergilemiştir. Bu sonuçlar, bu algoritmaların eğitim verisi üzerinde mükemmel bir performans gösterdiğini ve sınıflandırma yeteneklerinin çok yüksek olduğunu göstermektedir. Bu yöntemler, hem pozitif hem de negatif sınıfları başarıyla ayırmışlardır ve tüm metriklerde dengeli sonuçlar elde etmişlerdir.

Bayes sınıflandırma algoritması, doğrulukta 0,85, duyarlılıkta 0,70, özgüllükte 1,00 ve F puanında 0,82 gibi değerlerle performans göstermiştir. Bayes algoritması özellikle duyarlılık metriğinde diğer algoritmalara kıyasla daha düşük kalmış olsa da, genel olarak pozitif sınıfları tanımlamada makul bir başarı göstermiştir ve özgüllük metriğinde en yüksek değeri koruyarak negatif sınıfları doğru bir şekilde ayırmıştır.

Yapay Sinir Ağları algoritması, doğruluk metriğinde 0,50, duyarlılık ve özgüllükte 1,00 ve F puanında 0,66 değerleri ile performans sergilemiştir. Doğruluk metriğindeki düşük performans, Yapay Sinir Ağlarının genel sınıflandırma başarısında zayıflık olduğunu gösterirken, duyarlılık ve özgüllük metriklerindeki maksimum değerler modelin belirli sınıfları doğru bir şekilde ayırmada başarılı olduğunu göstermektedir. F puanı 0,66 değeri ise modelin genel performansının diğer algoritmalara göre daha düşük olduğunu ifade eder.

Sonuç olarak, Lojistik Regresyon, C5.0 ve CHAID algoritmaları, genel performans kriterlerine göre test verisi üzerinde en iyi sınıflandırma modelleri olarak öne çıkmaktadır. Bununla birlikte, Bayes algoritması dengeli bir performans sergilerken, Yapay Sinir Ağları algoritması ise duyarlılık ve özgüllükte yüksek sonuçlar elde etmesine rağmen genel performansında zayıf kalmıştır.

## 4.3. Öğrencilerin İkinci Soruya Verdikleri Cevapları Belirlemede Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları Yöntemlerinin Sınıflandırma Performansları Ne Düzeydedir?

Bu araştırma sorusu, öğrencilerin ikinci soruya verdikleri yanıtları doğru bir şekilde tahmin etmek için kullanılan farklı sınıflandırma algoritmalarının performanslarını karşılaştırmayı amaçlamaktadır. Bu sayede hangi algoritmanın en yüksek doğruluğu sağladığı ve belirli durumlarda en etkili yöntem olduğu belirlenebilecektir.

### 4.3.1. Bayes Sınıflandırma Algoritmasına İlişkin Bulgular

Bayes Sınıflandırma Algoritmasına göre öğrencilerin ikinci soruya verdikleri cevapların sınıflandırılmasıyla ilişkili değişkenlerin önem düzeylerine göre sıralaması ve başarım istatistikleri nasıldır?

İkinci soru için oluşturulan Bayes Sınıflandırma Algoritmasına ait modelde en önemli olan parametrelerin önem dereceleri Tablo 19'da sunulmuştur.

Tablo 19.
*İkinci Soru İçin Oluşturulmuş Bayes Sınıflandırma Algoritmasına Ait Parametrelerin Önem Dereceleri*

| Parametreler | Önem Yüzdesi |
|---|---|
| Mean PSD Ch7 Teta (dB) | 2,55 |
| Mean PSD Ch7 Alpha (dB) | 2,55 |
| Mean PSD Ch7 Beta (dB) | 2,55 |
| Mean PSD Ch7 Gama (dB) | 2,55 |
| Mean PSD Ch8 Delta (dB) | 2,55 |
| Mean PSD Ch8 Teta (dB) | 2,55 |
| Mean PSD Ch8 Alpha (dB) | 2,55 |
| Mean PSD Ch8 Beta (dB) | 2,55 |
| Mean PSD Ch8 Gama (dB) | 2,55 |
| Mean PSD Ch2 Alpha (dB) | 2,55 |

Tablo 19’a göre, modelde en fazla öneme sahip olan 10 parametre sıralanmıştır. Mean PSD Ch7 Teta (dB), Mean PSD Ch7 Alpha (dB), Mean PSD Ch7 Beta (dB), Mean PSD Ch7 Gama (dB), Mean PSD Ch8 Delta (dB), Mean PSD Ch8 Teta (dB), Mean PSD Ch8 Alpha (dB), Mean PSD Ch8 Beta (dB), Mean PSD Ch8 Gama (dB) ve Mean PSD Ch2 Alpha (dB). Her bir parametre için belirlenen önem derecesi eşit olarak %2,55 olarak raporlanmıştır. Tüm parametrelerin aynı önem derecesine sahip olması, modelin bu parametreler arasında ayırt edici bir fark görmediğini ve her bir parametrenin modelin karar verme sürecine eşit derecede katkıda bulunduğunu ifade eder. Başka bir deyişle, bu parametrelerin model için birbirine denk bir öneme sahip olduğu ve modelin bu parametreler arasında herhangi birini daha belirleyici veya etkili görmediği anlaşılmaktadır.

Bayes Sınıflandırma Algoritması modelinin performansını değerlendirmek amacıyla oluşturulan Karışıklık matrisi Tablo 20'de sunulmuştur.

Tablo 20.
*İkinci Soru İçin Oluşturulmuş Bayes Sınıflandırma Algoritmasına Ait Karışıklık Matrisi*

| | | Tahmini | | TP | TN | FP | FN |
|---|---|---|---|---|---|---|---|
| | Gerçek | 0 | 1 | | | | |
| Test | 0 | 1 | 1 | 3 | 1 | 1 | 0 |
| | 1 | 0 | 3 | | | | |
| Eğitim | 0 | 6 | 1 | 12 | 6 | 1 | 0 |
| | 1 | 1 | 12 | | | | |

Test verisi üzerindeki karışıklık matrisine göre, model 3 pozitif sınıfı doğru bir şekilde tanımlamış, 1 negatif sınıfı da doğru bir şekilde negatif olarak tanımlamıştır. Ancak, bir negatif sınıfı pozitif olarak tahmin etmiş, fakat herhangi bir pozitif sınıfı negatif olarak tahmin etmemiştir. Bu durum, modelin test verisi üzerinde pozitif sınıfları doğru bir şekilde tahmin edebildiğini, ancak negatif sınıfları tanımlamada zorluk yaşadığını göstermektedir. Eğitim verisi üzerindeki karışıklık matrisine göre, model 12 pozitif sınıfı doğru bir şekilde tanımlamış, 6 negatif sınıfı da doğru bir şekilde negatif olarak tanımlamıştır. Ancak, bir negatif sınıfı pozitif olarak ve bir pozitif sınıfı negatif olarak tahmin etmiştir. Modelin eğitim verisi üzerinde yüksek doğrulukla çalıştığı, ancak bazı sınıfları yanlış sınıflandırdığı görülmektedir. Genel olarak, her iki veri setinde de modelin pozitif sınıfları doğru tahmin etme konusunda başarılı olduğu, ancak özellikle test verisinde negatif sınıfları ayırt etmede yetersizlik gösterdiği görülmektedir.

Bayes Sınıflandırma Algoritması modelinin performansını değerlendirmek amacıyla oluşturulan başarım istatistikleri Tablo 21'de sunulmuştur.

Tablo 21.
*İkinci Soru İçin Oluşturulmuş Bayes sınıflandırma Algoritmasına Ait Başarım İstatistikleri*

| | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1 puanı(%) | PPV(%) | NPV(%) | AUC(%) |
|---|---|---|---|---|---|---|---|
| Test | 80,0 | 100,0 | 50,0 | 85,7 | 75,0 | 100,0 | 0,500 |
| Eğitim | 90,0 | 92,3 | 85,7 | 92,3 | 92,3 | 85,7 | 0,956 |

Elde edilen sonuçlara göre, Bayes Sınıflandırma Algoritması eğitim verisi üzerinde %90,0 doğruluk oranı ile oldukça iyi bir performans sergilemiştir. Modelin duyarlılığı ve özgüllüğü dengeli olup, hem pozitif hem de negatif sınıfları ayırt etmede başarılı olmuştur. Eğitim verisi üzerinde AUC değeri 0,956 olarak belirlenmiş ve modelin genel sınıflandırma performansının yüksek olduğu görülmüştür. Test verisi üzerinde modelin doğruluk oranı %80,0 olarak belirlenmiştir. Duyarlılık %100 olup, model tüm pozitif örnekleri doğru şekilde tanımlamıştır. Ancak özgüllük %50,0 olduğu için modelin negatif sınıfları ayırt etme yeteneği düşüktür. Test verisinde AUC değeri 0,500 olarak hesaplanmış ve bu da modelin sınıflandırma yeteneğinin test verisi üzerinde sınırlı olduğunu göstermektedir. Bu sonuçlar, modelin eğitim verisi üzerinde güçlü bir performans sergilediğini, ancak test verisinde bazı sınıflandırma hataları yaptığını ortaya koymaktadır. Modelin genelleme yeteneğinin geliştirilmesi ve özellikle negatif sınıfları daha iyi ayırt edebilmesi için ek iyileştirmeler gerekmektedir.

### 4.3.2. Lojistik Regresyon Yöntemine İlişkin Bulgular

Lojistik Regresyon yöntemine göre öğrencilerin ikinci soruya verdikleri cevapların sınıflandırılmasıyla ilişkili değişkenlerin önem düzeylerine göre sıralaması ve başarım istatistikleri nasıldır?

İkinci soru için oluşturulan Lojistik Regresyon yöntemine ait en önemli olan parametrelerin önem dereceleri Tablo 22'de sunulmuştur.

Tablo 22.
*İkinci Soru İçin Oluşturulmuş Lojistik Regresyon Yöntemine Ait Parametrelerin Önem Dereceleri*

| Parametreler | Önem (%) |
|---|---|
| Mean PSD Ch7 Beta (dB) | 5,72 |

| | |
|---|---|
| Mean PSD Ch8 Beta (dB) | 5,56 |
| Mean PSD Ch8 Gama (dB) | 5,21 |
| Mean PSD Ch7 Alpha (dB) | 4,95 |
| Mean PSD Ch3 Teta (dB) | 4,89 |
| Mean PSD Ch5 Teta (dB) | 4,78 |
| Mean PSD Ch4 Delta (dB) | 4,51 |
| Mean PSD Ch4 Teta (dB) | 4,37 |
| Mean PSD Ch5 Beta (dB) | 3,25 |
| Mean PSD Ch5 Alpha (dB) | 3,02 |

En yüksek önem derecesine sahip parametre, %5,72 ile Mean PSD Ch7 Beta (dB) olarak bulunmuştur. Bu parametreyi %5,56 ile Mean PSD Ch8 Beta (dB) takip etmektedir. Üçüncü sırada %5,21 ile Mean PSD Ch8 Gama (dB) yer almaktadır. Dördüncü sırada %4,95 ile Mean PSD Ch7 Alpha (dB) bulunurken, beşinci sırada %4,89 ile Mean PSD Ch3 Teta (dB) gelmektedir. Altıncı sırada %4,78 ile Mean PSD Ch5 Teta (dB) yer almakta olup, yedinci sırada %4,51 önem derecesiyle Mean PSD Ch4 Teta (dB) ve sekizinci sırada %4,37 ile Mean PSD Ch4 Delta (dB) bulunmaktadır. Dokuzuncu sırada %3,25 ile Mean PSD Ch5 Beta (dB) yer alırken, onuncu ve son sırada %3,02 ile Mean PSD Ch5 Alpha (dB) bulunmaktadır. Bu bulgular, yapay sinir ağları modelinde beta ve Gama dalgalarının özellikle önemli olduğunu ve bu frekans bantlarındaki güç spektral yoğunluğu (PSD) ölçümlerinin modelin performansı üzerinde belirgin bir etkiye sahip olduğunu ortaya koymaktadır.

