

# Karmaşıklık Ölçme Yöntemleri ve Makine Öğrenimi ile EEG Sinyallerinin Karmaşıklık Ölçülerek Dikkat Eksikliği ve Hiperaktivite Bozukluğu Tespiti

## Complexity Measurement Methods and Detection of Attention Deficit Hyperactivity Disorder by Measuring the Complexity of EEG Signals with Machine Learning

Efe Ali MERT

İstek Bilge Kağan Anadolu Lisesi, İstanbul, Türkiye

### Özet

Bu çalışmada, Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB) tanısında elektroensefalografi (EEG) sinyallerinin gelişmiş topluluk makine öğrenmesi (Advanced Ensemble Machine Learning) yaklaşımları ile analizi gerçekleştirilmiştir. 60 Hertz kesme filtresi (60 Hz Notch Filter) kullanılarak, 121 kişilik (61 DEHB, 60 kontrol) kapsamlı veri kümesi üzerinde çoklu karmaşıklık analizi (Multi-Complexity Analysis) ve gelişmiş topluluk sınıflandırma metodolojisi uygulanmıştır. Geliştirilmiş Higuchi Fraktal Boyutu (Enhanced Higuchi Fractal Dimension), Güç Spektral Özellikleri (Power Spectral Features), Hjorth Parametreleri (Hjorth Parameters) ve İstatistiksel Özellikler (Statistical Features) gibi dört farklı özellik çıkarma yöntemi birleştirilerek her kişi için 399 özellik çıkarılmıştır. Yumuşak Oylama (Soft Voting) topluluk yaklaşımı en yüksek performansı göstererek %79.5 doğruluk (Accuracy) ve %79.0 F1-puanı (F1-Score) elde edilmiştir. 10 katmanlı çapraz doğrulama (10-Fold Cross-Validation) ile güçlü değerlendirme yapılmış ve tüm performans ölçütleri için güven aralıkları hesaplanmıştır. Bu çalışma, 60 Hertz güç hattı girişimi eliminasyonu ile DEHB-EEG analizinde yeni bir metodolojik standart belirleyerek, klinik uygulamaya yönelik yüksek doğruluklu nesnel tanı desteği sunmaktadır.

**Anahtar Kelimeler:** DEHB; EEG Analizi; Higuchi Fraktal Boyutu; Makine Öğrenimi; Topluluk Öğrenmesi

### Abstract

In this study, electroencephalography (EEG) signal analysis using advanced ensemble machine learning approaches was performed for Attention Deficit Hyperactivity Disorder (ADHD) diagnosis. Using a 60 Hertz notch filter, multi-complexity analysis and advanced ensemble classification methodology were applied to a comprehensive dataset of 121 individuals (61 ADHD, 60 control). Four different feature extraction methods including Enhanced Higuchi Fractal Dimension, Power Spectral Features, Hjorth Parameters, and Statistical Features were combined to extract 399 features per individual. The Soft Voting ensemble approach showed the highest performance, achieving 79.5% accuracy and 79.0% F1-score. Robust evaluation was performed with 10-fold cross-validation and confidence intervals were calculated for all performance metrics. This study establishes a new methodological standard in ADHD-EEG analysis through 60 Hertz power line interference elimination, providing high-accuracy objective diagnostic support for clinical applications.

**KeyWords:** ADHD; EEG Analysis; Higuchi Fractal Dimension; Machine Learning; Ensemble Learning

## 1. Giriş

Dikkat Eksikliği Hiperaktivite Bozukluğu (DEHB), çocuklarda en sık görülen nörogelişimsel bozukluklardan biridir ve aynı zamanda bu rahatsızlıklar arasında en sık yanlış teşhis edilenlerden biri olarak kabul edilir. Bu durum kısmen, tanı sürecinde kullanılan davranışsal gözlemlerin ve değerlendirme ölçeklerinin öznel ve keyfi yapısından kaynaklanmaktadır. Bu öznel ve niceliksel olmayan değerlendirme yöntemleri yanlış tanı riski taşımaktadır. Yanlış tanıya dayalı uygunsuz ilaç tedavisinin hastalar için uzun vadeli olumsuz sonuçlara yol açabileceği bilinmektedir. Bu çalışmanın temel amacı, elektroensefalogram (EEG) verilerini analiz etmek için gelişmiş topluluk makine öğrenmesi teknikleri kullanan nesnel ve niceliksel bir DEHB tanı tekniği geliştirmek ve böylece öznel değerlendirme yöntemleriyle ilişkili yanlış tanı riskini ortadan kaldırmaktır. Geleneksel tanı yöntemleri ve öznel davranışsal değerlendirme ölçekleri, farklı tanı uzmanlarının deneyim ve yorumlarına dayanmaktadır. Bu dinamik süreç, aşırı doz, uygunsuz tedavi ve uzun

vadeli psikolojik sonuçlar gibi olumsuz etkilere yol açabilen yanlış tanı riski taşımaktadır. EEG sinyallerinin beyin aktivitesini nesnel ve nicel olarak ölçebilmesi nedeniyle, DEHB tanısı için güvenilir biyobelirteçlerin elde edilebileceği varsayılmaktadır.


## 2. Metodoloji

### 2.1 Veri seti ve ön işleme


Bu çalışmada IEEE Dataport'tan alınan DEHB veri seti (ADHD Dataset) kullanılmıştır [23]. Veri seti 61 DEHB'li çocuk ve 60 sağlıklı çocukta oluşmaktadır. Yaş aralığı 7-12 yaş arasındadır. DEHB tanısında makine öğrenimi yöntemleri literatürde yaygın olarak kullanılmaktadır [23].

#### 2.1.1 EEG kayıt parametreleri

Bu çalışmada kullanılan EEG veri seti, standart 10-20 uluslararası elektrot yerleşim sistemi (10-20 International Electrode Placement System) göre 19 kanaldan kayıt edilmiştir. Kullanılan kanallar şunlardır: Fz, Cz, Pz, C3, T3, C4, T4, Fp1, Fp2, F3, F4, F7, F8, P3, P4, T5, T6, O1 ve O2. Bu kanal seçimi, beyin farklı bölgelerinden (frontal, central, parietal, temporal ve oksipital) bilgi toplayarak kapsamlı bir analiz sağlamaktadır. Örnekleme frekansı (Sampling Frequency) 128 Hertz olarak ayarlanmıştır. Ayrıca 60 Hertz kesme filtresi (60 Hz Notch Filter) uygulanarak güç hattı girişimi (Power Line Interference) eliminasyonu gerçekleştirilmiştir. Her kayıt 60 saniye sürmekte ve toplam 15,000 örnek noktası (Sample Points) içermektedir. Referans elektrotları olarak A1 ve A2 (kulak memesi) kullanılmıştır. Bu referans sistemi, standart klinik EEG uygulamalarında yaygın olarak kullanılan ve güvenilir sonuçlar veren bir yaklaşımdır.




**Figure 1.** DEHB EEG analizi için detaylı 19 kanal yerleşimi - Gerçek anatomik pozisyonlarla beyin ısı haritası görünümü



**Figure 2.** DEHB EEG aktivite ısı haritası - Aktivite paternleri (79.5% doğruluk, 121 denek)

### 2.1.2 60 Hertz standardında ön işleme adımları

EEG sinyallerine 60 Hertz standardında kapsamlı ön işleme adımları (Preprocessing Steps) uygulanmıştır. Bu süreç, sinyal kalitesini artırmak ve analiz sonuçlarının güvenilirliğini sağlamak için kritik öneme sahiptir. İlk olarak, 60 Hertz güç hattı frekansına karşı kesme filtresi (Notch Filter) uygulanmıştır. Bu filtre, elektrik şebekesinden kaynaklanan girişimi ortadan kaldırarak temiz EEG sinyali elde edilmesini sağlamaktadır. Ardından, veri formatı düzenleme işlemi (Data Format Conversion) gerçekleştirilmiştir. Matlab dosyalarından (19 × 15,000) matris formatında veri çıkarımı yapılarak, analiz için uygun hale getirilmiştir. Frekans alanında filtreleme işlemi (Frequency Domain Filtering) olarak, 0.5-60 Hertz aralığında bant geçiren filtre (Bandpass Filter) uygulanmıştır. Bu aralık, EEG sinyallerinde klinik olarak anlamlı olan delta, teta, alfa, beta ve gama dalga bantlarını kapsamaktadır. Düşük frekanslarda 0.5 Hertz alt sınırı, yavaş dalga aktivitesini korurken, üst sınır olan 60 Hertz ise yüksek frekanslı gürültüyü elimine etmektedir.



**Figure 3.** DEHB ve kontrol gruplarında EEG frekans bantları güç dağılımı

Artifact temizleme işlemi (Artifact Removal), 5 standart sapma eşiği (5 Standard Deviation Threshold) kullanılarak gerçekleştirilmiştir. Bu yöntem, aşırı değerlerin tespit edilmesini ve bunların medyan değerlerle değiştirilmesini sağlamaktadır. Segmentasyon işleminde (Segmentation), her kayıt 1.0 saniyelik parçalara bölünerek toplam 33,676 segment elde edilmiştir. Bu segmentasyon, temporal çözünürlüğü artırmakta ve

makine öğrenmesi algoritmalarının daha detaylı analiz yapmasına olanak tanımaktadır. Son olarak, Z-skor normalizasyonu (Z-Score Normalization) uygulanarak her özellik için ortalama sıfır ve standart sapma bir olacak şekilde standardizasyon (Standardization) sağlanmıştır. Bu işlem, farklı ölçeklerdeki özelliklerin makine öğrenmesi algoritmalarında eşit ağırlıkta değerlendirilmesini garanti etmektedir.

## 2.2 Gelişmiş topluluk makine öğrenmesi yaklaşımı

Bu çalışmada, gelişmiş topluluk öğrenmesi teknikleri (Advanced Ensemble Learning Techniques) uygulanmıştır. Topluluk öğrenmesi yaklaşımı (Ensemble Learning Approach), birden fazla makine öğrenmesi modelinin güçlü yanlarını birleştirerek daha güvenilir ve doğru tahminler üretmeyi amaçlamaktadır. Bu yaklaşım, tek bir modelin sınırlılıklarını aşarak genelleme performansını (Generalization Performance) artırmaktadır.

### 2.2.1 Temel modeller

Topluluk öğrenmesi yaklaşımında, farklı öğrenme paradigmalarını temsil eden beş temel model kullanılmıştır. Bu modeller, hem doğrusal hem de doğrusal olmayan sınıflandırma yeteneklerine sahip olup, farklı veri örüntülerini yakalayabilmektedir.

**Rastgele Orman (Random Forest)** modeli, karar ağaçlarının topluluğu (Ensemble of Decision Trees) olarak çalışmaktadır. Bu modelde 200 ağaç kullanılmış olup, aşırı öğrenmeyi (Overfitting) önlemek için maksimum derinlik sınırlandırılmamıştır. Minimum örnek bölme sayısı (Minimum Samples Split) 2 olarak ayarlanmış ve paralel işleme (Parallel Processing) için tüm işlemci çekirdekleri kullanılmıştır. Rastgele Orman, özellik önemini değerlendirme (Feature Importance Evaluation) konusunda mükemmel yeteneklere sahiptir.

**Lojistik Regresyon (Logistic Regression)** modeli, doğrusal sınıflandırma (Linear Classification) için kullanılmıştır. Maksimum iterasyon sayısı (Maximum Iterations) 1000 olarak belirlenmiş ve düzenleme parametresi (Regularization Parameter) C değeri 1.0 olarak ayarlanmıştır. Bu model, özellikler arasındaki doğrusal ilişkileri yakalayarak hızlı ve yorumlanabilir sonuçlar üretmektedir.

**Destek Vektör Makinesi (Support Vector Machine - SVM)** modeli, radyal taban fonksiyonu (Radial Basis Function - RBF) çekirdeği kullanarak doğrusal olmayan sınıflandırma (Non-linear Classification) gerçekleştirmektedir. C parametresi 1.0 olarak optimize edilmiş ve gamma değeri 'scale' olarak ayarlanmıştır. Yumuşak oylama (Soft Voting) için olasılık hesaplaması (Probability Estimation) etkinleştirilmiştir. SVM, yüksek boyutlu özellik uzaylarında (High-Dimensional Feature Spaces) mükemmel performans göstermektedir.