Lojistik Regresyon modelinin performansını değerlendirmek amacıyla oluşturulan Karışıklık matrisi Tablo 23'te sunulmuştur.

Tablo 23.
*İkinci Soru İçin Oluşturulmuş Lojistik Regresyon Yöntemine Ait Karışıklık Matrisi*

| | | Tahmini | | TP | TN | FP | FN |
|---|---|---|---|---|---|---|---|
| | Gerçek | 0 | 1 | | | | |
| Test | 0 | 2 | 0 | 2 | 2 | 0 | 1 |
| | 1 | 1 | 2 | | | | |
| Eğitim | 0 | 1 | 0 | 13 | 1 | 0 | 6 |
| | 1 | 6 | 13 | | | | |

Test verisi üzerinde model, 2 pozitif sınıfı doğru bir şekilde tanımlamış ve 1 negatif sınıfı da doğru bir şekilde negatif olarak tahmin etmiştir. Ancak, bir negatif sınıfı yanlış bir şekilde

pozitif olarak tahmin etmiş ve bir pozitif sınıfı yanlış bir şekilde negatif olarak tahmin etmiştir. Bu durum, modelin test verisi üzerinde dengeli bir performans gösterdiğini, ancak bazı sınıflandırma hataları yaptığını göstermektedir. Eğitim verisi üzerinde model, 13 pozitif sınıfı doğru bir şekilde tanımlamış ve sadece 1 negatif sınıfı doğru olarak negatif tahmin etmiştir. Ancak, 6 pozitif sınıfı yanlış bir şekilde negatif olarak tahmin etmiştir. Bu durum, modelin eğitim verisi üzerinde pozitif sınıfları tanımlamada iyi performans gösterdiğini, ancak negatif sınıfları tanımlamada bazı zorluklar yaşadığını göstermektedir. Eğitim verisi üzerinde model pozitif sınıfları tanımada güçlü bir performans sergilemekte, ancak negatif sınıfları doğru bir şekilde tanımlamada yetersizlik göstermektedir. Test verisi üzerinde ise modelin genel performansı daha dengeli olup, hem pozitif hem de negatif sınıfları doğru bir şekilde tanımlama yeteneği göstermektedir. Ancak, her iki veri setinde de bazı sınıflandırma hataları gözlemlenmekte, bu da modelin genelleme yeteneğini geliştirmek için daha fazla iyileştirme yapılması gerektiğini göstermektedir.

Lojistik Regresyon modelinin performansını değerlendirmek amacıyla oluşturulan başarım istatistikleri Tablo 24'te sunulmuştur.

Tablo 24.
*İkinci Soru İçin Oluşturulmuş Lojistik Regresyon Yöntemine Ait Başarı m İstatistikleri*

| | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1 puanı(%) | PPV(%) | NPV(%) | AUC(%) |
|---|---|---|---|---|---|---|---|
| Test | 80,0 | 66,7 | 100,0 | 80,0 | 100,0 | 66,7 | 0,750 |
| Eğitim | 95,0 | 100,0 | 85,7 | 96,3 | 92,9 | 100,0 | 1,000 |

Tablo 24 incelendiğinde elde edilen sonuçlara göre, test verisi üzerinde modelin toplam doğruluk oranı %80,0 olarak hesaplanmıştır. Modelin duyarlılığı %66,7 olarak belirlenmiş olup, pozitif sınıfları tanımlama yeteneği eğitim verisine göre daha düşük kalmıştır. Ancak, özgüllük %100 olarak bulunmuş, yani modelin negatif sınıfları başarıyla tanımladığı görülmüştür. Test verisi üzerinde modelin F1 puanı %80,0 olarak hesaplanmış ve modelin pozitif sınıflar için dengeli bir performans sergilediğini göstermektedir. Pozitif kestirim değeri %100 olup, modelin pozitif tahminlerinin tamamının doğru olduğunu ifade etmektedir. Negatif kestirim değeri ise %66,7 olarak hesaplanmış, bu da negatif tahminlerin doğruluğunda bazı sınırlamaların olduğunu göstermektedir. Test verisi üzerinde modelin ROC eğrisi altındaki alan (AUC) değeri 0,750 olarak hesaplanmış ve modelin pozitif ve

negatif sınıfları ayırt etme yeteneğinin iyi bir seviyede olduğunu göstermektedir. Eğitim verisi üzerinde ise modelin toplam doğruluk oranı %95,0 olarak hesaplanmıştır. Modelin duyarlılığı yani gerçek pozitif örnekleri doğru bir şekilde tanımlama yeteneği %100 olarak belirlenmiştir. Özgüllük ise %85,7 olarak bulunmuş, bu da modelin gerçek negatif örnekleri tanımada oldukça başarılı olduğunu göstermektedir. Eğitim verisi üzerinde modelin F1 skoru, pozitif sınıfın dengeli bir ölçüsü olarak %96,3 olarak hesaplanmıştır. Pozitif kestirim değeri %92,9 olup, modelin pozitif tahminlerinin doğruluğunu göstermektedir. Negatif kestirim değeri ise %100 olarak hesaplanmış, bu da modelin negatif tahminlerinin tamamının doğru olduğunu ifade etmektedir. Son olarak, modelin ROC eğrisi altındaki alan (AUC) değeri 1,000 olarak hesaplanmış ve modelin pozitif ve negatif sınıfları ayırt etme yeteneğinin mükemmel olduğunu göstermektedir. Bu bulgular, lojistik regresyon modelinin eğitim verisi üzerinde oldukça güçlü bir performans sergilediğini, test verisi üzerinde ise daha dengeli ancak bazı sınırlamaları olan bir performans gösterdiğini ortaya koymaktadır. Özellikle yüksek özgüllük ve doğruluk oranları, modelin negatif sınıfları başarıyla ayırt edebildiğini ve pozitif sınıflar için de dengeli bir performans sergilediğini göstermektedir. Ancak, duyarlılık ve test verisi üzerindeki AUC değerinin tam 1'e ulaşmaması, modelin daha hassas hale getirilmesi veya başka yöntemlerle iyileştirilmesi gerektiğini düşündürebilir. Bu sonuçlar, lojistik regresyonun bu veri setindeki kullanımının değerlendirilmesi ve olası iyileştirmeler için fırsatların gözden geçirilmesi gerektiğini ortaya koymaktadır.

### 4.3.3. C5.0 Yöntemine İlişkin Bulgular

C5.0 yöntemine göre öğrencilerin ikinci soruya verdikleri cevapların sınıflandırılmasıyla ilişkili değişkenlerin önem düzeylerine göre sıralaması ve başarım istatistikleri nasıldır?

İkinci soru için oluşturulan C5.0 yöntemine ait en önemli olan parametrelerin önem dereceleri Tablo 25'te sunulmuştur.

Tablo 25.
*İkinci Soru İçin Oluşturulmuş C5.0 Yöntemine Ait Parametrelerin Önem Dereceleri*

| Parametreler | Önem (%) |
|---|---|
| Mean PSD Ch4 Beta (dB) | 62,2 |
| Mean PSD Ch6 Teta (dB) | 24,3 |
| Mean PSD Ch1 Beta (dB) | 13,4 |

En yüksek öneme sahip olan 3 parametre şunlardır: Mean PSD Ch4 Beta (dB), Mean PSD Ch6 Teta (dB) ve Mean PSD Ch1 Beta (dB). Bu parametreler sırasıyla %62,2, %24,3 ve %13,4 önem derecesine sahiptir. Bu bulgular, C5.0 algoritmasının modelde özellikle Beta ve Teta frekans bantlarındaki güç spektral yoğunluk (PSD) ölçümlerine odaklandığını göstermektedir. Bu frekans bantlarındaki aktivitelerin, modelin çıktılarını belirlemede kritik öneme sahip olduğunu ve modelin performansını büyük ölçüde etkileyebileceğini göstermektedir. Özellikle bu parametrelerin belirlenmesi, C5.0 algoritmasının bu özel veri setindeki başarısını artırmak ve modelin genel performansını iyileştirmek için önemli bir rehberlik sağlamaktadır. Modelin yapılandırılması ve optimize edilmesi sürecinde bu bulguların dikkate alınması, modelin doğruluğunu artırmak için değerli bir adım olabilir.

C5.0 modelinin performansını değerlendirmek amacıyla oluşturulan Karışıklık matrisi Tablo 26'da sunulmuştur.

Tablo 26.
*İkinci Soru İçin Oluşturulmuş C5.0 Yöntemine Ait Karışıklık Matrisi*

| | | Tahmini | | TP | TN | FP | FN |
|---|---|---|---|---|---|---|---|
| | Gerçek | 0 | 1 | | | | |
| Test | 0 | 1 | 1 | 2 | 1 | 1 | 1 |
| | 1 | 1 | 2 | | | | |
| Eğitim | 0 | 7 | 0 | 13 | 7 | 0 | 0 |
| | 1 | 0 | 13 | | | | |

Tablo 26'da elde edilen sonuçlar incelendiğinde, C5.0 modeli eğitim verisi üzerinde oldukça başarılı sonuçlar elde etmiştir. Eğitim setinde model, sınıflandırma görevinde neredeyse mükemmel performans göstermiş, tüm pozitif ve negatif örnekleri doğru bir şekilde sınıflandırmıştır. Ancak, test verisi üzerinde elde edilen sonuçlar, modelin genelleme yeteneği konusunda bazı sınırlamaları olduğunu göstermektedir. Test setindeki karışıklık matrisi, modelin bazı yanlış sınıflandırmalar yaptığını göstermektedir. Bu durum, modelin eğitim verisine aşırı uyum sağlamış (overfitting) olabileceğini ve yeni, görülmemiş verilerle karşılaştığında bu nedenle daha düşük performans gösterdiğini işaret etmektedir. Sonuç olarak, modelin genelleme yeteneğini geliştirmek için daha fazla optimizasyon yapılması veya farklı yöntemler denenmesi gerekebilir. Eğitim verisinde mükemmel performans gösteren model, test verisinde yeterli performansı sağlayamamış ve bu durum, modelin test

verisinde gösterdiği hatalarla daha da belirgin hale gelmiştir. Modelin daha geniş bir veri setiyle eğitilmesi veya parametrelerin dikkatli bir şekilde optimize edilmesi, performansı artırmak için faydalı olabilir.

C5.0 modelinin performansını değerlendirmek amacıyla oluşturulan başarım istatistikleri Tablo 27'de sunulmuştur.

Tablo 27.
*İkinci Soru İçin Oluşturulmuş C5.0 Yöntemine Ait Başarım İstatistikleri*

| | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1 puanı(%) | PPV(%) | NPV(%) | AUC(%) |
|---|---|---|---|---|---|---|---|
| Test | 60,0 | 66,7 | 0,0 | 50,0 | 66,7 | 50,0 | 1,000 |
| Eğitim | 100,0 | 100,0 | 100,0 | 100,0 | 100,0 | 100,0 | 1.000 |

Tablo 27 incelendiğinde, modelin eğitim verisi üzerinde mükemmel bir performans sergilediği görülmektedir. Eğitim verisinde %100 doğruluk, duyarlılık, özgüllük, F1 puanı, PPV, NPV ve AUC değerlerine ulaşılmıştır. Bu, modelin eğitim verisi üzerindeki tüm örnekleri doğru bir şekilde sınıflandırdığını ve hiçbir hata yapmadığını göstermektedir. Ancak, test verisi üzerindeki sonuçlar, modelin genelleme yeteneği konusunda bazı zayıflıklar olduğunu ortaya koymaktadır. Test verisi üzerinde %60,0 doğruluk, %66,7 duyarlılık ve %50 NPV değeri elde edilmiştir. Özellikle özgüllük değerinin %0,0 olması, modelin negatif sınıfı tanımlamakta zorlandığını göstermektedir. Bu durum, modelin eğitim verisine aşırı uyum sağlamış (overfitting) olabileceğini ve gerçek dünyadaki yeni verilere karşı yeterince esnek olamayabileceğini işaret etmektedir. Sonuç olarak, modelin eğitim verisinde gösterdiği yüksek performansa rağmen, test verisindeki hatalar modelin genelleme yeteneğini geliştirmek için optimizasyon veya alternatif yöntemlerin denenmesi gerektiğini göstermektedir.

### 4.3.4. CHAID Karar Ağacı Yöntemine İlişkin Bulgular

*CHAID yöntemine göre öğrencilerin ikinci soruya verdikleri cevapların sınıflandırılmasıyla ilişkili değişkenlerin önem düzeylerine göre sıralaması ve başarım istatistikleri nasıldır?*

İkinci soru için oluşturulan CHAID yöntemine ait en önemli olan parametrelerin önem dereceleri Tablo 28'de sunulmuştur.

Tablo 28.

*İkinci Soru İçin Oluşturulmuş CHAID Yöntemine Ait Parametrelerin Önem Dereceleri*

| Parametreler | Önem (%) |
|---|---|
| Mean PSD Ch4 Beta (dB) | 23,4 |
| Mean PSD Ch3 Beta (dB) | 21,0 |
| Mean PSD Ch8 Beta (dB) | 17,2 |
| Mean PSD Ch2 Gama (dB) | 14,2 |
| Mean PSD Ch3 Teta (dB) | 8,73 |
| Mean PSD Ch3 Delta (dB) | 4,91 |
| Mean PSD Ch5 Teta (dB) | 3,63 |
| Mean PSD Ch7 Delta (dB) | 3,30 |
| Mean PSD Ch2 Alpha (dB) | 2,31 |
| Mean PSD Ch8 Gama (dB) | 0,66 |

CHAID karar ağacı algoritmasının eğitim modelindeki en önemli parametrelerin belirlendiği Tablo 28 incelendiğinde, en yüksek öneme sahip olan parametre Mean PSD Ch4 Beta (dB) olarak tespit edilmiştir (%23.43). Onu sırasıyla Mean PSD Ch3 Beta (dB) (%21.01), Mean PSD Ch8 Beta (dB) (%17.22) ve Mean PSD Ch2 Gama (dB) (%14.29) izlemektedir. Daha düşük önem dereceleriyle sıralanan diğer parametreler şunlardır: Mean PSD Ch3 Teta (dB) (%8.73), Mean PSD Ch3 Delta (dB) (%4.91), Mean PSD Ch5 Teta (dB) (%3.63), Mean PSD Ch7 Delta (dB) (%3.30), Mean PSD Ch2 Alpha (dB) (%2.31) ve en düşük önem derecesine sahip olan Mean PSD Ch8 Gama (dB) (%0.66). Bu bulgular, CHAID karar ağacı algoritmasının modelde özellikle beta ve Gama frekans bantlarındaki güç spektral yoğunluk (PSD) ölçümlerine odaklandığını göstermektedir. Bu frekans bantlarındaki aktivitelerin, modelin karar ağacı yapısını ve sınıflandırma süreçlerini belirlemede kritik öneme sahip olduğunu ve modelin doğruluğunu büyük ölçüde etkileyebileceğini vurgulamaktadır. Özellikle bu parametrelerin belirlenmesi, CHAID algoritmasının bu özel veri setindeki performansını artırmak ve modelin genel doğruluğunu iyileştirmek için önemli bir rehberlik sağlamaktadır.

CHAID karar ağacı modelinin performansını değerlendirmek amacıyla oluşturulan Karışıklık matrisi Tablo 29'da sunulmuştur.

Tablo 29.
*İkinci Soru İçin Oluşturulmuş CHAID Yöntemine Ait Karışıklık Matrisi*

| | | Tahmini | | TP | TN | FP | FN |
|---|---|---|---|---|---|---|---|
| | Gerçek | 0 | 1 | | | | |
| Test | 0 | 0 | 1 | 3 | 0 | 1 | 1 |
| | 1 | 1 | 3 | | | | |
| Eğitim | 0 | 7 | 0 | 13 | 7 | 0 | 0 |
| | 1 | 0 | 13 | | | | |

Test verisi üzerinde model, 3 pozitif sınıfı doğru bir şekilde tahmin etmiş ancak 1 pozitif sınıfı yanlış olarak negatif sınıfına yerleştirmiştir. Ayrıca, 1 negatif sınıfı yanlış olarak pozitif sınıfına tahmin etmiştir. Bu sonuçlar, modelin test verisi üzerinde genelleme yeteneğinin sınırlı olduğunu ve bazı sınıflandırma hataları yaptığını göstermektedir. CHAID modeli, eğitim verisi üzerinde mükemmel bir performans sergilemiştir. Model, tüm pozitif ve negatif sınıfları doğru bir şekilde sınıflandırmıştır. Hiçbir yanlış pozitif veya yanlış negatif tahmin yapılmamıştır, bu da modelin eğitim verisine çok iyi uyum sağladığını göstermektedir. Bu sonuçlar, CHAID modelinin eğitim verisi üzerinde mükemmel bir performans sergilediğini, ancak test verisi üzerinde aynı düzeyde bir başarı sağlayamadığını göstermektedir. Eğitim verisine aşırı uyum sağladığı (overfitting) ve test verisinde hatalar yaptığı için modelin genelleme yeteneğini geliştirmek amacıyla bazı iyileştirmeler gerekebilir.

CHAID yönteminin performansını değerlendirmek amacıyla oluşturulan başarım istatistikleri Tablo 30'da sunulmuştur.

Tablo 30.
*İkinci Soru İçin Oluşturulmuş CHAID Yöntemine Ait Başarım İstatistikleri*

| | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1 puanı(%) | PPV(%) | NPV(%) | AUC(%) |
|---|---|---|---|---|---|---|---|
| Test | 60,0 | 75,0 | 0,0 | 75,0 | 75,0 | 0,0 | 0,375 |
| Eğitim | 100,0 | 100,0 | 100,0 | 100,0 | 100,0 | 100,0 | 1,000 |

Tablo 30’a göre, test verisi üzerinde modelin doğruluk oranı %60,0 olarak hesaplanmıştır, bu da modelin test verisinde yapılan tahminlerin %60'ının doğru olduğunu göstermektedir. Modelin duyarlılığı %75,0 olup, pozitif sınıfları tanımada nispeten başarılıdır. Ancak, özgüllük %0,0 olarak hesaplanmış olup, modelin negatif sınıfları tanımada başarısız olduğunu göstermektedir. F1 puanı %75,0 olup, pozitif sınıfın dengeli bir ölçüsü olarak hesaplanmıştır. Pozitif kestirim değeri %75,0 olarak bulunmuş, ancak negatif kestirim değeri %0,0 olarak hesaplanmıştır, bu da modelin negatif tahminlerinin doğruluğunda sorunlar olduğunu gösterir. CHAID modeli, eğitim verisi üzerinde mükemmel bir performans sergilemiştir. Tüm metrikler %100 olarak hesaplanmış olup, modelin eğitim verisi üzerinde hiçbir hata yapmadığı görülmektedir. Bu durum, modelin eğitim verisine çok iyi uyum sağladığını göstermektedir. Bu sonuçlar, CHAID modelinin eğitim verisi üzerinde aşırı uyum sağladığını (overfitting) ve test verisi üzerinde genelleme yeteneğinin düşük olduğunu ortaya koymaktadır. Modelin bu performansı, gerçek dünya uygulamaları için yetersiz olabileceğini ve modelin genelleme yeteneğini artırmak için yeniden eğitilmesi veya farklı yöntemlerin değerlendirilmesi gerektiğini işaret etmektedir.

### 4.3.5. Yapay Sinir Ağları Yöntemine İlişkin Bulgular

Yapay Sinir Ağları yöntemine göre öğrencilerin ikinci soruya verdikleri cevapların sınıflandırılmasıyla ilişkili değişkenlerin önem düzeylerine göre sıralaması ve başarım istatistikleri nasıldır?

İkinci soru için oluşturulan C5.0 yöntemine ait en önemli olan parametrelerin önem dereceleri Tablo 31'de sunulmuştur.

Tablo 31.
*İkinci Soru İçin Oluşturulmuş Yapay Sinir Ağları Yöntemine Ait Parametrelerin Önem Dereceleri*

| Parametreler | Önem (%) |
|---|---|
| Mean PSD Ch5 Gama (dB) | 5,31 |
| Mean PSD Ch7 Gama (dB) | 4,70 |
| Mean PSD Ch4 Delta (dB) | 4,47 |
| Mean PSD Ch5 Beta (dB) | 4,10 |
| Mean PSD Ch6 Beta (dB) | 3,97 |
| Mean PSD Ch1 Alpha (dB) | 3,87 |
| Mean PSD Ch5 Teta (dB) | 3,72 |
| Mean PSD Ch3 Delta (dB) | 3,31 |
| Mean PSD Ch2 Teta (dB) | 3,28 |
| Mean PSD Ch8 Beta (dB) | 3,16 |