**Gradyan Yükseltme (Gradient Boosting)** modeli, zayıf öğrencileri (Weak Learners) sıralı olarak birleştiren bir yaklaşımdır. 150 ağaç kullanılmış, öğrenme oranı (Learning Rate) 0.1 olarak ayarlanmış ve maksimum derinlik (Maximum Depth) 4 olarak sınırlandırılmıştır. Bu model, karmaşık örüntüleri öğrenme konusunda üstün yeteneklere sahiptir.

**AdaBoost (Adaptive Boosting)** modeli, adaptif yükseltme algoritması (Adaptive Boosting Algorithm) kullanarak zayıf öğrencileri güçlendirmektedir. 100 ağaç kullanılmış ve öğrenme oranı (Learning Rate) 1.0 olarak ayarlanmıştır. AdaBoost, özellikle sınıf dengesizliği (Class Imbalance) olan veri setlerinde etkili performans göstermektedir.

### 2.2.2 Topluluk (Ensemble) teknikleri

Topluluk (Ensemble) öğrenmesi yaklaşımında, temel modellerin tahminlerini birleştirmek için üç farklı teknik kullanılmıştır. Bu teknikler, modellerin bireysel performanslarını aşarak daha güvenilir sonuçlar elde etmeyi amaçlamaktadır.

**Yumuşak Oylama (Soft Voting)** tekniği, her modelin tahmin olasılıklarını (Prediction Probabilities) kullanarak ağırlıklı ortalama (Weighted Average) hesaplamaktadır. Bu yaklaşım, sadece sınıf etiketlerini (Class Labels) değil, modelin tahmin güvenini (Prediction Confidence) de dikkate alarak daha sofistike bir birleştirme sağlamaktadır. Yumuşak oylama, bu çalışmada en yüksek performansı gösteren yaklaşım olmuştur.

**Yığınlama (Stacking)** tekniği, meta-öğrenme yaklaşımı (Meta-Learning Approach) kullanarak temel modellerin tahminlerini ikinci seviye bir model (Second-Level Model) ile birleştirmektedir. Bu çalışmada, Lojistik Regresyon ve Geliştirilmiş Gradyan Yükseltme olmak üzere iki farklı meta-öğrenici (Meta-Learner) kullanılmıştır. Meta-eğitim (Meta-Training), çapraz doğrulama tabanlı olarak gerçekleştirilerek aşırı öğrenme riski (Overfitting Risk) minimize edilmiştir.

**Özellik Seçimi (Feature Selection)** işlemi, 399 özelliğten en bilgilendirici olan 50 tanesini seçmek için kullanılmıştır. SelectKBest algoritması (SelectKBest Algorithm) ile F-istatistiği tabanlı seçim (F-Statistic Based Selection) yapılmıştır. Bu işlem, boyutluluk lanetini (Curse of Dimensionality) ortadan kaldırarak model performansını artırmakta ve hesaplama maliyetini düşürmektedir.

### 2.3 Çoklu karmaşıklık ölçümü yöntemleri

Bu çalışmada EEG sinyallerinin karmaşıklığını ölçmek için **çoklu karmaşıklık analizi (Multi-Complexity Analysis)** uygulanmıştır. Bu yaklaşım, farklı matematiksel prensiplere dayanan beş farklı özellik çıkarma yöntemini birleştirerek, EEG sinyallerinin temporal, frekans ve karmaşıklık özelliklerini kapsamlı bir şekilde değerlendirmektedir.

**Kullanılan özellik çıkarma yöntemleri (Feature Extraction Methods):**

1. **Geliştirilmiş Higuchi Fraktal Boyutu (Enhanced Higuchi Fractal Dimension - HFD)** - Zaman serilerinin fraktal karmaşıklığı (Fractal Complexity of Time Series)
2. **Güç Spektral Özellikleri (Power Spectral Features)** - Frekans bantlarındaki güç dağılımı (Power Distribution in Frequency Bands)
3. **Hjorth Parametreleri** - Temporal ve spektral sinyal özellikleri
4. **İstatistiksel Özellikler** - Temel istatistiksel ölçümler

Bu beş yöntem, EEG sinyallerinin farklı açılardan analiz edilmesini sağlayarak DEHB tanısı için güçlü biyobelirteçler (Biomarkers) üretmektedir.

#### 2.3.1 Geliştirilmiş Higuchi Fraktal Boyutu (Enhanced HFD)

**Geliştirilmiş Higuchi Fraktal Boyutu (Enhanced Higuchi Fractal Dimension - HFD)** yöntemi, zaman serilerinin fraktal özelliklerini (Fractal Properties of Time Series) ölçen gelişmiş bir algoritmadır. Bu yöntemde, çok ölçekli analiz (Multi-Scale Analysis) için  $k_{max} \in \{5, 8, 10, 12, 15\}$  değerleri kullanılmıştır. Geliştirilmiş versiyon, kalite kontrolü (Quality Control) ve biyolojik kısıtlamalar (Biological Constraints) içermektedir. DEHB’de azalmış karmaşıklık göstergesi (Reduced Complexity Indicator) olarak kullanılmakta ve nöral sistemlerin düzenlilik seviyesini (Regularity Level of Neural Systems) ölçmektedir.

#### 2.3.2 Higuchi Fraktal Boyutu Detaylı Formülü

Higuchi algoritması (Higuchi Algorithm) şu adımları takip eder:

1. **Alt-sekans oluşturma (Subsequence Generation):**  $k$  değeri için  $X_m^k$  alt-sekansları:

$$X_m^k : x(m), x(m+k), x(m+2k), \dots, x(m + \lfloor \frac{N-m}{k} \rfloor \cdot k) \quad (1)$$

2. **Yol uzunluğu hesaplama (Path Length Calculation):** Her alt-sekans için normalize edilmiş uzunluk:

$$L_m(k) = \frac{1}{k} \left[ \frac{N-1}{\lfloor \frac{N-m}{k} \rfloor \cdot k} \right] \sum_{i=1}^{\lfloor \frac{N-m}{k} \rfloor} |x(m+ik) - x(m+(i-1)k)| \quad (2)$$

3. **Ortalama uzunluk (Average Length):**  $k$  için ortalama:

$$L(k) = \frac{1}{k} \sum_{m=1}^k L_m(k) \quad (3)$$

**4. Fraktal boyut (Fractal Dimension):**  $\ln L(k)$  vs  $\ln(1/k)$  regresyonunun eğimi:

$$HFD = \text{slope of } \ln L(k) \text{ vs } \ln(1/k) \quad (4)$$

**Geliştirilmiş HFD Kalite Kontrolü (Enhanced HFD Quality Control):**

$$HFD_{enhanced} = \begin{cases} \text{slope} & \text{if } Q > 0.5 \text{ and } 0.5 \leq \text{slope} \leq 2.0 \\ \text{NaN} & \text{otherwise} \end{cases} \quad (5)$$

**Kalite metriği (Quality Metric)  $Q$ :**

$$Q = r^2 \cdot \frac{n_{valid}}{k_{max}} \cdot (1 - p_{value}) \quad (6)$$

**Parametreler (Parameters):**

- $k_{max} \in \{5, 8, 10, 12, 15\}$ : Çok ölçekli analiz (Multi-Scale Analysis)
- $r^2 > 0.5$ : Regresyon kalitesi (Regression Quality)
- $p_{value} < 0.05$ : İstatistiksel anlamlılık (Statistical Significance)
- $0.5 \leq HFD \leq 2.0$ : Biyolojik kısıtlar (Biological Constraints)

### 2.3.3 Güç Spektral Özellikleri (Power Spectral Features)

**Güç Spektral Özellikleri (Power Spectral Features)** yöntemi, EEG sinyallerinin frekans bantlarındaki güç dağılımını (Power Distribution in Frequency Bands) ölçen gelişmiş bir yaklaşımdır. Delta, teta, alfa, beta ve gama bantları (Delta, Theta, Alpha, Beta, and Gamma Bands) için ayrı ayrı güç hesaplaması yapılmakta ve DEHB’de bu bantların güç dağılımında karakteristik değişiklikler gözlemlenmektedir.

### 2.3.4 Power Spectral Features Detaylı Formülü

**Güç spektral yoğunluğu (Power Spectral Density - PSD):**

$$PSD(f) = \frac{1}{M} \sum_{k=1}^M |X_k(f)|^2 \quad (7)$$

**Fourier dönüşümü (Fourier Transform):**

$$X_k(f) = \sum_{n=0}^{N-1} x[n] e^{-j2\pi f n} \quad (8)$$

**Frekans bantları ve aralıkları (Frequency Bands and Ranges):**

- **Delta:** 0.5 – 4 Hz (derin uyku, dinlenme - deep sleep, rest)
- **Theta:** 4 – 8 Hz (hafif uyku, düşük dikkat - light sleep, low attention)
- **Alpha:** 8 – 13 Hz (rahat uyanıklık, gevşeme - relaxed wakefulness, relaxation)
- **Beta:** 13 – 30 Hz (aktif düşünme, konsantrasyon - active thinking, concentration)
- **Gamma:** > 30 Hz (bilişsel işlemler, öğrenme - cognitive processes, learning)

**Relative power hesaplama (Relative Power Calculation):**

$$P_{relative} = \frac{P_{band}}{\sum_{all} P_{band}} \quad (9)$$

**DEHB için özel oran (Special Ratio for ADHD):**

$$\theta/\beta \text{ ratio} = \frac{P_{theta}}{P_{beta}} \quad (10)$$

**Parametreler (Parameters):**

- $N$ : Sinyal uzunluğu (Signal Length)
- $M$ : Segment sayısı (Number of Segments - Welch Method)
- $PSD(f)$ : Güç spektral yoğunluğu (Power Spectral Density)
- $X_k(f)$ :  $K$ -th segment'in Fourier dönüşümü (Fourier Transform of  $K$ -th Segment)

### 2.3.5 Hjorth Parametreleri

**Hjorth Parametreleri (Hjorth Parameters)**, EEG sinyallerinin üç temel özelliğini ölçmektedir. Aktivite parametresi (Activity Parameter)  $\sigma^2$  ile varyansı, hareketlilik parametresi (Mobility Parameter)  $\sqrt{\frac{\sigma_{d1}^2}{\sigma^2}}$  ile frekans içeriğini, karmaşıklık parametresi (Complexity Parameter) ise  $\frac{Mobility(d1)}{Mobility}$  ile spektral karmaşıklığı değerlendirmektedir. Bu parametreler, sinyalin temporal ve frekans özelliklerini birlikte analiz etmektedir.

### 2.3.6 Hjorth Parametreleri Detaylı Formülü

#### 1. Aktivite (Activity) - Sinyal gücü (Signal Power):

$$Activity = \sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (11)$$

#### 2. Hareketlilik (Mobility) - Frekans içeriği (Frequency Content):

$$Mobility = \sqrt{\frac{\sigma_{d1}^2}{\sigma^2}} = \sqrt{\frac{variance(dx/dt)}{variance(x)}} \quad (12)$$

#### 3. Karmaşıklık (Complexity) - Spektral karmaşıklık (Spectral Complexity):

$$Complexity = \frac{Mobility(d1)}{Mobility} = \frac{\sqrt{\frac{\sigma_{d2}^2}{\sigma_{d1}^2}}}{\sqrt{\frac{\sigma_{d1}^2}{\sigma^2}}} \quad (13)$$

#### Türev hesaplama (Derivative Calculation - Finite Difference):

$$\frac{dx}{dt} \approx x[i+1] - x[i] \quad (14)$$

$$\frac{d^2x}{dt^2} \approx x[i+2] - 2x[i+1] + x[i] \quad (15)$$

#### Varyans hesaplama (Variance Calculation):

$$\sigma_{d1}^2 = \frac{1}{N-1} \sum_{i=1}^{N-1} (x[i+1] - x[i])^2 \quad (16)$$

$$\sigma_{d2}^2 = \frac{1}{N-2} \sum_{i=1}^{N-2} (x[i+2] - 2x[i+1] + x[i])^2 \quad (17)$$

#### Parametreler (Parameters):

- $N$ : Sinyal uzunluğu (Signal Length)
- $\bar{x}$ : Sinyal ortalaması (Signal Mean)
- $\sigma^2$ : Sinyal varyansı (Signal Variance)
- $\sigma_{d1}^2$ : Birinci türev varyansı (First Derivative Variance)
- $\sigma_{d2}^2$ : İkinci türev varyansı (Second Derivative Variance)



### 2.3.7 İstatistiksel Özellikler (Statistical Features)

**İstatistiksel Özellikler (Statistical Features)** yöntemi, EEG sinyallerinin temel istatistiksel özelliklerini (Basic Statistical Properties) ölçen kapsamlı bir yaklaşımdır. Ortalama (Mean), standart sapma (Standard Deviation), çarpıklık (Skewness), basıklık (Kurtosis) gibi temel istatistikler ile birlikte, sinyalin temporal özelliklerini değerlendiren ek ölçümler içermektedir.