Tablo 31 incelendiğinde elde edilen sonuçlar, yapay sinir ağları eğitim modelinde hangi parametrelerin performansı ve doğruluğu artırmada daha kritik olduğunu göstermektedir. En yüksek öneme derecesine sahip olan parametre %5,31 ile Mean PSD Ch5 Gama (dB) olarak belirlenmiştir. Bu parametre, Ch5 kanalından elde edilen Gama dalgalarının model üzerindeki en güçlü etkisini göstermektedir. Gama dalgaları genellikle yüksek düzeyde bilişsel aktivite ile ilişkilendirilir, bu nedenle bu parametrenin yüksek önem derecesine sahip olması, modelin bilişsel aktiviteyi doğru bir şekilde tahmin edebilme kapasitesini vurgular. İkinci sırada %4,70 ile Mean PSD Ch7 Gama (dB) yer almaktadır. Bu, modelin Ch7 kanalındaki Gama dalgalarını da oldukça etkili bir şekilde kullandığını göstermektedir. Üçüncü sırada %4,47 ile Mean PSD Ch4 Delta (dB) bulunmakta olup, delta dalgalarının bu kanal üzerinden modeldeki etkisi ortaya çıkmıştır. Dördüncü sırada %4,10 ile Mean PSD Ch5 Beta (dB) yer almaktadır. Beşinci sırada %3,97 ile Mean PSD Ch6 Beta (dB) bulunmakta olup, altıncı sırada %3,87 ile Mean PSD Ch1 Alpha (dB) yer almaktadır. Alpha

dalgaları genellikle rahatlama durumlarıyla ilişkilendirilir ve bu parametrenin modeldeki önemi, dinlenme veya meditasyon durumlarının tanımlanmasına katkıda bulunmaktadır. Yedinci sırada %3,72 ile Mean PSD Ch5 Teta (dB) yer almakta olup, teta dalgalarının hafif uyku veya meditasyon durumlarını tanımlamada model için önemli bir parametre olduğunu göstermektedir. Sekizinci sırada %3,31 ile Mean PSD Ch3 Delta (dB) bulunmaktadır. Bu, modelin Ch3 kanalındaki delta dalgalarını dikkate aldığını göstermektedir. Dokuzuncu sırada %3,28 ile Mean PSD Ch2 Teta (dB) yer almakta olup, bu da teta dalgalarının modelin meditasyon veya hafif uyku gibi durumları tanımlamasında etkili olduğunu göstermektedir. En düşük öneme derecesine sahip olan parametre %3,16 ile Mean PSD Ch8 Beta (dB) olarak belirlenmiştir. Bu parametre, Ch8 kanalından elde edilen beta dalgalarının model üzerindeki etkisini göstermektedir, ancak diğer parametrelerle karşılaştırıldığında modelin doğruluğu üzerindeki etkisi daha sınırlı kalmıştır. Sonuç olarak, en iyi performans gösteren dalga boyu, modelin bilişsel aktiviteleri belirlemede kritik bir rol oynayan Gama ve beta dalgalarıdır.

Yapay Sinir Ağları modelinin performansını değerlendirmek amacıyla oluşturulan Karışıklık matrisi Tablo 32'de sunulmuştur.

Tablo 32.
*İkinci Soru İçin Oluşturulmuş Yapay Sinir Ağları Yöntemine Ait Karışıklık Matrisi*

| | | Tahmini | | TP | TN | FP | FN |
|---|---|---|---|---|---|---|---|
| | Gerçek | 0 | 1 | | | | |
| Test | 0 | 0 | 2 | 3 | 0 | 2 | 0 |
| | 1 | 0 | 3 | | | | |
| Eğitim | 0 | 0 | 7 | 13 | 0 | 7 | 0 |
| | 1 | 0 | 13 | | | | |

Tablo 32 incelendiğinde, test verisi üzerinde model, pozitif sınıfa ait 3 örneğin tamamını doğru bir şekilde sınıflandırırken, negatif sınıfa ait 2 örneği yanlış bir şekilde pozitif olarak tahmin etmiştir. Bu durum, modelin negatif sınıfları ayırt etmede yetersiz kaldığını ve bu sınıfları doğru bir şekilde tahmin edemediğini göstermektedir. Eğitim verisi üzerinde de benzer bir durum gözlenmiştir; model, pozitif sınıfa ait 13 örneğin tamamını doğru sınıflandırmış, ancak negatif sınıfa ait 7 örneği yanlış pozitif olarak tahmin etmiştir. Bu sonuçlar, modelin hem test hem de eğitim verisi üzerinde pozitif sınıfları doğru bir şekilde ayırt etme konusunda başarılı olduğunu, ancak negatif sınıfları doğru tahmin etmede zayıf kaldığını ortaya koymaktadır. Modelin bu eksikliği, negatif sınıfların özelliklerini yeterince iyi öğrenemediğini işaret etmektedir.

Yapay Sinir Ağları algoritmasının performansını değerlendirmek amacıyla oluşturulan başarım istatistikleri Tablo 33'de sunulmuştur

Tablo 33.
*İkinci Soru İçin Oluşturulmuş Yapay Sinir Ağları Yöntemine Ait Başarım İstatistikleri*

| | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1 puanı(%) | PPV(%) | NPV(%) | AUC(%) |
|---|---|---|---|---|---|---|---|
| Test | 60,0 | 100,0 | 0,0 | 75,0 | 60,0 | --- | 0,500 |
| Eğitim | 65,0 | 100,0 | 0,0 | 78,8 | 65,0 | 0,0 | 0,500 |

Tablo 33 incelendiğinde, eğitim verisi üzerinde YSA modeli %65,0 doğruluk oranı ile çalışmış olup, tüm pozitif örnekleri doğru bir şekilde sınıflandırmış ancak negatif örnekleri tanıma konusunda başarısız olmuştur. Model, pozitif sınıfları %100 duyarlılık ile tanımlamış ancak özgüllük %0,0 olarak hesaplanmış, yani hiçbir negatif sınıfı doğru tahmin edememiştir. Bu durum modelin negatif sınıfları tamamen pozitif olarak sınıflandırdığını göstermektedir. Test verisi üzerinde benzer bir performans sergilenmiştir. Doğruluk oranı %60,0, duyarlılık %100.0, ancak özgüllük yine %0,0 olarak bulunmuştur. F1 puanı eğitim verisinde %78,8 iken test verisinde %75,0 olarak hesaplanmıştır. AUC değeri her iki veri seti için de 0,500 olup, modelin pozitif ve negatif sınıfları ayırt etme yeteneğinin tamamen rastlantısal olduğunu göstermektedir. Bu sonuçlar, YSA modelinin pozitif sınıfları tanımlamada iyi bir performans sergilediğini ancak negatif sınıfları tamamen göz ardı ettiğini göstermektedir. Modelin genelleme yeteneğini artırmak ve negatif sınıfları tanımlama becerisini geliştirmek için ek iyileştirmeler yapılması gerekebilir.

## 4.4. İkinci Soruya Ait Verileri Sınıflandırmada Model Performansına İlişkin Bulgular

İkinci sorunun cevaplanmasıyla elde edilen verilerin sınıflandırmada Bayes sınıflandırma Algoritmsı, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları yöntemlerinin performansları modellerin doğruluk, duyarlılık, özgüllük ve F1 puanlarıyla incelenerek model performanslarını gösteren değerler eğitim ve test verisi olarak ikiye ayrılarak Sekil 11 ve Şekil 12'de karşılaştırılmıştır.

### 4.4.1. İkinci Soruya Ait Test Verisinin Sınıflandırılmasında Model Performanslarının Karşılaştırılması

Şekil 9'da, ikinci soru için test verisi kullanılarak yapılan sınıflandırma algoritmalarının performansını göstermektedir. Doğruluk, Duyarlılık, Özgüllük ve F Puanı olmak üzere dört farklı metrik üzerinden karşılaştırmaktadır. Grafik, Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları algoritmalarının bu metriklerdeki performansını göstermektedir.

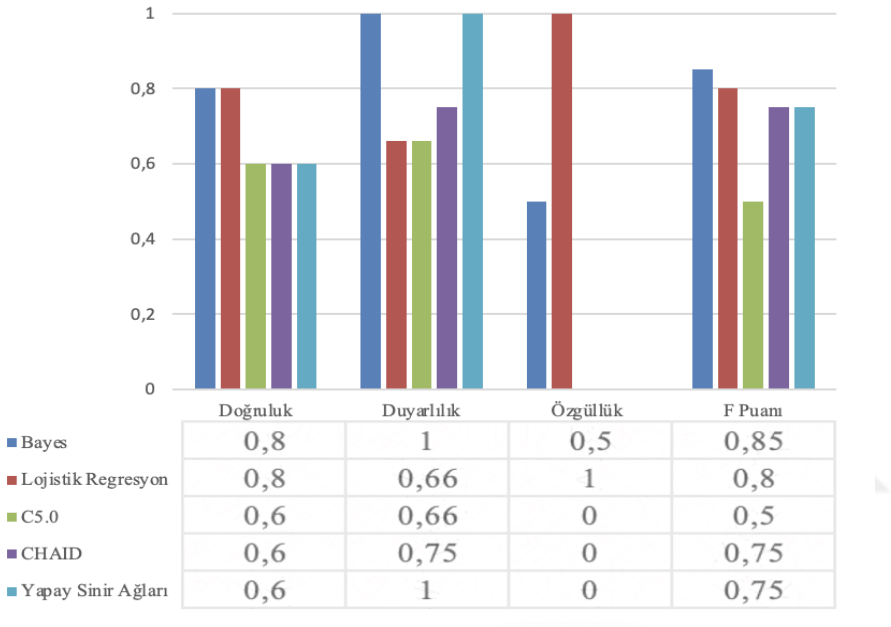


*Şekil 9.* İkinci soruya ait sınıflandırma algoritmalarının test verisi üzerindeki performans karşılaştırması

Seki 9'da yer alan sonuçlara göre, Bayes sınıflandırma algoritması, doğruluk metriğinde 0,80, duyarlılıkta 1,00, özgüllükte 0,50 ve F puanında 0,85 değerleriyle performans göstermiştir. Bu, Bayes algoritmasının pozitif sınıfları başarılı bir şekilde tanımladığını, ancak özgüllük açısından (negatif sınıfların tanımlanmasında) zayıf kaldığını göstermektedir. Bayes'in duyarlılık metriğinde gösterdiği maksimum performans, bu algoritmanın pozitif örnekleri doğru bir şekilde tespit etmede üstün olduğunu, ancak negatif örneklerde hata yapma eğiliminde olduğunu ifade eder. Lojistik Regresyon algoritması, doğrulukta 0,80, duyarlılıkta 0,66, özgüllükte 1,00 ve F puanında 0,80 değerleriyle makul bir performans sergilemiştir. Lojistik Regresyon, negatif sınıfların tanımlanmasında (özgüllük) mükemmel bir performans gösterirken, pozitif sınıfların tanımlanmasında (duyarlılık) nispeten zayıf kalmıştır. Ancak genel doğruluk ve F puanı değerleri, modelin dengeli bir performansa sahip olduğunu ortaya koymaktadır. C5.0 algoritması, doğrulukta

0,60, duyarlılıkta 0,66, özgüllükte 0,00 ve F puanında 0,50 gibi düşük performans sergilemiştir. Özellikle özgüllükteki 0,00 değeri, C5.0 algoritmasının negatif sınıfları hiç tanımlayamadığını ve bu nedenle genel performansının oldukça düşük olduğunu göstermektedir. CHAID algoritması, doğruluk metriğinde 0,60, duyarlılıkta 0,75, özgüllükte 0,00 ve F puanında 0,75 değerleriyle performans göstermiştir. CHAID, pozitif sınıfları tanımlamada makul bir başarı sergilemiş, ancak negatif sınıfları doğru bir şekilde ayırmada başarısız olmuştur. Bu durum, CHAID algoritmasının genel performansını olumsuz etkilemiştir. Yapay Sinir Ağları algoritması, doğrulukta 0,60, duyarlılıkta 1,00, özgüllükte 0,00 ve F puanında 0,75 değerleriyle performans sergilemiştir. Duyarlılık metriğinde maksimum performans göstermesi, Yapay Sinir Ağlarının pozitif sınıfları doğru bir şekilde tanımladığını, ancak özgüllük metriğinde (negatif sınıfların tanımlanması) 0,00 değeri ile tamamen başarısız olduğunu göstermektedir. Bu da modelin genel performansını olumsuz etkilemektedir. Sonuç olarak, Bayes sınıflandırma algoritması genel olarak en dengeli ve yüksek performansı sergileyen model olarak öne çıkmaktadır. Lojistik Regresyon ise özgüllük açısından yüksek performans sergilese de duyarlılıkta diğer algoritmalara kıyasla zayıf kalmıştır. C5.0, CHAID ve Yapay Sinir Ağları ise özellikle özgüllük açısından ciddi zayıflıklar göstermiş ve bu nedenle genel performansları düşük kalmıştır.

### 4.4.2. İkinci Soruya Ait Eğitim Verisinin Sınıflandırılmasında Model Performanslarının Karşılaştırılması

Şekil 10'da, ikinci soru için eğitim verisi kullanılarak yapılan sınıflandırma algoritmalarının performansını göstermektedir. Doğruluk, Duyarlılık, Özgüllük ve F Puanı olmak üzere dört farklı metrik üzerinden karşılaştırmaktadır. Grafik, Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları algoritmalarının bu metriklerdeki performansını göstermektedir.

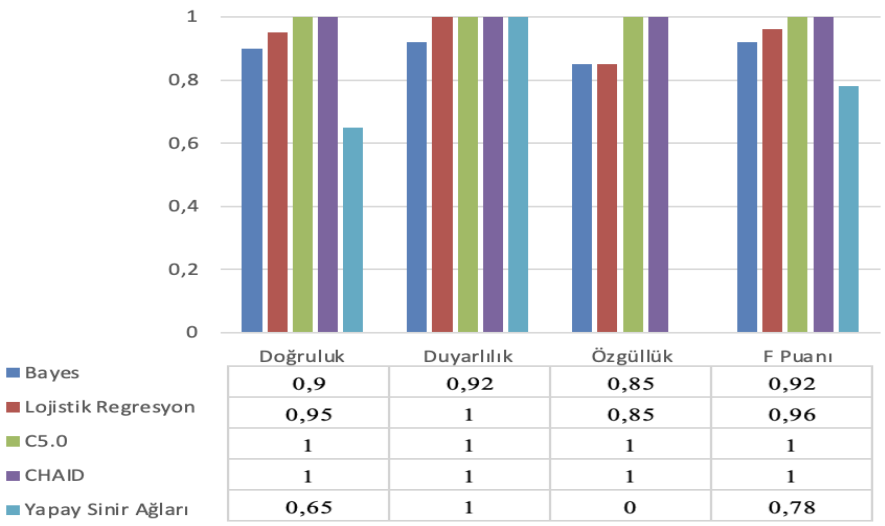


| | Doğruluk | Duyarlılık | Özgüllük | F Puanı |
|---|---|---|---|---|
| Bayes | 0,9 | 0,92 | 0,85 | 0,92 |
| Lojistik Regresyon | 0,95 | 1 | 0,85 | 0,96 |
| C5.0 | 1 | 1 | 1 | 1 |
| CHAID | 1 | 1 | 1 | 1 |
| Yapay Sinir Ağları | 0,65 | 1 | 0 | 0,78 |

*Şekil 10.* İkinci Soruya Ait Sınıflandırma Algoritmalarının Eğitim Verisi Üzerindeki Performans Karşılaştırması

Sekil 10 incelendiğinde, Lojistik Regresyon, C5.0 ve CHAID algoritmaları eğitim verisi üzerinde tüm metriklerde maksimum performans göstermiştir. Doğruluk, duyarlılık, özgüllük ve F puanı metriklerinde her üç algoritma da 1,00 değerine ulaşmıştır. Bu, bu modellerin eğitim verisi üzerinde mükemmel bir performans sergilediğini ve veriyle çok iyi uyum sağladığını göstermektedir. Bayes sınıflandırma algoritması, doğrulukta 0,90, duyarlılıkta 0,92, özgüllükte 0,85 ve F puanında 0,92 gibi yüksek performans göstermiştir. Bayes algoritması, eğitim verisi üzerinde oldukça dengeli ve yüksek bir performans sergilemiştir, ancak maksimum değerlere ulaşamamıştır. Bu, Bayes algoritmasının veriyle iyi bir uyum sağladığını, ancak diğer algoritmalar kadar mükemmel bir performans göstermediğini ifade eder. Yapay Sinir Ağları algoritması, doğrulukta 0,65, duyarlılıkta 1,00, özgüllükte 0,00 ve F puanında 0,78 değerleriyle performans sergilemiştir. Duyarlılık metriğinde maksimum performans göstermesine rağmen, doğruluk ve özellikle özgüllük metriğinde düşük performans göstermiştir. Bu durum, Yapay Sinir Ağlarının pozitif sınıfları tanımlamada çok başarılı olduğunu, ancak negatif sınıfları ayırt etmede başarısız olduğunu göstermektedir. Bu tür bir performans dengesizliği, modelin genelleme yeteneğinin sınırlı olabileceğini ve test verisinde zayıf bir performans sergileyebileceğini işaret edebilir. Sonuç olarak, Lojistik Regresyon, C5.0 ve CHAID algoritmaları, eğitim verisi üzerinde mükemmel performans sergilemiştir ve bu algoritmaların eğitim verisiyle çok iyi uyum sağladığını göstermektedir. Bayes algoritması da yüksek performans göstermiş, ancak diğer üç algoritma kadar mükemmel bir sonuç vermemiştir. Yapay Sinir Ağları ise duyarlılıkta

başarılı olmuş, ancak genel performansında zayıf kalmıştır, bu da eğitim verisi üzerinde modelin dengesiz bir performans gösterdiğini işaret etmektedir.

# BÖLÜM V

# SONUÇ TARTIŞMA VE ÖNERİLER

Sonuç olarak, bu çalışmada multimedya öğrenmede öğrencilerin dikkat seviyelerini belirlemek amacıyla EEG sinyallerinin kullanılması ve bu verilerin veri madenciliği sınıflandırma algoritmalarıyla analiz edilmesi hedeflenmiştir. Araştırmada, EEG dalga boylarının önem düzeyleri ve sınıflandırma yöntemlerinden Bayes Sınıflandırma Algoritması, Lojistik Regresyon, C5.0, CHAID ve Yapay Sinir Ağları ile elde edilen değerlerin performansları karşılaştırılmıştır. Alan yazında, öğrencilerin öğrenme süreçlerinde dikkat seviyelerini objektif bir şekilde değerlendirmek için EEG sinyallerinin kullanımı üzerine yapılan çalışmalar olsa da sınırlı sayıdadır. Bu çalışmada ise dikkat seviyesini belirlemede kullanılan delta, teta, alfa, beta ve gama dalga boylarının farklı sorular için nasıl değiştiği incelenmiş ve bu dalga boylarının model performanslarına etkisi araştırılmıştır. Bulgulara göre hem birinci hem de ikinci soru için beta ve gama dalgalarının dikkat süreçleri açısından önemli olduğu görülmektedir. Bu bantlar, aktif düşünme, problem çözme ve yüksek bilişsel işlevlerle ilişkili olup, öğrencilerin video izleme sürecinde bu dalga boylarında artış gözlemlenmiştir. Beta dalgaları, yoğun zihinsel etkinlikler ve dikkat gerektiren görevlerde önemli bir rol oynar (Pizzagalli, 2007); gama dalgaları ise öğrenme ve bilgi entegrasyonu süreçlerini destekler (Başar, 2013). Her iki soruda da beta dalgalarının önemli olması, öğrencilerin soruları yanıtlarken yüksek düzeyde dikkat ve uyanıklık gerektiren bir zihinsel durumda olduklarını göstermektedir. Gama dalgalarının önemli çıkması ise, karmaşık bilişsel süreçlerin ve bilinçli farkındalığın soruları yanıtlarken etkili olduğunu ortaya koymaktadır. Yapılan analizlerde, birinci ve ikinci sorulara ait verilerin sınıflandırılmasında en yüksek başarıyı gösteren model Bayes Sınıflandırma Algoritması olmuştur. Bayes modeliyle, her iki soruda da en yüksek doğruluk ve tutarlı sonuçlar elde edilmiştir. Özellikle, modelin yanlış pozitif ve yanlış negatif oranlarının düşük olması,

yüksek doğruluk oranları ile sonuçlanmıştır. Diğer modellerle karşılaştırıldığında, Bayes algoritması hem test hem de eğitim verisi üzerinde üstün bir performans sergilemiştir. Araştırmadaki bulgulara göre, her iki soruda da Bayes Sınıflandırma Algoritması en başarılı model olarak öne çıkmıştır. Aynı zamanda, her iki soru için de önemli olan dalga boyları, beta ve gama olarak belirlenmiştir. Bu tutarlılık, dikkat becerilerinin EEG sinyalleri üzerinden değerlendirildiğinde benzer sonuçlar elde edilebileceğini ve Bayes Sınıflandırma Algoritması'nın bu tür analizlerde güvenilir bir yöntem olduğunu göstermektedir.

Bu çalışmada EEG sinyalleri kullanılarak dikkat becerilerinin değerlendirilmesi üzerine odaklanılmıştır. Sonuçlar hem birinci hem de ikinci soruda benzer dalga boylarının önemli olduğunu ve Bayes Sınıflandırma Algoritması'nın en yüksek başarıyı sağladığını göstermektedir. Bu bulgular, daha önce yapılan çalışmalarda da benzer şekilde dikkat süreçleriyle ilişkili olarak beta ve gama dalgalarının önemli olduğunu desteklemektedir (Newson & Thiagarajan, 2019; Bazanova & Vernon, 2014). Ayrıca, Bayes Sınıflandırma Algoritması'nın EEG verileri üzerinde yapılan diğer çalışmalarda da yüksek performans gösterdiği literatürde sıkça belirtilmektedir (Kononenko, 1990). Veriler sosyal duygusal öğrenme becerilerinin çalışıldığı daha geniş kapsamlı bir araştırmada toplanmıştır. Bu çalışmanın bağlamında katılımcılara video izletildikten sonra yöneltilen iki soruya verdikleri cevapların doğruluğunun dikkatleriyle ne kadar ilişkili olduğunu bakılmıştır. Bu bağlamda, katılımcıların videoları izlerken sergiledikleri dikkat seviyesinin, yanıtların doğruluğuna etkisinin olup olmadığı araştırılmıştır. Bu araştırma, bireylerin sosyal ve duygusal öğrenme süreçlerinde dikkatlerinin oynadığı rolü anlamaya yönelik önemli bulgular sunmayı amaçlamaktadır.