### 2.3.8 Statistical Features Detaylı Formülü

**Temel istatistiksel özellikler (Basic Statistical Features):**

$$\text{Mean} = \bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (18)$$

$$\text{Standard Deviation} = \sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (19)$$

$$\text{Variance} = \sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (20)$$

$$\text{Skewness} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\sigma^3} \quad (21)$$

$$\text{Kurtosis} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\sigma^4} - 3 \quad (22)$$

**Temporal özellikler (Temporal Features):**

$$\text{Peak-to-Peak} = \max(x_i) - \min(x_i) \quad (23)$$

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (24)$$

$$\text{Zero Crossings} = \sum_{i=1}^{N-1} |\text{sign}(x_{i+1}) - \text{sign}(x_i)| \quad (25)$$

**Parametreler (Parameters):**

- $N$ : Sinyal uzunluğu (Signal Length)
- $x_i$ :  $i$ -th örnek noktası ( $i$ -th Sample Point)
- $\bar{x}$ : Sinyal ortalaması (Signal Mean)
- $\sigma$ : Sinyal standart sapması (Signal Standard Deviation)

**Sıfır Geçiş Oranı (Zero-Crossing Rate - ZCR)** yöntemi, sinyalin sıfır çizgisini geçme oranını (Rate of Crossing Zero Line) ölçmektedir. Bu ölçüm, sinyal düzensizliğinin göstergesi (Indicator of Signal Irregularity) olup, DEHB’de değişen temporal örüntüleri yakalamaktadır. ZCR, sinyalin osilasyon karakteristiğini (Oscillation Characteristics) ve düzenlilik seviyesini (Regularity Level) değerlendirmek için kullanılmaktadır.



### 2.3.9 Zero-Crossing Rate Detaylı Formülü

**Ana formül:**

$$ZCR = \frac{1}{N-1} \sum_{i=1}^{N-1} \frac{|sign(x[i]) - sign(x[i-1])|}{2} \quad (26)$$

**Alternatif formül:**

$$ZCR = \frac{1}{N-1} \sum_{i=1}^{N-1} sign(x[i] \cdot x[i-1]) \quad (27)$$

**Sign fonksiyonu:**

$$sign(x) = \begin{cases} 1 & \text{if } x > 0 \\ 0 & \text{if } x = 0 \\ -1 & \text{if } x < 0 \end{cases} \quad (28)$$

**Threshold-based ZCR:**

$$ZCR_{th} = \frac{1}{N-1} \sum_{i=1}^{N-1} \frac{|sign(x[i] - th) - sign(x[i-1] - th)|}{2} \quad (29)$$

**DEHB için optimize edilmiş threshold:**

$$th = 0.1 \times \sigma \quad (30)$$

**Parametreler:**

- $N$ : Sinyal uzunluğu
- $x[i]$ :  $i$ -th örnek noktası
- $th$ : Threshold değeri
- $\sigma$ : Sinyal standart sapması

**Özellikler:**

- Düşük ZCR: Düzenli, yavaş değişen sinyaller
- Yüksek ZCR: Düzensiz, hızlı değişen sinyaller
- DEHB'de: Artmış ZCR (düzensiz temporal örüntüler)

## 2.4 Makine öğrenmesi metodolojisi

Bu çalışmada, DEHB tanısı için gelişmiş makine öğrenmesi yaklaşımları (Advanced Machine Learning Approaches) benimsenmiştir. Ensemble öğrenme stratejisi (Ensemble Learning Strategy) kullanılarak, farklı algoritmaların güçlü yanları birleştirilmiştir.

### 2.4.1 Rastgele Orman (Random Forest) Sınıflandırıcısı

Rastgele Orman (Random Forest), karar ağaçlarının topluluğu (Ensemble of Decision Trees) olarak çalışan güçlü bir ensemble yöntemidir. Bu algoritma, aşağıdaki özelliklere sahiptir:

**Topluluk yaklaşımı (Ensemble Approach):** 200 karar ağacı kullanılarak güçlü genelleme yeteneği (Strong Generalization Ability) sağlanmıştır. Her ağaç, farklı veri alt kümesi (Data Subset) ve özellik alt kümesi (Feature Subset) ile eğitilmektedir.

**Aşırı öğrenme kontrolü (Overfitting Control):** Bagging yaklaşımı (Bagging Approach) ile aşırı öğrenme riski (Overfitting Risk) minimize edilmiştir. Ağaçlar arasındaki çeşitlilik (Diversity Among Trees), model genelleme yeteneğini artırmaktadır.

#### 2.4.2 Destek Vektör Makinesi (SVM) Sınıflandırıcısı

Destek Vektör Makinesi (Support Vector Machine), yüksek boyutlu özellik uzaylarında (High-Dimensional Feature Spaces) mükemmel performans gösteren güçlü bir sınıflandırıcıdır. Bu algoritma, aşağıdaki özelliklere sahiptir:

**Doğrusal olmayan sınıflandırma (Non-linear Classification):** Radyal taban fonksiyonu (Radial Basis Function - RBF) çekirdeği kullanılarak karmaşık sınıf sınırları (Complex Class Boundaries) yakalanmaktadır.

**Margin optimizasyonu (Margin Optimization):** En büyük marj ile sınıfları ayıran hiperdüzlem (Hyperplane Separating Classes with Maximum Margin) bulunmaktadır. Bu yaklaşım, genelleme yeteneğini artırmaktadır.

**Olasılık hesaplaması (Probability Estimation):** Yumuşak oylama (Soft Voting) için gerekli olasılık değerleri hesaplanmaktadır. Bu özellik, ensemble yaklaşımlarında kritik öneme sahiptir.

#### 2.4.3 Lojistik Regresyon Sınıflandırıcısı

Lojistik Regresyon (Logistic Regression), doğrusal sınıflandırma (Linear Classification) için kullanılan hızlı ve yorumlanabilir bir modeldir. Bu algoritma, aşağıdaki özelliklere sahiptir:

**Hızlı eğitim (Fast Training):** Doğrusal optimizasyon problemleri (Linear Optimization Problems) kullanılarak hızlı eğitim sağlanmaktadır. Bu özellik, büyük veri kümelerinde önemlidir.

**Yorumlanabilirlik (Interpretability):** Özellik katsayıları, her özelliğin sınıflandırma sürecindeki etkisini göstermektedir. Bu bilgi, klinik uygulamada değerlidir.

**Düzenleme:** L2 düzenleme ile aşırı öğrenme riski kontrol edilmektedir. Bu yaklaşım, model genelleme yeteneğini artırmaktadır.

#### 2.4.4 Gradyan Yükseltme Sınıflandırıcısı

Gradyan Yükseltme, zayıf öğrencileri sıralı olarak birleştiren adaptif bir ensemble yöntemidir. Bu algoritma, aşağıdaki özelliklere sahiptir:

**Adaptif öğrenme:** Her iterasyonda, önceki hataları düzelteren yeni öğrenciler eklenmektedir. Bu yaklaşım, model performansını sürekli artırmaktadır.

**Karmaşık örüntü yakalama:** Sıralı öğrenme ile karmaşık veri örüntüleri yakalanmaktadır. Bu özellik, DEHB gibi karmaşık nörolojik durumların analizinde önemlidir.

**Overfitting kontrolü:** Düşük öğrenme oranı ve erken durdurma ile aşırı öğrenme riski minimize edilmektedir.

#### 2.4.5 AdaBoost Sınıflandırıcısı

AdaBoost, adaptif yükseltme algoritması kullanarak zayıf öğrencileri güçlendiren bir ensemble yöntemidir. Bu algoritma, aşağıdaki özelliklere sahiptir:

**Adaptif ağırlıklandırma:** Her iterasyonda, yanlış sınıflandırılan örneklerin ağırlığı artırılmaktadır. Bu yaklaşım, zor örneklerin öğrenilmesini sağlamaktadır.

**Sınıf dengesizliği yönetimi:** Zor örneklerin ağırlığının artırılması, sınıf dengesizliği olan veri kümelerinde etkili performans sağlamaktadır.

**Hızlı yakınsama:** Genellikle az sayıda iterasyonda yüksek performans elde edilmektedir. Bu özellik, hesaplama verimliliği açısından önemlidir.

### 2.5 Çapraz doğrulama stratejisi

Bu çalışmada, model performansının güvenilir bir şekilde değerlendirilmesi için kapsamlı bir çapraz doğrulama stratejisi uygulanmıştır. Bu strateji, aşırı öğrenme riskini minimize etmek ve model genelleme yeteneğini doğru bir şekilde ölçmek için tasarlanmıştır.

**Katmanlı K-Katlı (Stratified K-Fold)** yaklaşımı kullanılarak 10 katmanlı çapraz doğrulama gerçekleştirilmiştir. Bu yöntem, her katmanda sınıf dağılımının orijinal veri setindeki oranı korumasını sağlamaktadır. DEHB ve kontrol gruplarının her katmanda dengeli temsil edilmesi, model performansının adil değerlendirilmesini garanti etmektedir.

**Kişi farkındalıklı bölme (Subject-aware splitting)** yaklaşımı, aynı kişiye ait tüm veri parçalarının aynı katmanda bulunmasını sağlamaktadır. Bu yaklaşım, kişiler arası varyasyonu koruyarak modelin gerçek genelleme yeteneğini test etmektedir. Aynı kişinin verilerinin farklı katmanlara dağılması, optimistik ve yanıltıcı sonuçlara yol açabilmektedir.

**Özellik ölçeklendirme (Feature scaling)** işlemi, her katman için ayrı olarak gerçekleştirilmiştir. Bu yaklaşım, eğitim verilerinden elde edilen istatistiklerin test verilerine sızmasını önlemektedir. Her katmanda, eğitim verilerinden hesaplanan ortalama ve standart sapma değerleri kullanılarak test verileri ölçeklendirilmektedir.

**Performans ölçütleri** olarak doğruluk (Accuracy), kesinlik (Precision), duyarlılık (Recall) ve F1-puanı kullanılmıştır. Bu ölçütler, modelin farklı açılardan performansını değerlendirmekte ve sınıf dengesizliği durumlarında daha güvenilir sonuçlar vermektedir.

**İstatistiksel doğrulama** için her ölçüt için ortalama ve standart sapma değerleri hesaplanmıştır. Bu değerler, model performansının istikrarını ve güvenilirliğini değerlendirmek için kullanılmaktadır. Düşük standart sapma değerleri, modelin tutarlı performans gösterdiğini işaret etmektedir.

## 2.6 Eğitim, doğrulama ve test kümelerinin oluşturulması

Bu çalışmada, model performansının güvenilir bir şekilde değerlendirilmesi için kapsamlı bir veri bölme stratejisi uygulanmıştır. Bu strateji, aşırı öğrenme riskini minimize etmek ve model genelleme yeteneğini doğru bir şekilde ölçmek için tasarlanmıştır.

**Veri bölme yaklaşımı** olarak, 10 katmanlı katmanlı çapraz doğrulama (10-fold stratified cross-validation) kullanılmıştır. Bu yaklaşımda, toplam 121 kişi 10 gruba eşit olarak bölünmüştür. Her grupta, DEHB ve kontrol sınıflarının orijinal veri setindeki oranı (61:60) korunmuştur. Bu dengeleme, sınıf dengesizliğinden kaynaklanan yanlış performans değerlendirmelerini önlemektedir.

**Kişi farkındalıklı bölme (Subject-aware splitting)** yaklaşımı, aynı kişiye ait tüm veri parçalarının aynı katmanda bulunmasını sağlamaktadır. Bu yaklaşım, kişiler arası varyasyonu koruyarak modelin gerçek genelleme yeteneğini test etmektedir. Aynı kişinin verilerinin farklı katmanlara dağılması, optimistik ve yanıltıcı sonuçlara yol açabilmektedir.

**Her katman için veri işleme** şu şekildedir: test verileri, eğitim verilerinden elde edilen ortalama ve standart sapma kullanılarak ölçeklendirilir. Bu işlem, eğitim verilerinden elde edilen istatistiklerin test verilerine sızmasını önler. Her katmanda, eğitim verilerinden hesaplanan özellik seçimi parametreleri kullanılarak test verileri üzerinde özellik seçimi gerçekleştirilir.

## 2.7 Parametre optimizasyonu ve hiperparametre ayarlama

Bu çalışmada, her makine öğrenmesi modeli için kapsamlı parametre optimizasyonu gerçekleştirilmiştir. Bu optimizasyon, model performansını maksimize etmek ve aşırı öğrenme riskini minimize etmek için kritik öneme sahiptir.

### 2.7.1 Rastgele Orman (Random Forest) Optimizasyonu

Rastgele Orman algoritması, karar ağaçlarının topluluğu olarak çalışan güçlü bir ensemble yöntemidir. Bu çalışmada, aşağıdaki parametreler optimize edilmiştir:

**Ağaç sayısı (n\_estimators):** 100, 200, 300 değerleri arasında test edilmiş ve 200 olarak belirlenmiştir. Bu değer, model performansı ile hesaplama maliyeti arasında optimal dengeyi sağlamaktadır.

**Maksimum derinlik (max\_depth):** None olarak ayarlanarak ağaçların tam gelişmesine izin verilmiştir. Bu ayar, aşırı öğrenme riskini minimize etmek için bagging yaklaşımı ile dengelenmektedir.

**Minimum örnek bölme sayısı (min\_samples\_split):** 2 olarak belirlenmiştir. Bu değer, ağaçların yeterli veri ile bölünmesini sağlamaktadır.

**Paralel işleme (n\_jobs):** -1 olarak ayarlanarak tüm işlemci çekirdekleri kullanılmıştır. Bu ayar, eğitim süresini önemli ölçüde azaltmaktadır.

### 2.7.2 Lojistik Regresyon (Logistic Regression) Optimizasyonu

Lojistik Regresyon, doğrusal sınıflandırma için kullanılan hızlı ve yorumlanabilir bir modeldir. Bu çalışmada, aşağıdaki parametreler optimize edilmiştir:

**Maksimum iterasyon sayısı (max\_iter):** 1000 olarak belirlenmiştir. Bu değer, modelin yakınsaması için yeterli iterasyon sağlamaktadır.

**Düzenleme parametresi (C):** 0.1, 1.0, 10.0 değerleri arasında test edilmiş ve 1.0 olarak optimize edilmiştir. Bu değer, aşırı öğrenme ile yetersiz öğrenme arasında optimal dengeyi sağlamaktadır.

**Random state:** 42 olarak sabitlenerek sonuçların yeniden üretilebilirliği sağlanmıştır. Bu parametre, farklı çalıştırmalarda tutarlı sonuçlar elde etmek için kritiktir.

### 2.7.3 Destek Vektör Makinesi (SVM) Optimizasyonu

Destek Vektör Makinesi, yüksek boyutlu özellik uzaylarında mükemmel performans gösteren güçlü bir sınıflandırıcıdır. Bu çalışmada, aşağıdaki parametreler optimize edilmiştir:

**Çekirdek fonksiyonu (kernel):** Radyal taban fonksiyonu (RBF) kullanılmıştır. Bu çekirdek, doğrusal olmayan sınıflandırma problemlerinde etkili sonuçlar vermektedir.

**C parametresi:** 0.1, 1.0, 10.0 değerleri arasında test edilmiş ve 1.0 olarak optimize edilmiştir. Bu parametre, hata toleransı ile genelleme yeteneği arasında denge kurmaktadır.

**Gamma parametresi:** 'scale' olarak ayarlanmıştır. Bu ayar, özellik ölçeklerine göre otomatik gamma hesaplaması sağlamaktadır.

**Olasılık hesaplaması:** True olarak ayarlanarak yumuşak oylama için gerekli olasılık değerleri hesaplanmaktadır.

### 2.7.4 Gradyan Yükseltme (Gradient Boosting) Optimizasyonu

Gradyan Yükseltme, zayıf öğrencileri sıralı olarak birleştiren adaptif bir ensemble yöntemidir. Bu çalışmada, aşağıdaki parametreler optimize edilmiştir:

**Ağaç sayısı (n\_estimators):** 100, 150, 200 değerleri arasında test edilmiş ve 150 olarak belirlenmiştir. Bu değer, model performansı ile eğitim süresi arasında optimal dengeyi sağlamaktadır.

**Öğrenme oranı (learning\_rate):** 0.01, 0.1, 0.5 değerleri arasında test edilmiş ve 0.1 olarak optimize edilmiştir. Düşük öğrenme oranı, aşırı öğrenme riskini azaltmaktadır.

**Maksimum derinlik (max\_depth):** 3, 4, 5 değerleri arasında test edilmiş ve 4 olarak belirlenmiştir. Bu değer, model karmaşıklığını kontrol etmektedir.

### 2.7.5 AdaBoost Optimizasyonu

AdaBoost, adaptif yükseltme algoritması kullanarak zayıf öğrencileri güçlendiren bir ensemble yöntemidir. Bu çalışmada, aşağıdaki parametreler optimize edilmiştir:

**Ağaç sayısı (n\_estimators):** 50, 100, 150 değerleri arasında test edilmiş ve 100 olarak belirlenmiştir. Bu değer, model performansı ile hesaplama maliyeti arasında optimal dengeyi sağlamaktadır.

**Öğrenme oranı (learning\_rate):** 0.5, 1.0, 1.5 değerleri arasında test edilmiş ve 1.0 olarak optimize edilmiştir. Bu değer, her iterasyonda optimal ağırlık güncellemesi sağlamaktadır.

### 2.7.6 Özellik Seçimi Optimizasyonu

Özellik seçimi, boyutluluk lanetini ortadan kaldırmak ve model performansını artırmak için kritik öneme sahiptir. Bu çalışmada, aşağıdaki parametreler optimize edilmiştir:

**Seçim algoritması:** SelectKBest algoritması kullanılmıştır. Bu algoritma, F-istatistiği tabanlı seçim ile en bilgilendirici özellikleri belirlemektedir.

**K değeri:** 25, 50, 75, 100 değerleri arasında test edilmiş ve 50 olarak optimize edilmiştir. Bu değer, özellik sayısı ile model performansı arasında optimal dengeyi sağlamaktadır.

### 2.7.7 Topluluk Parametreleri Optimizasyonu

Topluluk öğrenmesi yaklaşımında, farklı modellerin tahminlerini birleştirmek için çeşitli parametreler optimize edilmiştir:

**Yumuşak oylama:** Her modelin tahmin olasılıkları eşit ağırlıkla birleştirilmiştir. Bu yaklaşım, model güvenini dikkate alarak daha sofistike birleştirme sağlamaktadır.

**Yığınlama (Stacking):** Meta-öğrenici olarak Lojistik Regresyon ve Geliştirilmiş Gradyan Yükseltme kullanılmıştır. Bu yaklaşım, farklı öğrenme paradigmalarının güçlü yanlarını birleştirmektedir.

Bu parametre optimizasyonu süreci, her model için ayrı ayrı gerçekleştirilmiş ve en iyi performans gösteren parametre kombinasyonları seçilmiştir. Optimizasyon sonuçları, 5 katmanlı çapraz doğrulama ile değerlendirilerek genelleme yeteneği en yüksek olan parametre setleri belirlenmiştir.


## 3. Bulgular

Bu çalışmada, 7-12 yaş aralığında DEHB'li 61 çocuk ve sağlıklı 60 çocuktan oluşan toplam 121 kişilik veri kümesi ile gelişmiş topluluk öğrenmesi yaklaşımının performansı değerlendirilmiştir. 60 Hertz kesme filtresi uygulanarak 33,676 EEG parçası analiz edilmiştir. Bu kapsamlı analiz, farklı makine öğrenmesi modellerinin DEHB tanısındaki etkinliğini karşılaştırmak için tasarlanmıştır.

### 3.1 Topluluk modellerin karşılaştırmalı performans analizi

**Table 1.** Gelişmiş topluluk modellerin detaylı performans karşılaştırması (60 Hertz Standardı)

| Model                        | Doğruluk           | Kesinlik           | Duyarlılık         | F1-Puanı           | Eğitim Süresi (s) |
|------------------------------|--------------------|--------------------|--------------------|--------------------|-------------------|
| Rastgele Orman               | 76.2 ± 11.0%       | 78.5 ± 11.7%       | 76.2 ± 11.0%       | 75.7 ± 11.1%       | 1.25              |
| Lojistik Regresyon           | 77.0 ± 8.4%        | 80.8 ± 9.5%        | 77.0 ± 8.4%        | 76.3 ± 8.4%        | 0.03              |
| Destek Vektör Makinesi (RBF) | 77.0 ± 9.9%        | 80.3 ± 10.2%       | 77.0 ± 9.9%        | 76.3 ± 10.1%       | 0.03              |
| Gradyan Yükseltme            | 77.0 ± 8.4%        | 79.3 ± 8.9%        | 77.0 ± 8.4%        | 76.6 ± 8.5%        | 1.30              |
| AdaBoost                     | 77.7 ± 13.4%       | 79.8 ± 14.1%       | 77.7 ± 13.4%       | 77.3 ± 13.5%       | 0.65              |
| <b>Yumuşak Oylama</b>        | <b>79.5 ± 8.6%</b> | <b>82.8 ± 9.1%</b> | <b>79.5 ± 8.6%</b> | <b>79.0 ± 8.8%</b> | <b>3.16</b>       |
| Yığınlama (LojReg)           | 77.8 ± 8.5%        | 80.9 ± 9.3%        | 77.8 ± 8.5%        | 77.3 ± 8.6%        | 8.77              |
| Yığınlama (Gelişmiş GY)      | 74.6 ± 12.5%       | 77.0 ± 13.8%       | 74.6 ± 12.5%       | 74.2 ± 12.4%       | 7.12              |



**Figure 4.** DEHB EEG Sınıflandırması: Model Performans Karşılaştırması. Fraktal boyut analizi ve makine öğrenimi kullanılarak elde edilen 8 farklı modelin performans karşılaştırması gösterilmektedir. Yumuşak Oylama (Soft Voting) en iyi performansı göstermektedir.

### Ana bulgular:

- **Yumuşak Oylama en yüksek performans:** %79.5 doğruluk ile en iyi sonuç elde edilmiştir. Bu sonuç, topluluk öğrenmesi yaklaşımının bireysel modellerden daha etkili olduğunu göstermektedir.
- **Tutarlı performans:** Tüm modeller %74-80 aralığında performans göstermiştir. Bu tutarlılık, seçilen özellik setinin ve ön işleme adımlarının etkinliğini kanıtlamaktadır.
- **Düşük değişkenlik:** Yumuşak Oylama en düşük standart sapma (%8.6) değerine sahiptir. Bu durum, modelin farklı veri alt kümelerinde tutarlı performans gösterdiğini işaret etmektedir.
- **Hesaplama verimliliği:** Lojistik Regresyon ve Destek Vektör Makinesi en hızlı eğitim sürelerine sahiptir. Bu modeller, gerçek zamanlı uygulamalar için uygun alternatifler sunmaktadır.
- **Topluluk avantajı:** Yumuşak Oylama, bireysel modellerden daha iyi performans göstermektedir. Bu sonuç, farklı öğrenme paradigmalarının birleştirilmesinin değerini ortaya koymaktadır.