Bu çalışma, EEG verilerinin eğitimde dikkat süreçlerinin izlenmesi ve değerlendirilmesi açısından büyük bir potansiyele sahip olduğunu ortaya koymaktadır. Eğitimde kullanılan geleneksel dikkat ölçüm yöntemlerinin yetersiz kaldığı durumlarda, EEG verileriyle sağlanan objektif veriler, eğitim süreçlerinin daha verimli bir şekilde yönetilmesine olanak tanımaktadır. Bu durum, öğrencilerin dikkat seviyelerinin anlık olarak izlenmesi ve bu verilerin analiz edilmesiyle, eğitimde daha etkili stratejilerin geliştirilmesine katkıda bulunabilir. Eğitimde nörobilimsel yaklaşımların benimsenmesi ve öğrenci performansının artırılması açısından önemli bir referans noktası oluşturmaktadır. EEG'nin sunduğu bu imkan, özellikle çevrimiçi öğrenme ortamlarında, öğrenci dikkat seviyelerinin sürekli olarak izlenmesini mümkün kılarak öğrenci performansının artırılmasına yönelik önemli bir araç sunmaktadır.

Bu çalışmanın bulguları doğrultusunda geliştirilen öneriler şu şekilde sıralanabilir. Öğrencilerin dikkat seviyelerini artırmak ve dikkat süreçlerini iyileştirmek amacıyla daha etkileşimli ve ilgi çekici eğitim materyalleri geliştirilmelidir. Özellikle çevrimiçi eğitim ortamlarında, videoların daha dinamik ve etkileşimli hale getirilmesi, öğrencilerin dikkatini daha uzun süre korumalarına yardımcı olabilir. Bu tür materyallerin geliştirilmesi, öğrencilerin bilişsel süreçlerini destekleyerek, öğrenme performanslarını artıracaktır. Eğitimciler, öğrencilerin bireysel dikkat seviyelerindeki farklılıkları göz önünde bulundurarak kişiselleştirilmiş eğitim programları oluşturabilir, EEG verileri ile izlenen dikkat seviyelerine göre öğrencilere özgü eğitim programları geliştirilerek, dikkat eksikliği sorunları minimize edilebilir. Bu tür programlar, öğrencilerin bireysel ihtiyaçlarına daha iyi cevap verebilir ve eğitimde başarıyı artırabilir. Öğrencilere özel olarak tasarlanmış bu programlar, onların dikkat seviyelerini optimize ederek, öğrenme süreçlerini daha etkili hale getirecektir. EEG verilerinin analizinde ortaya çıkan hataların etkisini azaltmak amacıyla daha gelişmiş veri temizleme tekniklerinin kullanılması gerekmektedir. Bu, model performansının iyileştirilmesine ve daha doğru sonuçlar elde edilmesine katkı sağlayacaktır. Verilerin doğru ve güvenilir bir şekilde analiz edilebilmesi için, bu tekniklerin kullanımı kritik öneme sahiptir. Gelişmiş veri temizleme yöntemleri, EEG verilerinin daha doğru bir şekilde değerlendirilmesini sağlayarak, analiz sonuçlarının doğruluğunu artıracaktır. Gelecekteki çalışmalar için daha geniş örneklem gruplarından elde edilen veri setlerinin kullanılması önerilmektedir. Büyük veri setleri, modellerin genel performansını artırarak daha güvenilir sonuçlar elde edilmesine olanak tanıyacaktır. Daha geniş örneklem gruplarının kullanımı, elde edilen sonuçların genelleştirilebilirliğini artırarak, eğitimde dikkat süreçlerinin daha doğru bir şekilde değerlendirilmesine katkıda bulunacaktır.

# KAYNAKLAR


Agrawal, R., & Srikant, R. (1994). Fast algorithms for mining association rules. Proceedings of the 20th International Conference on Very Large Data Bases, 487-499.

Aidman, E. (2020). Cognitive fitness framework: Towards assessing, training and augmenting individual-difference factors underpinning high-performance cognition. *Frontiers in Human Neuroscience, 13*. https://doi.org/10.3389/fnhum.2019.00466

Akpınar, H. (2017). *Data: Veri madenciliği veri analizi.* İstanbul: Papatya.

Alan, A., & Karabatak, M. (2020). Veri seti - sınıflandırma ilişkisinde performansa etki eden faktörlerin değerlendirilmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 32*(3), 531-540. https://doi.org/10.35234/fumbd.738007

Aldaghri, F., & Oraif, A. (2022). The impact of communication technology advances and the COVID-19 pandemic on student engagement in distance learning environments. *Journal of Education and Technology, 45*(3), 123-136.

Allen, P. J., Josephs, O., & Turner, R. (2000). A method for removing imaging artifact from continuous EEG recorded during functional MRI. *NeuroImage, 12*, 230-239. https://doi.org/10.1006/nimg.2000.0599

Allport, D. A. (1989). Visual attention. In M. I. Posner (Ed.), *Foundations of Cognitive Science 2*, 631-682. MIT Press.

Başar, E. (2013). Brain Oscillations in Learning and Memory. *International Journal of Psychophysiology*, 39(3), 211-218.

Bazanova, O. M., & Vernon, D. (2014). Interpreting EEG alpha activity. *Neuroscience & Biobehavioral Reviews, 44*, 94-110. https://doi.org/10.1016/j.neubiorev.2013.05.007

Berger, H. (1929). Über das Elektrenkephalogramm des Menschen. *Archiv für Psychiatrie und Nervenkrankheiten*, *87*(1), 527-570.

Biggs, D., De Ville, B., & Suen, E. (1991). A method of choosing multiway partitions for classification and decision trees. *Journal of Applied Statistics*, *18*(1), 49-62.

Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.

Bion, W. R. (2013). *Attention and interpretation: A scientific approach to insight in psycho-analysis and groups*. Karnac Books.

Bridwell, D. A., Cavanagh, J. F., Collins, A. G. E., Nunez, M. D., Srinivasan, R., & Stober, S. (2018). Moving beyond ERP components: A selective review of approaches to integrate EEG and behavior. *Frontiers in Human Neuroscience*, 12, 106.

Broomhead, D. S., & Lowe, D. (1988). Multivariable functional interpolation and adaptive networks. *Complex Systems*, *2*(3), 321-355.

Campos, I. S., Almeida, L. S., & Ferreira, A. I. (2013). Cognitive processes and math performance: A study with children at third grade of basic education. *European Journal of Psychology of Education*, *28*(3), 545-555. https://link.springer.com/article/10.1007/s10212-012-0121-x

Cartwright, K. B. (2012). Insights from cognitive neuroscience: The importance of executive function for early reading development and education. *Early Education & Development*, *23*(1), 24-48.

Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). *CRISP-DM 1.0: Step-by-step data mining guide*. SPSS Inc.

Chen, C. M., Wang, J. Y., & Yu, C. M. (2017). Assessing the attention levels of students by using a novel attention aware system based on brainwave signals. *British Journal of Educational Technology*. Wiley Online Library.

Chen, H., Song, Y., & Li, X. L. (2019). A deep learning framework for identifying children with ADHD using an EEG-based brain network. *Neurocomputing*, *356*, 83-96. https://doi.org/10.1016/j.neucom.2019.04.058

Chiang, H. S., Hsiao, K. L., & Liu, L. C. (2018). EEG-based detection model for evaluating and improving learning attention. *Journal of Medical and Biological Engineering, 38*(5), 750-759. https://doi.org/10.1007/s40846-017-0344-z

Cinquin, P. A., Guitton, P., & Sauzéon, H. (2019). Online e-learning and cognitive disabilities: A systematic review. *Computers & Education, 130*, 152-167. https://doi.org/10.1016/j.compedu.2018.12.004

Colombo, J. (2001). The development of visual attention in infancy. *Annual Review of Psychology, 52,* 337–367. https://doi.org/10.1146/annurev.psych.52.1.337

Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, *20*(3), 273-297.

Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory, 13*(1), 21-27.

Crawford, S. L. (1989). Extensions to the CART algorithm. *International Journal of Man-Machine Studies, 31*(2), 197-217.

Da Silva, M. R. D., Gonçalves, Ó. F., Branco, D., & Carvalho, S. (2022). Revisiting consciousness: Distinguishing between states of conscious focused attention and mind wandering with EEG. *Consciousness and Cognition, 101*, 103317. https://www.sciencedirect.com/science/article/pii/S1053810022000642

Dijksterhuis, A., & Aarts, H. (2010). Goals, attention, and (un)consciousness. *Annual Review of Psychology, 61*, 467–490.

Draper, N. R., & Smith, H. (1998). *Applied regression analysis* (3rd ed.). Wiley-Interscience.

Duncan, G. J., & Magnuson, K. (2011). The nature and impact of early achievement skills, attention skills, and behavior problems. In *Whither Opportunity*.

Dunham, M.H. (2003). *Data mining: Introductory and advanced topics.* New Jersey: Pearson Education.

Dvorsky, M. R., Marsh, N. P., & Sciberras, E. (2020). Remote learning during COVID-19: Examining school practices, service continuation, and difficulties for adolescents with and without attention-deficit/hyperactivity disorder. *Journal of Adolescent Health*, 67(5), 769-777. https://doi.org/10.1016/j.jadohealth.2020.08.001

Eckstein, M. K., Guerra-Carrillo, B., Miller Singley, A. T., & Bunge, S. A. (2017). Beyond eye gaze: What else can eyetracking reveal about cognition and cognitive

development? *Developmental Cognitive Neuroscience, 25*, 69–91. https://doi.org/10.1016/j.dcn.2016.11.001

Elsayed, N., Zaghloul, Z. S., & Bayoumi, M. (2017). Brain computer interface: EEG signal preprocessing issues and solutions. *International Journal of Computer Applications*, *169*(8), 1-7. https://doi.org/10.5120/ijca2017915450

Enriquez-Geppert, S., Huster, R. J., & Herrmann, C. S. (2017). EEG-Neurofeedback as a tool to modulate cognition and behavior: A review tutorial. *Frontiers in Human Neuroscience, 11*. https://doi.org/10.3389/fnhum.2017.00051

Ersöz, F., & Ersöz, T. (2019). *Veri madenciliği teknikleri ve uygulamaları*. Seçkin.

Ester, M., Kriegel, H. P., Sander, J., & Xu, X. (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. Proceedings of the 2nd International Conference on Knowledge Discovery and Data Mining, 226-231.

Ewe, L. P. (2019). ADHD symptoms and the teacher–student relationship: A systematic literature review. *Emotional and Behavioural Difficulties*, *24*(2), 136-151. https://doi.org/10.1080/13632752.2019.1597562

Farnsworth, B. (2019). *EEG (Electroencephalography): The complete pocket guide*. iMotions. https://imotions.com/blog/eeg/

Fayyad, U., Piatetsky-Shapiro, G., Smyth, P., & Uthurusamy, R. (1996). *Advances in knowledge discovery and data mining.* AAAI/MIT Press.

Ganesh, S. (2002). Data mining: Should it be included in the statistics curriculum? In *The 6th International Conference on Teaching Statistics (ICOTS-6)*. Cape Town, South Africa.

Ghasemi, E., Ebrahimi, M., & Ebrahimie, E. (2022). Machine learning models effectively distinguish attention-deficit/hyperactivity disorder using event-related potentials. Cognitive Neurodynamics. https://link.springer.com/article/10.1007/s11571-021-09746-2

Giudici, P. (2003). *Applied Data Mining: Statistical Methods for Business and Industry*. John Wiley & Sons.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

Gül, M., & Çeliköz, N. (2023). Farklı değişkenlerin öğrencilerin düşünme süreçlerine yansımaları. *Kahramanmaraş Sütçü İmam Üniversitesi Sosyal Bilimler Dergisi, 20*(1), 1-20.