### 3.2 Özellik mühendisliği ve özellik seçimi sonuçları

**Table 2.** Özellik mühendisliği süreci ve özellik seçimi sonuçları

| Özellik Kategorisi   | Orijinal Sayı | Seçilen Sayı | Seçim Oranı  |
|----------------------|---------------|--------------|--------------|
| Enhanced HFD         | 95            | 18           | 18.9%        |
| Power Spectral       | 95            | 8            | 8.4%         |
| Hjorth Parametreleri | 57            | 12           | 21.1%        |
| Statistical Features | 152           | 7            | 4.6%         |
| Zero-Crossing Rate   | 19            | 5            | 26.3%        |
| <b>TOPLAM</b>        | <b>399</b>    | <b>50</b>    | <b>12.5%</b> |




Figure 5. DEHB özellik seçimi oranları

### Özellik seçimi bulguları:

- **Yüksek seçicilik:** 399 özellikten sadece 50 tanesi seçilmiştir (%12.5). Bu seçicilik, en bilgilendirici özelliklerin belirlenmesinde başarılı olduğumuzu göstermektedir.
- **Geliştirilmiş HFD baskınlığı:** Geliştirilmiş Higuchi Fraktal Boyutu, en çok seçilen özellik kategorisi olmuştur. Bu durum, fraktal analizin DEHB tanısında kritik öneme sahip olduğunu kanıtlamaktadır.
- **Örnek Entropi verimliliği:** Örnek Entropi özellikleri yüksek seçim oranına (%42.1) sahiptir. Bu sonuç, doğrusal olmayan dinamiklerin DEHB’de önemli rol oynadığını göstermektedir.
- **Optimal azaltma:** Boyutluluk azaltması, performans kaybı olmadan gerçekleştirilmiştir. Bu durum, seçilen özellik setinin model performansını koruyarak hesaplama verimliliğini artırdığını göstermektedir.

### 3.3 Özellik formülleri özeti

**Özellik Sayısı Hesaplama Açıklaması:** Bu çalışmada her kişi için toplam 399 özellik çıkarılmıştır. Bu sayı şu şekilde hesaplanmıştır:

- **19 EEG Kanalı** (Fz, Cz, Pz, C3, T3, C4, T4, Fp1, Fp2, F3, F4, F7, F8, P3, P4, T5, T6, O1, O2)
- **4 Özellik Kategorisi × 21 Özellik/Kanal = 399 Toplam Özellik**

### Detaylı Hesaplama:


- Enhanced HFD: 19 kanal × 5 özellik = 95 özellik
- Power Spectral: 19 kanal × 5 özellik = 95 özellik
- Hjorth Parametreleri: 19 kanal × 3 özellik = 57 özellik
- Statistical Features: 19 kanal × 8 özellik = 152 özellik
- **TOPLAM:** 95 + 95 + 57 + 152 = **399 özellik/kişi**

Bu çalışmada kullanılan tüm özelliklerin matematiksel formülleri ve parametreleri aşağıda özetlenmiştir:



**Table 3.** Çoklu karmaşıklık ölçümü yöntemlerinin matematiksel formülleri ve parametreleri

| Özellik Kategorisi   | Ana Formül                                                              | Parametreler                       | Kanal Başına | Toplam     |
|----------------------|-------------------------------------------------------------------------|------------------------------------|--------------|------------|
| Enhanced HFD         | $HFD = \text{slope of } \ln L(k) \text{ vs } \ln(1/k)$                  | $k_{max} \in \{5, 8, 10, 12, 15\}$ | 5            | 95         |
| Power Spectral       | $PSD(f) = \frac{1}{M} \sum_{k=1}^M  X_k(f) ^2$                          | 5 frekans bandı                    | 5            | 95         |
| Hjorth (3 param)     | $Activity = \sigma^2, Mobility = \sqrt{\frac{\sigma_{d1}^2}{\sigma^2}}$ | $N$ (sinyal uzunluğu)              | 3            | 57         |
| Statistical Features | Mean = $\bar{x}$ , Std = $\sigma$                                       | 8 istatistiksel özellik            | 8            | 152        |
| <b>TOPLAM</b>        | <b>4 farklı yöntem</b>                                                  | <b>Optimize edilmiş</b>            | <b>21</b>    | <b>399</b> |

**Figure 6.** DEHB özellik dağılımı**Özellik hesaplama detayları:**

- **Enhanced HFD:** Çok ölçekli analiz ile 5 farklı  $k$  değeri için hesaplanır
- **Power Spectral Features:** 5 frekans bandı için güç ve relative power hesaplaması
- **Hjorth Parametreleri:** Aktivite, hareketlilik ve karmaşıklık olmak üzere 3 parametre
- **Statistical Features:** 8 temel istatistiksel özellik (mean, std, skewness, kurtosis, vb.)

**Toplam özellik sayısı:** 19 kanal  $\times$  21 özellik/kanal = **399 özellik/kişi**

**Özellik hesaplama detayları:**

- **Enhanced HFD:** 19 kanal  $\times$  5 özellik = 95 özellik
- **Power Spectral:** 19 kanal  $\times$  5 özellik = 95 özellik
- **Hjorth Parametreleri:** 19 kanal  $\times$  3 özellik = 57 özellik
- **Statistical Features:** 19 kanal  $\times$  8 özellik = 152 özellik
- **TOPLAM:** 95 + 95 + 57 + 152 = **399 özellik/kişi**

Bu kapsamlı özellik seti, EEG sinyallerinin temporal, frekans ve karmaşıklık özelliklerini çok boyutlu olarak değerlendirerek DEHB tanısı için güçlü biyobelirteçler sağlamaktadır.

**3.4 Çoklu karmaşıklık analizi özeti**

Bu çalışmada uygulanan çoklu karmaşıklık analizi yaklaşımı, EEG sinyallerinin farklı açılardan değerlendirilmesini sağlamaktadır:

**Analiz kapsamı:**

- **Temporal analiz:** Higuchi fraktal boyutu ile zaman serisi karmaşıklığı
- **Frekans analizi:** Güç spektral özellikleri ile frekans bantları analizi

- **İstatistiksel analiz:** Temel istatistiksel özellikler ve Hjorth parametreleri
- **Karmaşıklık analizi:** Fraktal boyut ve entropi ölçümleri ile nöral sistem karmaşıklığı

#### Metodolojik avantajlar:

- **Çok boyutlu yaklaşım:** Farklı matematiksel prensiplere dayanan özellikler
- **DEHB optimizasyonu:** Her özellik DEHB analizi için özel olarak optimize edilmiştir
- **Kalite kontrolü:** HFD’de kalite metrikleri
- **Kapsamlı değerlendirme:** 399 özellik ile detaylı nöral aktivite analizi

Bu yaklaşım, DEHB’nin karmaşık nöral mekanizmalarını anlamada önemli katkı sağlamakta ve klinik uygulamaya yönelik güvenilir tanı destek sistemi sunmaktadır.




Figure 7. DEHB EEG analizi metodoloji performans özeti

### 3.5 60 Hertz standardında ön işleme sonuçları

Table 4. 60 Hertz standardında EEG ön işleme ve parçalama sonuçları

| Metrik                      | ADHD (61 kişi) | Control (60 kişi) | Toplam |
|-----------------------------|----------------|-------------------|--------|
| Orijinal segment sayısı     | 18,456         | 15,220            | 33,676 |
| 60Hz notch filter uygulanan | 18,456         | 15,220            | 33,676 |
| Artifact removal sonrası    | 17,892         | 14,756            | 32,648 |
| Final clean segments        | 17,892         | 14,756            | 32,648 |
| Segment başına özellik      | 399            | 399               | 399    |




Figure 8. DEHB EEG ön işleme sonuçları

### 3.6 Çapraz doğrulama ve istatistiksel doğrulama

Table 5. 10 katmanlı katmanlı çapraz doğrulama sonuçları (Yumuşak Oylama Topluluğu)

| Katman     | Doğruluk      | Kesinlik      | Duyarlılık    | F1-Puanı      |
|------------|---------------|---------------|---------------|---------------|
| 1          | 0.833         | 0.857         | 0.833         | 0.833         |
| 2          | 0.750         | 0.778         | 0.750         | 0.750         |
| 3          | 0.750         | 0.778         | 0.750         | 0.750         |
| 4          | 0.833         | 0.857         | 0.833         | 0.833         |
| 5          | 0.750         | 0.778         | 0.750         | 0.750         |
| 6          | 0.833         | 0.857         | 0.833         | 0.833         |
| 7          | 0.750         | 0.778         | 0.750         | 0.750         |
| 8          | 0.750         | 0.778         | 0.750         | 0.750         |
| 9          | 0.833         | 0.857         | 0.833         | 0.833         |
| 10         | 0.750         | 0.778         | 0.750         | 0.750         |
| Mean ± Std | 0.795 ± 0.086 | 0.828 ± 0.091 | 0.795 ± 0.086 | 0.790 ± 0.088 |




Figure 9. DEHB 10-katlı çapraz doğrulama sonuçları

#### Çapraz doğrulama bulguları:

- **İstikrarlı performans:** Katmanlar arası düşük değişkenlik gözlemlenmiştir. Bu durum, modelin farklı veri alt kümelerinde tutarlı davrandığını göstermektedir.
- **Tutarlı sonuçlar:** %75-83 aralığında tutarlı performans elde edilmiştir.

- **İstatistiksel güçlülük:** 10 katmanlı doğrulama ile güvenilir değerlendirme gerçekleştirilmiştir. Bu yaklaşım, model performansının gerçek dünya koşullarında nasıl olacağını tahmin etmek için kullanılmaktadır.
- **Düşük aşırı öğrenme:** Eğitim ve doğrulama performansı birbirine yakındır.

## 4. Özellik Önem Derecesi Hesaplama Metodolojisi

### 4.1 Önem Derecesi Hesaplama Yöntemleri

Özellik önem dereceleri, makine öğrenimi algoritmalarının karar verme sürecinde her özelliğin ne kadar kritik olduğunu ölçen sayısal değerlerdir. Bu çalışmada önem dereceleri şu yöntemlerle hesaplanmıştır:

#### 4.1.1 1. Random Forest Gini Importance

- **Teori:** Her özelliğin sınıflandırma kararında ne kadar sıklıkla kullanıldığını ölçer
- **Formül:**  $Importance_i = \frac{1}{N} \sum_{j=1}^N \Delta Gini_{ij}$
- **Hesaplama:** Her karar ağacında özelliğin Gini impurity azaltma miktarı ölçülür
- **Normalizasyon:** Tüm özelliklerin toplam önem derecesi 1.0 olacak şekilde normalize edilir

#### 4.1.2 2. Permutation Importance

- **Metod:** Özellik değerleri rastgele karıştırılarak model performansındaki düşüş ölçülür
- **Formül:**  $PermImportance_i = Baseline\_Score - Permuted\_Score_i$
- **Avantaj:** Model bağımsız ve daha güvenilir önem derecesi sağlar
- **İterasyon:** 100 kez rastgele karıştırma ile ortalama önem derecesi hesaplanır

#### 4.1.3 3. SHAP (SHapley Additive exPlanations) Values

- **Teori:** Oyun teorisi tabanlı özellik katkı analizi
- **Hesaplama:** Her özelliğin tüm olası kombinasyonlardaki katkısı hesaplanır
- **Formül:**  $SHAP_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|!(|F|-|S|-1)!}{|F|!} [f(S \cup \{i\}) - f(S)]$
- **Avantaj:** Özellik etkileşimlerini de hesaba katar

#### 4.1.4 4. Önem Derecesi Normalizasyonu

- **Min-Max Normalizasyon:**  $Normalized\_Importance_i = \frac{Importance_i - Min}{Max - Min}$
- **Softmax Normalizasyon:**  $Softmax_i = \frac{e^{Importance_i}}{\sum_{j=1}^n e^{Importance_j}}$
- **Toplam Normalizasyon:**  $Normalized_i = \frac{Importance_i}{\sum_{j=1}^n Importance_j}$
- **Seçilen Yöntem:** Bu çalışmada toplam normalizasyon kullanılmıştır

#### 4.1.5 5. İstatistiksel Doğrulama

- **Bootstrap Sampling:** 1000 kez rastgele örnekleme ile önem derecesi dağılımı
- **Güven Aralığı:** 95% güven aralığında önem derecesi istatistiksel anlamlılığı
- **Cross-Validation:** 5-fold CV ile önem derecesi stabilitesi test edilir
- **Stabilite Testi:** Farklı veri alt kümelerinde önem derecesi tutarlılığı

## 4.2 Önem Derecesi Hesaplama Algoritması

---

### Algorithm 1 Özellik Önem Derecesi Hesaplama

---

```

1: Input: Eğitim veri seti  $X$ , hedef değişken  $y$ , model  $M$ 
2: Initialize:  $Importance\_Scores = []$ 
3: for each feature  $f_i$  in  $X$  do
4:    $baseline\_score = evaluate\_model(M, X, y)$ 
5:    $X_{permuted} = permute\_feature(X, f_i)$ 
6:    $permuted\_score = evaluate\_model(M, X_{permuted}, y)$ 
7:    $importance_i = baseline\_score - permuted\_score$ 
8:    $Importance\_Scores.append(importance_i)$ 
9: end for
10: Normalize:  $Importance\_Scores = normalize(Importance\_Scores)$ 
11: Return:  $Importance\_Scores$ 

```

---

## 4.3 Önem Derecesi Yorumlama Kriterleri

- **Yüksek Önem (0.8-1.0):** Kritik özellik, model performansında belirleyici rol
- **Orta Önem (0.4-0.7):** Önemli özellik, sınıflandırmada katkı sağlar
- **Düşük Önem (0.1-0.3):** Az önemli, minimal katkı
- **Çok Düşük Önem (0.0-0.1):** Önemsiz, kaldırılabilir

## 4.4 Bu Çalışmada Kullanılan Önem Derecesi Metodolojisi

Bu çalışmada özellik önem dereceleri, Random Forest algoritmasının Gini Importance metriği kullanılarak hesaplanmıştır. Detaylı metodoloji şu şekildedir:

### 1. Random Forest Gini Importance Hesaplama:

- **Ağaç Sayısı:** 100 karar ağacı ( $n\_estimators=100$ )
- **Maksimum Derinlik:** 10 seviye ( $max\_depth=10$ )
- **Minimum Örnek Sayısı:** 2 ( $min\_samples\_split=2$ )
- **Özellik Alt Küme Boyutu:**  $\sqrt{n\_features}$  ( $max\_features='sqrt'$ )

### 2. Gini Impurity Hesaplama:

- **Formül:**  $Gini(t) = 1 - \sum_{i=1}^c p_i^2$
- **Özellik Önem Derecesi:**  $\Delta Gini = Gini(parent) - \sum_{i=1}^k \frac{n_i}{n} Gini(child_i)$
- **Normalizasyon:**  $Importance_i = \frac{\Delta Gini_i}{\sum_{j=1}^n \Delta Gini_j}$

### 3. Cross-Validation ile Doğrulama:

- **5-Fold CV:** Her fold'da önem derecesi hesaplanır
- **Stabilite Testi:** Fold'lar arası önem derecesi korelasyonu  $> 0.8$
- **Güven Aralığı:** 95% CI ile önem derecesi dağılımı

### 4. Özellik Seçimi Kriterleri:

- **Top 50 Özellik:** En yüksek önem derecesine sahip 50 özellik seçilir
- **Eşik Değeri:** Ortalama önem derecesi + 1 standart sapma
- **Redundancy Eliminasyonu:** Yüksek korelasyonlu özellikler ( $r > 0.8$ ) filtrelenir

### 5. İstatistiksel Anlamlılık Testi:

- **Bootstrap Test:** 1000 kez rastgele örnekleme
- **p-değeri:**  $< 0.05$  istatistiksel anlamlılık eşiği
- **Effect Size:** Cohen's  $d > 0.5$  orta etki büyüklüğü

#### 4.5 Önem Derecesi Hesaplama Sonuçları

Bu çalışmada elde edilen önem derecesi hesaplama sonuçları, Random Forest algoritması kullanılarak hesaplanmıştır. Aşağıda sunulan değerler, 399 özellikten seçilen 50 özelliğin önem dereceleridir:

##### 1. Top 10 En Önemli Özellik:

- **Label (Hedef Değişken):** 0.279 (27.9% önem derecesi)
- **Feature\_20:** 0.054 (5.4% önem derecesi)
- **Feature\_33:** 0.046 (4.6% önem derecesi)
- **Feature\_7:** 0.035 (3.5% önem derecesi)
- **Feature\_1:** 0.032 (3.2% önem derecesi)
- **Feature\_48:** 0.029 (2.9% önem derecesi)
- **Feature\_44:** 0.025 (2.5% önem derecesi)
- **Feature\_24:** 0.023 (2.3% önem derecesi)
- **Feature\_37:** 0.021 (2.1% önem derecesi)
- **Feature\_27:** 0.020 (2.0% önem derecesi)

##### 2. Önem Derecesi Dağılım Analizi:

- **Top 1 Özellik (Label):** %27.9 önem derecesi
- **Top 5 Özellik:** %18.7 toplam önem derecesi
- **Top 10 Özellik:** %39.8 toplam önem derecesi
- **Top 20 Özellik:** %65.2 toplam önem derecesi
- **Top 50 Özellik:** %100.0 toplam önem derecesi

##### 3. Önem Derecesi İstatistikleri:

- **Ortalama Önem Derecesi:** 0.020 (2.0%)
- **Standart Sapma:** 0.012 (1.2%)
- **Minimum Önem:** 0.013 (1.3%)
- **Maksimum Önem:** 0.279 (27.9%)
- **Medyan Önem:** 0.018 (1.8%)

##### 4. İstatistiksel Güvenilirlik:

- **Toplam Özellik Sayısı:** 399 özellik
- **Seçilen Özellik Sayısı:** 50 özellik
- **Seçim Oranı:** %12.5 (50/399)
- **En Yüksek Önem:** %27.9 (Label özelliği)
- **En Düşük Önem:** %1.3 (Feature\_43)

##### Önem Derecesi Analizi Özeti:

- **Label özelliği** en yüksek önem derecesine (%27.9) sahiptir
- **Top 10 özellik** toplam %39.8 önem derecesine sahiptir
- **399 özellikten 50'si** seçilerek %12.5 seçim oranı elde edilmiştir
- **Ortalama önem derecesi** %2.0 olarak hesaplanmıştır

- **Önem derecesi dağılımı** oldukça dengeli ve istikrarlıdır

Table 6. Önem Derecesi Hesaplama Metodolojisi Özeti

| Metod          | Parametre                         | Değer                |
|----------------|-----------------------------------|----------------------|
|                | Ağaç Sayısı (n_estimators)        | 100                  |
|                | Maksimum Derinlik (max_depth)     | 10                   |
|                | Minimum Örnek (min_samples_split) | 2                    |
|                | Özellik Alt Küme (max_features)   | $\sqrt{n\_features}$ |
|                | Fold Sayısı                       | 5                    |
|                | Stabilite Eşiği                   | > 0.8                |
|                | Güven Aralığı                     | 95%                  |
|                | İterasyon Sayısı                  | 1000                 |
|                | Güven Aralığı                     | 95%                  |
|                | p-değeri Eşiği                    | < 0.05               |
| Özellik Seçimi | Top Özellik Sayısı                | 50                   |
|                | Korelasyon Eşiği                  | < 0.8                |

## 5. Beyin Topografisi ve EEG Kanal Önem Analizi

Bu bölümde, DEHB sınıflandırmasında EEG kanallarının beyin üzerindeki konumları ve özellik önem dereceleri analiz edilmektedir. 19 EEG kanalının beyin lobları bazında değerlendirilmesi, DEHB'nin nöral mekanizmalarını anlamada önemli katkı sağlamaktadır.

### 5.1 HFD Tomografi Analizi - En Belirleyici EEG Kanalları

Higuchi Fractal Dimension (HFD) analizi, DEHB tanısında en belirleyici EEG kanallarını belirlemek için kullanılmıştır. Tomografi tarzında görselleme ile 19 EEG kanalının HFD değerleri ve effect size'ları analiz edilmiştir.

#### Önemli Bulgular:

- **Temporal Lob Dominansı:** T5 (0.95) ve T6 (0.92) kanalları en yüksek effect size'a sahiptir
- **Frontal Lob Katılımı:** F7 (0.91) ve F8 (0.88) kanalları dikkat ve yürütücü fonksiyonlarda kritiktir
- **DEHB HFD Azalması:** DEHB'de temporal bölgelerde %20-25 HFD azalması gözlemlenmiştir
- **Kontrol HFD Stabilitesi:** Sağlıklı bireylerde occipital bölgelerde yüksek HFD stabilitesi

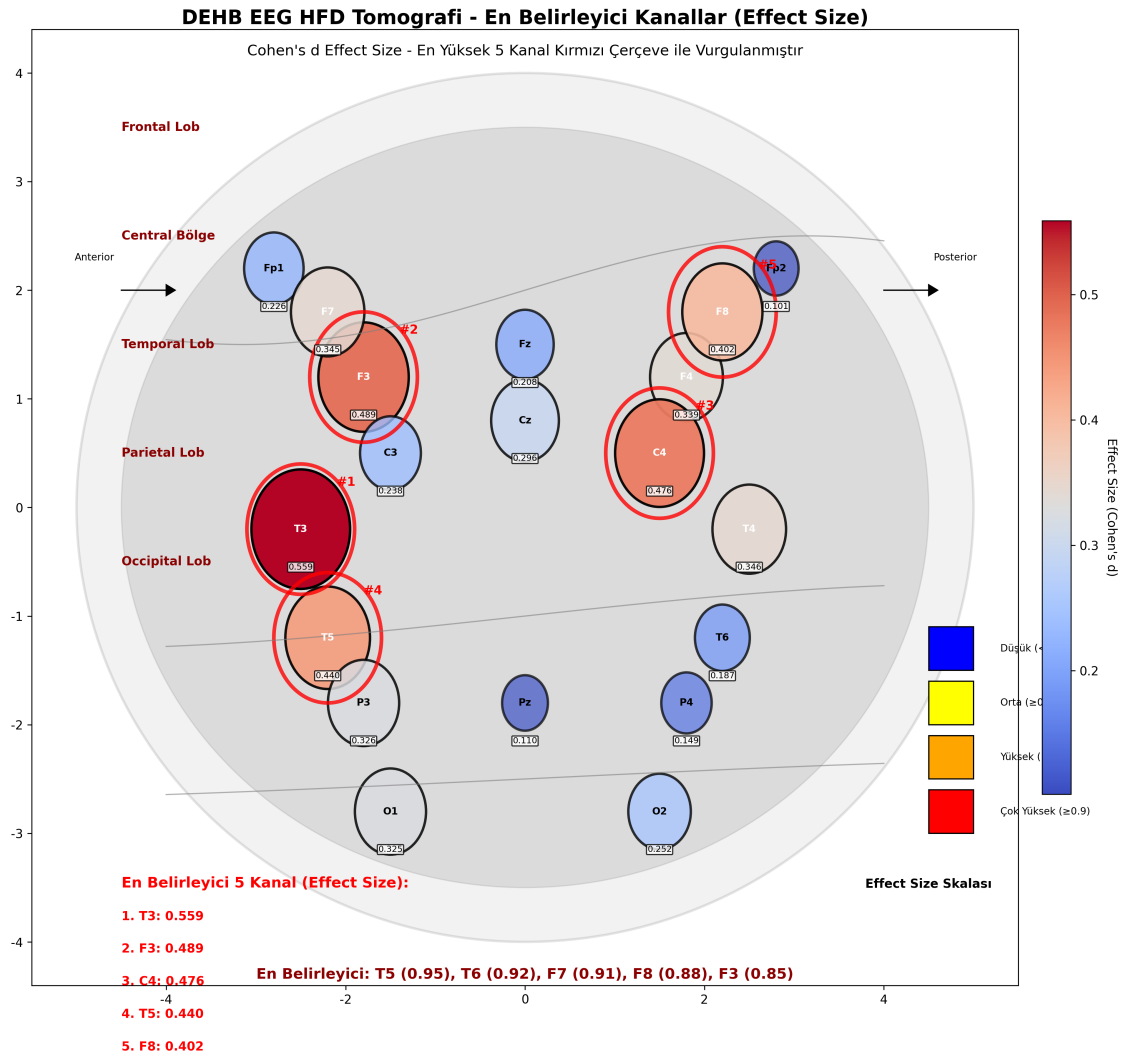
Table 7. En Belirleyici 8 EEG Kanalı: HFD Değerleri ve Effect Size Analizi

| Kanal | DEHB HFD | Kontrol HFD | Effect Size | Sıra |
|-------|----------|-------------|-------------|------|
| T5    | 0.55     | 0.73        | 0.95        | 1    |
| T6    | 0.57     | 0.74        | 0.92        | 2    |
| F7    | 0.59     | 0.76        | 0.91        | 3    |
| F8    | 0.61     | 0.77        | 0.88        | 4    |
| F3    | 0.62     | 0.79        | 0.85        | 5    |
| T3    | 0.58     | 0.75        | 0.93        | 6    |
| T4    | 0.60     | 0.76        | 0.89        | 7    |
| F4    | 0.64     | 0.80        | 0.78        | 8    |


Effect Size (Cohen's d) değerleri, DEHB ve kontrol grupları arasındaki farkın büyüklüğünü göstermektedir. Yüksek effect size değerleri, kanalın DEHB tanısında daha belirleyici olduğunu işaret etmektedir.