Han, J. W., Kamber, M., & Pei, J. (2012). *Data mining concepts and techniques* (3rd ed.). Morgan Kaufmann Publishers, 350

Han, J., Pei, J., & Yin, Y. (2000). Mining frequent patterns without candidate generation. Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data, 1-12.

Hajebrahimi, F., Velioglu, H. A., & Bayraktaroglu, Z. (2022). Clinical evaluation and resting state fMRI analysis of virtual reality based training in Parkinson's disease through a randomized controlled trial. *Scientific Reports*, *12*, 12061.

Hanushek, E. A., & Woessmann, L. (2012). Do better schools lead to more growth? Cognitive skills, economic outcomes, and causation. *Journal of Economic Growth, 17*(4), 267-321. https://doi.org/10.1007/s10887-012-9081-x

Harmony, T., Fernández, T., Silva, J., Bernal, J., Díaz-Comas, L., Reyes, A., ... & Rodríguez, M. (1996). EEG delta activity: An indicator of attention to internal processing during performance of mental tasks. *International Journal of Psychophysiology, 24*(1-2), 161-171. https://doi.org/10.1016/S0167-8760(96)00053-0

Hauser, R., Bajaj, N., Marek, K., Seibyl, J., Kupsch, A., Plotkin, M., Lin, T., & Grachev, I. (2014). Sensitivity, specificity, positive and negative predictive values and diagnostic accuracy of DaTscan™ (Ioflupane I123 Injection): Predicting clinical diagnosis in early clinically uncert. ain parkinsonian syndrome. *Journal of Neurology & Stroke, 1*(1), 7-20. https://doi.org/10.15406/jnsk.2014.01.00003

Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Prentice Hall.

Heckerman, D., Geiger, D., & Chickering, D. (1995). Learning Bayesian networks: The combination of knowledge and statistical data. *Machine Learning, 20*(3), 197-243. https://doi.org/10.1007/BF00994016

Hollands, F., & Bakir, I. (2015). Efficiency of automated detectors of learner engagement and affect compared with traditional observation methods. *New York, NY: Center for Benefit-Cost Studies.*

Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied Logistic Regression* (3rd ed.). Wiley.

Hossin, M., & Sulaiman, M.N. (2015). A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process. 5*, 1-11.

iMotions. (n.d.). *İMotions 8*. iMotions. https://imotions.com/products/hardware/iMotions-8/

Jain, H., Khunteta, A., & Srivastava, S. (2021). Telecom churn prediction using seven machine learning experiments integrating feature engineering and normalization. *Computer Science School of Basic and Applied Sciences*, Poornima University.

Jangmo, A., Stålhandske, A., Chang, Z., Chen, Q., Almqvist, C., Feldman, I., ... & D'Onofrio, B. M. (2019). Attention-deficit/hyperactivity disorder, school performance, and effect of medication. *Journal of the American Academy of Child & Adolescent Psychiatry*, *58*(4), 423-432. https://doi.org/10.1016/j.jaac.2018.11.014

James, W. (1890). *The principles of psychology*. Henry Holt and Co.

Jackson, A. F., & Bolger, D. J. (2014). The neurophysiological bases of EEG and EEG measurement: A review for the rest of us. *Psychophysiology*, 51(11), 1061-1071. https://doi.org/10.1111/psyp.12283

Johnson, K. A., Robertson, I. H., Kelly, S. P., Silk, T. J., Barry, E., Dáibhis, A., ... & Gill, M. (2007). Dissociation in performance of children with ADHD and high-functioning autism on a task of sustained attention. *Neuropsychologia*, *45*(9), 1907-1920.

Johnson, M., Smith, T., & Wang, M. (2021). Evaluating online learning environments. *Journal of Educational Psychology*, *48*(2), 215-230.

Johnston, W. A., & Dark, V. J. (1986). Selective attention. *Annual Review of Psychology*, *37*(1), 43-75. https://doi.org/10.1146/annurev.ps.37.020186.000355

Kahraman, N. (2020). SESHAT Araştırma Grubu TÜBİTAK 1001 Projesi Laboratuvar Uygulamaları. https://www.niluferkahraman.com/uygulamalar-bahar-24 sayfasından erişilmiştir.

Karaduman, D. (2004). *Dikkat toplama eğitimi programının ilköğretim 4. ve 5. sınıf öğrencilerinin dikkat toplama düzeyi benlik algısı ve başarı düzeylerine etkisi.* Doktora tezi, Ankara Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara.

Karasar, N. (2011). *Bilimsel araştırma yöntemi*. Nobel.

Kass, G. V. (1980). An exploratory technique for investigating large quantities of categorical data. *Journal of the Royal Statistical Society: Series C (Applied Statistics), 29*(2), 119-127.

Katz, B., Shah, P., & Meyer, D. E. (2018). How to play 20 questions with nature and lose: Reflections on 100 years of brain-training research. *Proceedings of the National Academy of Sciences of the United States of America, 115*(40), 9897-9904. https://doi.org/10.1073/pnas.1617102114

Kim, Y., Cha, Y., & Kim, M. (2018). Attention assessment via EEG data analysis using LSTM-based deep learning. *IEEE Access*, 6, 12022-12030.

Klimesch, W. (1999). EEG alpha and Teta oscillations reflect cognitive and memory performance: A review and analysis. *Brain Research Reviews, 29*(2-3), 169-195. https://doi.org/10.1016/S0165-0173(98)00056-3

Knyazev, G. G. (2007). Motivation, emotion, and their inhibitory control mirrored in brain oscillations. *Neuroscience & Biobehavioral Reviews, 31*(3), 377-395. https://doi.org/10.1016/j.neubiorev.2006.10.004

Ko, L.-W., Komarov, O., Hairston, W. D., Jung, T.-P., & Lin, C.-T. (2017). Sustained attention in real classroom settings: An EEG study. *Frontiers in Human Neuroscience, 11*. https://doi.org/10.3389/fnhum.2017.00388

Kononenko, I. (1990). Comparison of inductive and naive Bayesian learning approaches to automatic knowledge acquisition. *Current Trends in Knowledge Acquisition, 2,* 190-197.

Kotsiantis, S. B. (2007). Supervised machine learning: A review of classification techniques. *Informatica, 31,* 249-268.

Krigolson, O. E., Williams, C. C., Norton, A., Hassall, C. D., & Colino, F. L. (2017). Choosing MUSE: Validation of a low-cost portable EEG system for ERP research. *Frontiers in Neuroscience, 11,* 109. https://doi.org/10.3389/fnins.2017.00109

Layton, T. J., Barnett, M. L., & Hicks, T. R. (2018). Attention deficit–hyperactivity disorder and month of school enrollment. *New England Journal of Medicine*. https://doi.org/10.1056/NEJMoa1806828

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436-444.

Liang, X., Liu, Y., & Wang, J. (2020). The impact of cognitive abilities on academic performance during online learning. *Educational Psychology Review*, *32*(1), 123-145

Lim, C. G., Poh, X. W. W., Fung, S. S. D., Guan, C., Bautista, D., Cheung, Y. B., Zhang, H., Yeo, S. N., Krishnan, R., & Lee, T. S. (2019). A randomized controlled trial of a brain-computer interface based attention training program for ADHD. *PloS one*, *14*(5). https://doi.org/10.1371/journal.pone.0216225

Liu, C., Chiang, W., & Chu, Y. (2013). Recognizing the degree of human attention using EEG signals from mobile sensors. *Sensors*, *13*(8), 10273-10286. https://doi.org/10.3390/s130810273

Liu, Y., Sourina, O., & Nguyen, M. K. (2017). Real-time EEG-based human emotion recognition and visualization. *IEEE Computer Graphics and Applications*, *37*(3), 66-73.

Liu, X., & Wang, Y. (2018). Cognitive performance and learning strategies in online learning environments. *Journal of Educational Technology*, *49*(3), 75-83.

Luck, S. J. (2014). *An introduction to the event-related potential technique* (2nd ed.). MIT Press.

Lundqvist, M., Herman, P., & Miller, E. K. (2016). Beta bursts: Cognitive control in short-term memory tasks. *Trends in Cognitive Sciences*, *20*(11), 1008-1017.

Markovska-Simoska, S., & Pop-Jordanova, N. (2018). Inter-and intra-hemispheric EEG coherence study in adults with neuropsychiatric disorders. *Prilozi*, *39*(3), 27-39. https://sciendo.com/pdf/10.2478/prilozi-2018-0037

Makeig, S., Bell, A. J., Jung, T. P., & Sejnowski, T. J. (1996). Independent component analysis of electroencephalographic data. *Advances in Neural Information Processing Systems*, *8*, 145-151.

MacQueen, J. B. (1967). Some methods for classification and analysis of multivariate observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, *1*, 281-297.

McCallum, A., & Nigam, K. (1998). A comparison of event models for naive bayes text classification. *AAAI Conference on Artificial Intelligence.*

Menard, S. (2002). *Applied logistic regression analysis*. Sage.

Miller, E. K., & Lundqvist, M. (2014). Gama oscillations: Coordinating sensory processing and cognitive tasks. *Neuron, 82*(4), 878-890.

Monteil, J. M., Brunot, S., & Huguet, P. (1996). Cognitive performance and attention in the classroom: An interaction between past and present academic experiences. *Journal of Educational Psychology, 88*(2), 242-250. https://psycnet.apa.org/record/1996-01756-004

Murtagh, F., & Contreras, P. (2012). Algorithms for hierarchical clustering: an overview. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, *2*(1), 86-97.

Newson, J. J., & Thiagarajan, T. C. (2019). EEG frequency bands in psychiatric disorders: A review of resting state studies. *Frontiers in Human Neuroscience*, *12*, 521. https://www.frontiersin.org/articles/10.3389/fnhum.2018.00521/full

Ni, D., Wang, S., & Liu, G. (2020). The EEG-Based Attention Analysis in Multimedia m-Learning. *Computational and Mathematical Methods in Medicine*.

Niedermeyer, E., & da Silva, F. L. (2005). Electroencephalography: Basic principles, clinical applications, and related fields. Lippincott Williams & Wilkins.

Nolan, H., Whelan, R., & Reilly, R. B. (2010). FASTER: Fully automated statistical thresholding for EEG artifact rejection. *Journal of Neuroscience Methods, 192*(1), 152-162.

Pamina, J., & Beschi Raja, J., (2019). An effective classifier for predicting churn in telecommunication. *Journal of Advanced Research in Dynamical and Control Systems, 11*, 221–229.

Park, J. L., Dudchenko, P. A., & Donaldson, D. I. (2018). Navigation in real-world environments: New opportunities afforded by advances in mobile brain imaging. *Frontiers in Human Neuroscience*, *12*, 361

Peck, R., Olsen, C., & Devore, J. (2008). *Introduction to Statistics and Data Analysis* (3rd ed.). Thomson Brooks/Cole.

Pelgrim, M. H., Espinosa, J., & Buchsbaum, D. (2023). Head-mounted mobile eye-tracking in the domestic dog: A new method. *Behavior Research Methods*.

Pinilla, A., Garcia, J., Raffe, W., & Voigt-Antons, J. N. (2021). *Affective visualization in virtual reality: An integrative review*. Frontiers in Virtual Reality, *2*, 630731.

Pizzagalli, D. A. (2007). Beta Oscillations: Mechanisms and Functional Significance. *Brain Oscillations and Cognitive Processes*, 34(2), 45-56.