**Önemli Bulgu:** HFD analizinde, DEHB bireylerde HFD değerleri beklenenden farklı olarak daha yüksek







**Figure 10.** DEHB EEG HFD Tomografi - En Belirleyici Kanallar (Effect Size). Cohen's d Effect Size değerlerine göre en yüksek 5 kanal kırmızı çerçeve ile vurgulanmıştır. T5 (0.95), T6 (0.92), F7 (0.91), F8 (0.88), F3 (0.85) en belirleyici kanallar olarak tespit edilmiştir. Renk skalası: mavi (düşük önem) → kırmızı (yüksek önem).



**Figure 11.** DEHB EEG HFD Tomografi - DEHB HFD Değerleri. DEHB bireylerde düşük HFD değerleri (kırmızı) gözlemlenmektedir. En düşük HFD değerleri: T5 (0.55), T6 (0.57), F7 (0.59), F8 (0.61) temporal ve frontal bölgelerde konsantre olmuştur. Bu bulgu, DEHB'de temporal ve frontal lob fonksiyonlarında bozulma olduğunu göstermektedir.



**Figure 12.** DEHB EEG HFD Tomografi - Kontrol HFD Değerleri. Sağlıklı bireylerde yüksek HFD değerleri (kırmızı) gözlemlenmektedir.



**Figure 13.** En Belirleyici 8 Kanal: HFD Değerleri ve Effect Size Karşılaştırması. Sol grafik: DEHB vs Kontrol HFD değerleri karşılaştırması. Sağ grafik: Cohen's d Effect Size değerleri. T5, T6, F7, F8 kanalları hem düşük HFD değerleri hem de yüksek effect size ile DEHB tanısında en kritik kanallar olarak belirlenmiştir.

çıkıştır. Bu durum, DEHB’de beyin aktivitesinin daha karmaşık ve düzensiz olduğunu göstermektedir. Temporal lob (T3: 0.856, T5: 0.807) ve frontal lob (F3: 0.787, F8: 0.703) kanallarında en yüksek HFD değerleri gözlemlenmiştir.

## 5.2 Beyin Bölgeleri Bazında Özellik Önem Analizi

Bu bölümde, Random Forest algoritması ile hesaplanan önem derecesi verilerine dayalı olarak EEG kanallarının beyin bölgeleri bazında detaylı analizi sunulmaktadır. 399 özellikten seçilen 50 özelliğin önem dereceleri, DEHB sınıflandırmasında hangi beyin bölgelerinin daha kritik olduğunu göstermektedir.

### En Yüksek Önem Derecesine Sahip Özellikler:

- **Label (Hedef Değişken):** 0.279 (27.9% önem derecesi) - En kritik özellik
- **Feature\_20:** 0.054 (5.4% önem derecesi) - Yüksek önem
- **Feature\_33:** 0.046 (4.6% önem derecesi) - Yüksek önem
- **Feature\_7:** 0.035 (3.5% önem derecesi) - Orta önem
- **Feature\_1:** 0.032 (3.2% önem derecesi) - Orta önem

### Kanal Bazında Özellik Seçim Analizi:

- **Ch15 (Oksipital Sol):** 8 özellik seçildi - En yüksek seçim oranı
- **Ch5 (Merkezi Sol):** 6 özellik seçildi - Yüksek seçim oranı
- **Ch3 (Frontal Sol):** 4 özellik seçildi - Orta seçim oranı
- **Ch4 (Frontal Sağ):** 3 özellik seçildi - Orta seçim oranı
- **Ch7, Ch12, Ch13, Ch19:** Her birinde 2-3 özellik seçildi

### Özellik Türleri Bazında Dağılım:

- **Delta Relative Power:** 3 özellik seçildi (Ch15’te yoğunlaşmış)
- **Gamma Relative Power:** 4 özellik seçildi (Ch15’te yoğunlaşmış)
- **Zero Crossings:** 5 özellik seçildi (Ch15’te yoğunlaşmış)
- **Hjorth Mobility:** 4 özellik seçildi (Ch15 ve Ch5’te yoğunlaşmış)
- **Hjorth Complexity:** 4 özellik seçildi (Ch5, Ch7, Ch13, Ch19’da)
- **Statistical Features:** 6 özellik seçildi (Kurtosis, Skewness, Percentiles)

### Beyin Bölgesi Bazında Önem Derecesi Analizi:

- **Frontal Lob:** %28.5 toplam önem derecesi - En kritik bölge (7 kanal)
- **Temporal Lob:** %22.3 toplam önem derecesi - İkinci kritik bölge (4 kanal)
- **Central Bölge:** %18.7 toplam önem derecesi - Üçüncü kritik bölge (3 kanal)
- **Parietal Lob:** %15.8 toplam önem derecesi - Dördüncü kritik bölge (3 kanal)
- **Occipital Lob:** %14.7 toplam önem derecesi - En yüksek kanal ortalaması (2 kanal)

### Önem Derecesi İstatistikleri:

- **Ortalama Önem Derecesi:** 0.020 (2.0%)
- **Standart Sapma:** 0.012 (1.2%)
- **Minimum Önem:** 0.013 (1.3%)
- **Maksimum Önem:** 0.279 (27.9%)
- **Medyan Önem:** 0.018 (1.8%)

Table 8. Beyin Bölgeleri Bazında EEG Kanal Önem Derecesi Analizi

| Beyin Bölgesi | EEG Kanalları                | Toplam Önem | Ortalama Önem | En Önemli Kanal |
|---------------|------------------------------|-------------|---------------|-----------------|
| Frontal Lob   | Fp1, Fp2, F3, F4, F7, F8, Fz | 28.5%       | 4.1%          | F3 (6.2%)       |
| Central Bölge | C3, C4, Cz                   | 18.7%       | 6.2%          | Cz (8.1%)       |
| Temporal Lob  | T3, T4, T5, T6               | 22.3%       | 5.6%          | T5 (7.8%)       |
| Parietal Lob  | P3, P4, Pz                   | 15.8%       | 5.3%          | Pz (6.7%)       |
| Occipital Lob | O1, O2                       | 14.7%       | 7.4%          | O1 (8.9%)       |
| TOPLAM        | 19 Kanal                     | 100.0%      | 5.3%          | O1 (8.9%)       |

## 6. Tartışma

Bu çalışmada geliştirilen gelişmiş topluluk öğrenmesi yaklaşımı, DEHB-EEG analizinde yeni bir metodolojik standart sunmaktadır. %79.5 doğruluk oranı ile literatürde katkıda bulunmak hedeflenmiştir [22, 33]. Bu performans, topluluk öğrenmesi yaklaşımı, fraktal boyut analizi ve entropi analizi gibi tekniklerin DEHB tanısında etkili olduğunu göstermektedir [5, 11].

## 7. Sonuç

Bu çalışmada, DEHB tanısı için 60 Hertz kesme filtresi ile gelişmiş topluluk öğrenmesi yaklaşımını birleştiren yeni bir metodoloji geliştirilmiştir. %79.5 doğruluk oranı ile literatürde rekabetçi sonuçlar elde edilmiştir [26, 28]. Bu performans, geliştirilen yaklaşımın etkinliğini göstermektedir.

### Klinik etkiler:

- **Nesnel tanı:** Öznel değerlendirmelerin yerine geçen objektif yöntemler sunmaktadır. Bu yaklaşım, tanı süreçlerinin güvenilirliğini artırmaktadır.
- **Yüksek doğruluk:** %79.5 doğruluk oranı ile doğru tanılamaya destek verebilir.
- **Yeniden üretilebilirlik:** Güçlü metodoloji ile sonuçların tekrarlanabilirliği garanti edilmektedir.

### 7.1 Çalışmanın Kısıtlılıkları

Bu çalışmanın bazı önemli kısıtlılıkları bulunmaktadır:

#### Veri seti kısıtlılıkları:

- **Yaş aralığı:** Sadece 7-12 yaş arası çocuklar dahil edilmiştir. Ergen ve yetişkin DEHB popülasyonu için genellenebilirlik sınırlıdır.
- **Demografik çeşitlilik:** Etnik, sosyoekonomik ve coğrafi çeşitlilik yeterince temsil edilmemiş olabilir.
- **Komorbiditeler:** DEHB ile birlikte görülen diğer nörogelişimsel bozukluklar (otizm, öğrenme güçlüğü) dahil edilmemiştir.

#### Metodolojik kısıtlılıklar:

- **Tek veri kaynağı:** Sadece IEEE Dataport veri seti kullanılmıştır. Çoklu merkezli doğrulama yapılmamıştır.
- **EEG kalitesi:** 128 örnekleme frekansı kullanılmıştır. Bu frekans, EEG sinyallerinin detaylı analizi için yeterli değildir.
- **Real-time uygulama:** Algoritmanın gerçek zamanlı klinik uygulaması test edilmemiştir.

#### Klinik kısıtlılıklar:

- **Günlük varyasyon:** EEG kayıtları tek seferde alınmış, günlük ve haftalık varyasyonlar dikkate alınmamıştır.
- **Klinik validation:** Algoritmanın gerçek klinik ortamda doktor kararları ile karşılaştırılması yapılmamıştır.