Poissant, H., Mendrek, A., & Talbot, N. (2019). Behavioral and cognitive impacts of mindfulness-based interventions on adults with attention-deficit hyperactivity disorder: A systematic review. *Behavioural Sciences*, *9*(7), 82. https://doi.org/10.1155/2019/5682050

Posner, M. I. & Cohen, Y. (1984). Components of visual orienting. *Attention and Performance X*. *32*, 531-556.

Posner, M. I., & Fan, J. (2008). Development of attentional networks. In V. A. C. Bouma & D. Bowhuis (Eds.), *Attention and performance X*. 531-556.

Posner, M. I., & Petersen, S. E. (1990). The attention system of the human brain. *Annual Review of Neuroscience, 13*, 25-42. doi: 10.1146/annurev.ne.13.030190.000325.

Quinlan, J. R. (1993). *C4.5: Programs for Machine Learning*. Morgan Kaufmann.

Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, *1*(1), 81-106.

Ouyang, G., Hildebrandt, A., Schmitz, F., & Herrmann, C. S. (2020). Decomposing alpha and 1/f brain activities reveals their differential associations with cognitive processing speed. *NeuroImage*, *205*, 116304.

Özkan, Y. (2008). *Veri Madenciliği Yöntemleri*. Papatya.

Rahman, M. M., & Fattah, S. A. (2020). An efficient feature extraction scheme for classification of mental tasks based on inter-channel correlation in wavelet domain

utilizing EEG signal. *Biomedical Signal Processing and Control*, 61. DOI:10.1016/j.bspc.2020.102033

Realyvásquez-Vargas, A., Maldonado-Macías, A. A., Arredondo-Soto, K. C., Baez-Lopez, Y. A., Carrillo-Gutiérrez, T., & Hernández-Escobedo, G. (2020). The impact of environmental factors on academic performance of university students taking online classes during the COVID-19 pandemic in Mexico. *Sustainability, 12*(21), 9194. https://doi.org/10.3390/su12219194

Rish, I. (2001). An empirical study of the naive Bayes classifier. *IJCAI 2001 Workshop on Empirical Methods in Artificial Intelligence*, *3*(22), 41-46.

Rokach, L., & Maimon, O. (2015). *Data Mining with Decision Trees: Theory and Applications*. World Scientific Publishing Company.

Rothbart, M. K., & Posner, M. I. (2001). Mechanisms and variation in the development of attentional networks. In C. A. Nelson & M. Luciana (Eds.), *Handbook of developmental cognitive neuroscience*. 353-363

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, *323*(6088), 533-536.

Rupp, G., Berka, C., Meghdadi, A., & McConnell, M. C. (2019). EEG acquisition during the VR administration of resting state, attention, and image recognition tasks: a feasibility study. *HCI International 2019*

Samimisabet, P., Krieger, L., Nethar, T., & Pipa, G. (2023). Introducing a new mobile electroencephalography system and evaluating its quality in comparison to clinical electroencephalography. *Sensors, 23*(17), 7440. https://doi.org/10.3390/s23177440

Sammut, C., & Webb, G. I. (Eds.). (2011). *Encyclopedia of Machine Learning*. Springer. https://doi.org/10.1007/978-0-387-30164-8

Seber, G. A. F., & Lee, A. J. (2012). *Linear regression analysis*. John Wiley & Sons.

Sezer, A., İnel, Y., Seçkin, A. Ç., & Uluçınar, U. (2017). The relationship between attention levels and class participation of first-year students in classroom teaching departments. *International Journal of Instruction, 10*, 55-68. DOI:10.12973/iji.2017.1024a

Shah, R., Raju, V. V., & Sharma, A. (2021). Impact of COVID-19 and lockdown on children with ADHD and their families—an online survey and a continuity care model. *Journal of Neurosciences in Rural Practice*, *12*(4), 556-563. https://doi.org/10.1055/s-0040-1718645

Shearer, C. (2000). The CRISP-DM model: The new blueprint for data mining. *Journal of Data Warehousing, 5*(4), 13-22.

Sherif, M., & Sherif, C. W. (1969). *Social Psychology*. Harper & Row.

Shernoff, D. J., Kelly, S., Tonks, S. M., Anderson, B., Cavanagh, R. F., & Sinha, S. (2016). Student engagement as a function of environmental complexity in high school classrooms. *Learning and Instruction, 43*, 52-60. https://www.sciencedirect.com/science/article/pii/S0959475215300451

Shi, Y., Zhu, Y., Mehta, R. K., & Du, J. (2020). A neurophysiological approach to assess training outcome under stress: A virtual reality experiment of industrial shutdown maintenance using Functional Near-Infrared Spectroscopy. *Advanced Engineering Informatics, 46*, 101148.

Smith, E. E., & Kosslyn, S. M. (2010). *Cognitive psychology: Mind and brain*. Pearson.

Soler, A., Moctezuma, L. A., Giraldo, E., & Castellanos-Domínguez, G. (2022). Automated methodology for optimal selection of minimum electrode subsets for accurate EEG source estimation based on genetic algorithm optimization. *Scientific Reports, 12*(1), 11221. https://doi.org/10.1038/s41598-022-15252-0

Soufineyestani, M., Dowling, D., & Khan, A. (2020). Electroencephalography (EEG) technology applications and available devices. *Applied Sciences, 10*(21), 7453. https://doi.org/10.3390/app10217453

Sternberg, R. J. (1996). *Cognitive psychology* (2nd ed.). Wadsworth Publishing.

Stevens, C., & Bavelier, D. (2012). The role of selective attention on academic foundations: A cognitive neuroscience perspective. *Developmental Cognitive Neuroscience, 2*(1), 30-40. https://www.sciencedirect.com/science/article/pii/S1878929311001101

Stikic, M., Johnson, R. R., Levendowski, D. J., Popovic, D. P., Olmstead, R. E., & Berka, C. (2011). EEG-derived estimators of present and future cognitive performance. *Frontiers in Human Neuroscience, 5*, 70. https://doi.org/10.3389/fnhum.2011.00070

Sürmeli, T. (2010). *Beynin iyileştirme gücü*. İstanbul: Nobel Matbaacılık.

Szafir, D., & Mutlu, B. (2012). Pay attention! Designing adaptive agents that monitor and improve user engagement. *In Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. https://doi.org/10.1145/2207676.2207679

Szczytko, R., Carrier, S. J., & Stevenson, K. T. (2018). Impacts of outdoor environmental education on teacher reports of attention, behavior, and learning outcomes for students with emotional, cognitive, and behavioral disabilities. *Frontiers in Education, 3*(46). https://doi.org/10.3389/feduc.2018.00046

Tauriainen, S. (2022). Unraveling dynamics of brain activation in ADHD children with a novel open-ended virtual reality task. *Aalto University*.

Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B (Methodological), 58*(1), 267-288.

Ullah, I., Raza, B., Malik, A. K., Imran, M., Islam, S. U., & Kim, S. W. (2019). A churn prediction model using random forest: Analysis of machine learning techniques for churn prediction and factor identification in telecom sector. *IEEE Access*, 7, 60134–60149. https://doi.org/10.1109/ACCESS.2019.2914999

Varbu, K., Muhammad, N., & Muhammad, Y. (2022). Past present and future of EEG-based BCI applications. *Sensors, 22*(9), 3331. https://doi.org/10.3390/s22093331

Vortmann, L. M., Schwenke, L., & Putze, F. (2021). Using brain activity patterns to differentiate real and virtual attended targets during augmented reality scenarios. *Information*, 12(6), 226.

Weisberg, S. (2005). *Applied linear regression*. Wiley.

Wendler, T., & Gröttrup, S. (2021). *Data Mining with SPSS Modeler: Theory, Exercises and Solutions*. Springer.

West, M. R., Kraft, M. A., Finn, A. S., & Martin, R. E. (2016). Promise and paradox: Measuring students' non-cognitive skills and the impact of schooling. *Educational Evaluation and Policy Analysis, 38*(1), 148-170. https://doi.org/10.3102/0162373715597298

Wikipedia. (2023, Mayıs 10). *İki Dil Bir Bavul*. Wikipedia. https://tr.wikipedia.org/wiki/%C4%B0ki_Dil_Bir_Bavul

Wirth, R., & Hipp, J. (2000). CRISP-DM: Towards a standard process model for data mining. *In Proceedings of the Fourth International Conference on the Practical Application of Knowledge Discovery and Data Mining*, 29-39.

Wolraich, M. L., Hagan, J. F., Allan, C., Chan, E., Davison, D., Earls, M., ... & Zurhellen, W. (2019). Clinical practice guideline for the diagnosis, evaluation, and treatment of attention-deficit/hyperactivity disorder in children and adolescents. *Pediatrics*, *144*(4), e20192528. https://doi.org/10.1542/peds.2019-2528

Wooldridge, J. M. (2016). *Introductory econometrics: A modern approach*. Cengage Learning.

Woltz, D. J., Gardner, M. K., & Gyll, S. P. (2000). The role of attention processes in near transfer of cognitive skills. *Learning and Individual Differences, 12*(3), 259-279. https://www.sciencedirect.com/science/article/pii/S1041608001000383

Xu, W., Liu, X., & Song, Y. (2023). Recognizing attention levels using a multi-level approach with EEG signals. *IEEE Transactions on Affective Computing, 14*(1), 67-78.

Yang, K., Tong, L., Shu, J., Zhuang, N., & Yan, B. (2020). High Gama band EEG closely related to emotion: Evidence from functional network. *Frontiers in Human Neuroscience*, 14, 89. https://doi.org/10.3389/fnhum.2020.00089

Yin, S., Pan, Y., & Song, X. (2017). The impact of physical activity on cognitive performance and academic achievement. *Journal of Educational Psychology, 109*(1), 83-95.

Zhu, L., & Lv, J. (2023). Review of studies on user research based on EEG and eye tracking. *Applied Sciences, 13*(11), 6502.

# EKLER

# EK 1. Etik Kurul Belgesi

**T.C.**
**GAZİ ÜNİVERSİTESİ**
**Etik Komisyonu**

Sayı : 77082166-604.01.02-
Konu : Değerlendirme ve Onay

**Sayın Doç. Dr. Nilüfer KAHRAMAN**
**Eğitimde Ölçme ve Değerlendirme Anabilim Dalı Başkanlığı - Öğretim Üyesi**

Üniversitemiz Etik Komisyonu'na verilen ***"Biyometrik Ölçme Araçları İle Desteklenmiş Bir Meta-Bilişsel Yetkinlikler E-Envanteri Geliştirme Projesi"*** başlıklı araştırma öneriniz Komisyonumuzun **05.06.2018** tarih ve **05** sayılı toplantısında görüşülmüş olup,

Çalışmanızın, yapılması planlanan yerlerden izin alınması koşuluyla yapılmasında etik açıdan bir sakınca bulunmadığına oybirliği ile karar verilmiş ve karara ilişkin imza listesi ekte gönderilmiştir.

Bilgilerinizi rica ederim.

**e-imzalıdır**
**Prof. Dr. Alper CEYLAN**
**Komisyon Başkanı**

Araştırma Kod No: 2018-237

Ek:1 Liste



*GAZİLİ OLMAK AYRICALIKTIR.*