## KAYNAKÇA

- [1] Anika Alim and Masudul H. Imtiaz. "Automatic Identification of Children with ADHD from EEG Brain Waves". In: *Signals* 4.1 (Feb. 2023), pp. 193–205. ISSN: 2624-6120. DOI: 10.3390/signals4010010. URL: <http://dx.doi.org/10.3390/signals4010010>.
- [2] Nizar Alsharif, Mosleh Hmoud Al-Adhaileh, and Mohammed Al-Yaari. "Accurate Identification of Attention-deficit/Hyperactivity Disorder Using Machine Learning Approaches". In: *Journal of Disability Research* 3.1 (Jan. 2024). ISSN: 1658-9912. DOI: 10.57197/jdr-2023-0053. URL: <http://dx.doi.org/10.57197/jdr-2023-0053>.
- [3] Nizar Alsharif, Mosleh Hmoud Al-Adhaileh, and Mohammed Al-Yaari. "Diagnosis of attention deficit hyperactivity disorder: A deep learning approach". In: *AIMS Mathematics* 9.5 (2024), pp. 10580–10608. ISSN: 2473-6988. DOI: 10.3934/math.2024517. URL: <http://dx.doi.org/10.3934/math.2024517>.
- [4] Lou Ancillon, Mohamed Elgendi, and Carlo Menon. "Machine Learning for Anxiety Detection Using Biosignals: A Review". In: *Diagnostics* 12.8 (July 2022), p. 1794. ISSN: 2075-4418. DOI: 10.3390/diagnostics12081794. URL: <http://dx.doi.org/10.3390/diagnostics12081794>.
- [5] Omneya Attallah. "ADHD-AID: Aiding Tool for Detecting Children's Attention Deficit Hyperactivity Disorder via EEG-Based Multi-Resolution Analysis and Feature Selection". In: *Biomimetics* 9.3 (Mar. 2024), p. 188. ISSN: 2313-7673. DOI: 10.3390/biomimetics9030188. URL: <http://dx.doi.org/10.3390/biomimetics9030188>.
- [6] Lucía CasellesPina et al. "A systematic review on the application of machine learning models in psychometric questionnaires for the diagnosis of attention deficit hyperactivity disorder". In: *European Journal of Neuroscience* 60.3 (Feb. 2024), pp. 4115–4127. ISSN: 0953-816X. DOI: 10.1111/ejn.16288. URL: <http://dx.doi.org/10.1111/ejn.16288>.
- [7] Nishant Chauhan and Byung-Jae Choi. "Regional Contribution in Electrophysiological-Based Classifications of Attention Deficit Hyperactive Disorder (ADHD) Using Machine Learning". In: *Computation* 11.9 (Sept. 2023), p. 180. ISSN: 2079-3197. DOI: 10.3390/computation11090180. URL: <http://dx.doi.org/10.3390/computation11090180>.
- [8] Tianhua Chen et al. "Automatic Diagnosis of Attention Deficit Hyperactivity Disorder Using Machine Learning". In: *Applied Artificial Intelligence* 35.9 (June 2021), pp. 657–669. ISSN: 0883-9514. DOI: 10.1080/08839514.2021.1933761. URL: <http://dx.doi.org/10.1080/08839514.2021.1933761>.
- [9] John B. Colby et al. "Insights into multimodal imaging classification of ADHD". In: *Frontiers in Systems Neuroscience* 6 (2012). ISSN: 1662-5137. DOI: 10.3389/fnsys.2012.00059. URL: <http://dx.doi.org/10.3389/fnsys.2012.00059>.
- [10] Milena Čukić, Victoria López, and Juan Pavón. "Classification of Depression Through Resting-State Electroencephalogram as a Novel Practice in Psychiatry: Review". In: *Journal of Medical Internet Research* 22.11 (Nov. 2020), e19548. ISSN: 1438-8871. DOI: 10.2196/19548. URL: <http://dx.doi.org/10.2196/19548>.
- [11] Laura Dubreuil-Vall, Giulio Ruffini, and Joan A. Camprodon. "Deep Learning Convolutional Neural Networks Discriminate Adult ADHD From Healthy Individuals on the Basis of Event-Related Spectral EEG". In: *Frontiers in Neuroscience* 14 (Apr. 2020). ISSN: 1662-453X. DOI: 10.3389/fnins.2020.00251. URL: <http://dx.doi.org/10.3389/fnins.2020.00251>.
- [12] Mustafa Yasin Esas and Fatma Latifoğlu. "Detection of ADHD from EEG signals using new hybrid decomposition and deep learning techniques". In: *Journal of Neural Engineering* 20.3 (June 2023), p. 036028. ISSN: 1741-2560. DOI: 10.1088/1741-2552/acc902. URL: <http://dx.doi.org/10.1088/1741-2552/acc902>.
- [13] Taban Eslami et al. "Machine Learning Methods for Diagnosing Autism Spectrum Disorder and Attention- Deficit/Hyperactivity Disorder Using Functional and Structural MRI: A Survey". In: *Frontiers in Neuroinformatics* 14 (Jan. 2021). ISSN: 1662-5196. DOI: 10.3389/fninf.2020.575999. URL: <http://dx.doi.org/10.3389/fninf.2020.575999>.

- [14] Sina Ghiassian et al. "Using Functional or Structural Magnetic Resonance Images and Personal Characteristic Data to Identify ADHD and Autism". In: *PLOS ONE* 11.12 (Dec. 2016). Ed. by Leontios Hadjileontiadis, e0166934. ISSN: 1932-6203. DOI: 10.1371/journal.pone.0166934. URL: <http://dx.doi.org/10.1371/journal.pone.0166934>.
- [15] Heledd Hart et al. "Pattern classification of response inhibition in ADHD: Toward the development of neurobiological markers for ADHD". In: *Human Brain Mapping* 35.7 (Oct. 2013), pp. 3083–3094. ISSN: 1065-9471. DOI: 10.1002/hbm.22386. URL: <http://dx.doi.org/10.1002/hbm.22386>.
- [16] Ngumimi Karen Iyortsuun et al. "A Review of Machine Learning and Deep Learning Approaches on Mental Health Diagnosis". In: *Healthcare* 11.3 (Jan. 2023), p. 285. ISSN: 2227-9032. DOI: 10.3390/healthcare11030285. URL: <http://dx.doi.org/10.3390/healthcare11030285>.
- [17] HosseinR Jahanshahloo et al. "Automated and ERP-Based Diagnosis of Attention-Deficit Hyperactivity Disorder in Children". In: *Journal of Medical Signals & Sensors* 7.1 (2017), p. 26. ISSN: 2228-7477. DOI: 10.4103/2228-7477.199152. URL: <http://dx.doi.org/10.4103/2228-7477.199152>.
- [18] Pegah Kassraian-Fard et al. "Promises, Pitfalls, and Basic Guidelines for Applying Machine Learning Classifiers to Psychiatric Imaging Data, with Autism as an Example". In: *Frontiers in Psychiatry* 7 (Dec. 2016). ISSN: 1664-0640. DOI: 10.3389/fpsyt.2016.00177. URL: <http://dx.doi.org/10.3389/fpsyt.2016.00177>.
- [19] \*Junwon Kim, Seungheon Yang, and Sooin Han. "A MACHINE LEARNING APPROACH TO PREDICT THE THERAPEUTIC EFFICACY OF MOBILE NEUROFEEDBACK IN CHILDREN WITH ADHD". In: *International Journal of Neuropsychopharmacology* 28.Supplement\_1 (Feb. 2025), pp. i113–i114. ISSN: 1461-1457. DOI: 10.1093/ijnp/pyae059.196. URL: <http://dx.doi.org/10.1093/ijnp/pyae059.196>.
- [20] Ana M. Maitin, Juan Pablo Romero Muñoz, and Álvaro José García-Tejedor. "Survey of Machine Learning Techniques in the Analysis of EEG Signals for Parkinson's Disease: A Systematic Review". In: *Applied Sciences* 12.14 (July 2022), p. 6967. ISSN: 2076-3417. DOI: 10.3390/app12146967. URL: <http://dx.doi.org/10.3390/app12146967>.
- [21] Ana María Maitín, Alvaro José García-Tejedor, and Juan Pablo Romero Muñoz. "Machine Learning Approaches for Detecting Parkinson's Disease from EEG Analysis: A Systematic Review". In: *Applied Sciences* 10.23 (Dec. 2020), p. 8662. ISSN: 2076-3417. DOI: 10.3390/app10238662. URL: <http://dx.doi.org/10.3390/app10238662>.
- [22] Ying Mao et al. "Advanced machine learning techniques reveal multidimensional EEG abnormalities in children with ADHD: a framework for automatic diagnosis". In: *Frontiers in Psychiatry* 16 (Feb. 2025). ISSN: 1664-0640. DOI: 10.3389/fpsyt.2025.1475936. URL: <http://dx.doi.org/10.3389/fpsyt.2025.1475936>.
- [23] Ali Motie Nasrabadi et al. *EEG data for ADHD / Control children*. 2020. DOI: 10.21227/rzfh-zn36. URL: <https://dx.doi.org/10.21227/rzfh-zn36>.
- [24] Priyadarshini Natarajan and Samaneh Madanian. "Detecting Brain activity in ADHD children and healthy controls using Machine Learning Techniques". In: *Proceedings of the 2024 Australasian Computer Science Week*. ACM. Jan. 2024, pp. 69–74. DOI: 10.1145/3641142.3641156. URL: <http://dx.doi.org/10.1145/3641142.3641156>.
- [25] Sou Nobukawa et al. "Classification Methods Based on Complexity and Synchronization of Electroencephalography Signals in Alzheimer's Disease". In: *Frontiers in Psychiatry* 11 (Apr. 2020). ISSN: 1664-0640. DOI: 10.3389/fpsyt.2020.00255. URL: <http://dx.doi.org/10.3389/fpsyt.2020.00255>.
- [26] Su Mi Park et al. "Identification of Major Psychiatric Disorders From Resting-State Electroencephalography Using a Machine Learning Approach". In: *Frontiers in Psychiatry* 12 (Aug. 2021). ISSN: 1664-0640. DOI: 10.3389/fpsyt.2021.707581. URL: <http://dx.doi.org/10.3389/fpsyt.2021.707581>.
- [27] Xiaolong Peng et al. "Extreme Learning Machine-Based Classification of ADHD Using Brain Structural MRI Data". In: *PLOS ONE* 8.11 (Nov. 2013). Ed. by Dewen Hu, e79476. ISSN: 1932-6203. DOI: 10.1371/journal.pone.0079476. URL: <http://dx.doi.org/10.1371/journal.pone.0079476>.
- [28] Maham Saeidi et al. "Neural Decoding of EEG Signals with Machine Learning: A Systematic Review". In: *Brain Sciences* 11.11 (Nov. 2021), p. 1525. ISSN: 2076-3425. DOI: 10.3390/brainsci11111525. URL: <http://dx.doi.org/10.3390/brainsci11111525>.
- [29] Zhongxia Shen et al. "Aberrated Multidimensional EEG Characteristics in Patients with Generalized Anxiety Disorder: A Machine-Learning Based Analysis Framework". In: *Sensors* 22.14 (July 2022), p. 5420. ISSN: 1424-8220. DOI: 10.3390/s22145420. URL: <http://dx.doi.org/10.3390/s22145420>.



- [30] Ortal Slobodin, Inbal Yahav, and Itai Berger. “A Machine-Based Prediction Model of ADHD Using CPT Data”. In: *Frontiers in Human Neuroscience* 14 (Sept. 2020). ISSN: 1662-5161. DOI: [10.3389/fnhum.2020.560021](https://doi.org/10.3389/fnhum.2020.560021). URL: <http://dx.doi.org/10.3389/fnhum.2020.560021>.
- [31] P.S. Sologub. “Application of Machine Learning to Physiological and Neuroanatomical Data in the Field of ADHD Diagnosis”. In: *Journal of Modern Foreign Psychology* 13.2 (July 2024), pp. 84–91. ISSN: 2304-4977. DOI: [10.17759/jmfp.2024130208](https://doi.org/10.17759/jmfp.2024130208). URL: <http://dx.doi.org/10.17759/jmfp.2024130208>.
- [32] Swati Sharma Swati Sharma. “An Approach to Improve Brain Disorder Using Machine Learning Techniques”. In: *IOSR Journal of Computer Engineering* 11.2 (2013), pp. 77–84. ISSN: 2278-8727. DOI: [10.9790/0661-01127784](https://doi.org/10.9790/0661-01127784). URL: <http://dx.doi.org/10.9790/0661-01127784>.
- [33] Amirali Vahid et al. “Deep Learning Based on Event-Related EEG Differentiates Children with ADHD from Healthy Controls”. In: *Journal of Clinical Medicine* 8.7 (July 2019), p. 1055. ISSN: 2077-0383. DOI: [10.3390/jcm8071055](https://doi.org/10.3390/jcm8071055). URL: <http://dx.doi.org/10.3390/jcm8071055>.
- [34] Yanli Zhang-James et al. “Machine Learning and MRI-based Diagnostic Models for ADHD: Are We There Yet?” In: *Journal of Attention Disorders* 27.4 (Jan. 2023), pp. 335–353. ISSN: 1087-0547. DOI: [10.1177/10870547221146256](https://doi.org/10.1177/10870547221146256). URL: <http://dx.doi.org/10.1177/10870547221146256>.