



POLİTEKNİK DERGİSİ

*JOURNAL of POLYTECHNIC*

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



**Epileptik nöbet tespiti için yüksek çözünürlüklü güç spektral yoğunluğu yaklaşımları**

*High-resolution power spectral density approaches for epileptic seizure detection*

*Yazar(lar) (Author(s)):* Nuri İKİZLER<sup>1</sup>, Güneş EKİM<sup>2</sup>

*ORCID<sup>1</sup>:* 0000-0002-7632-1973

*ORCID<sup>2</sup>:* 0000-0003-4867-3100

**To cite to this article:** İkizler N. ve Ekim G., “Epileptik nöbet tespiti için yüksek çözünürlüklü güç spektral yoğunluğu yaklaşımları”, *Journal of Polytechnic*, \*(\*) : \*, (\*).

**Bu makaleye şu şekilde atıfta bulunabilirsiniz:** İkizler N. ve Ekim G., “Epileptik nöbet tespiti için yüksek çözünürlüklü güç spektral yoğunluğu yaklaşımları”, *Politeknik Dergisi*, \*(\*) : \*, (\*).

**Erişim linki (To link to this article):** <http://dergipark.org.tr/politeknik/archive>

**DOI:** 10.2339/politeknik.1605362

# Epileptik Nöbet Tespiti İçin Yüksek Çözünürlüklü Güç Spektral Yoğunluğu Yaklaşımları


## High-Resolution Power Spectral Density Approaches For Epileptic Seizure Detection

### Önemli noktalar (Highlights)

- ❖ Çalışma, yüksek çözünürlüklü PSD yöntemlerinin epileptik nöbet tespitinde etkili olduğunu vurgular./ The study highlights that high-resolution PSD methods are effective in detecting epileptic seizures.
- ❖ Çalışma, spektral enerji ve entropi farkının, nöbet tespiti için kritik özellikler olduğunu gösterir./ The study demonstrates that spectral energy and entropy differences are critical features for seizure detection.
- ❖ Çalışma, epileptik nöbet tespitinde doğruluğu artıran yeni yöntemler sunmaktadır./ The study presents new methods that increase accuracy in epileptic seizure detection.
- ❖ PSD yöntemlerinin RF ve k-NN ile çok sınıflı nöbet tespitinde yüksek doğruluk sağladığı gösterilmiştir./ PSD methods have been shown to provide high accuracy in multi-class seizure detection with RF and k-NN.

### Grafik Özet (Graphical Abstract)

Epileptik nöbet tespiti için çeşitli PSD yöntemleri ve sınıflandırıcılar kullanılarak farklı analizler yapılmıştır./ Different analyses have been performed using various PSD methods and classifiers for epileptic seizure detection.



Şekil. Çeşitli PSD yöntemleri ile nöbet tespiti /Figure. Seizure detection with various PSD methods

### Amaç (Aim)

Epileptik nöbetlerin otomatik tespiti için yüksek çözünürlüklü güç spektral yoğunluğu yöntemleri ve sınıflandırıcıların etkileşimlerini inceleyerek doğruluğu artıran parametreleri belirlemek. / To identify parameters that enhance accuracy in the automatic detection of epileptic seizures by analyzing the interaction between high-resolution power spectral density methods and classifiers.

### Tasarım ve Yöntem (Design & Methodology)

Music ve Lomb-Scargle gibi yüksek çözünürlüklü PSD yöntemleri ile RF ve k-NN sınıflandırıcıları birleştirilerek, spektral özelliklere dayalı çok sınıflı nöbet tespiti yapılmıştır. / High-resolution PSD methods such as Music and Lomb-Scargle were combined with RF and k-NN classifiers to perform multi-class seizure detection based on spectral features.

### Özgünlük (Originality)

Epileptik nöbet tespitinde PSD yöntemlerinin ve spektral özelliklerin sınıflandırıcı performansına etkisi analiz edilmiştir. / The effects of PSD methods and spectral features on classifier performance in epileptic seizure detection were analyzed.

### Bulgular (Findings)

Music ve Lomb-Scargle yöntemleri ile RF kombinasyonları, nöbet tespitinde en yüksek doğruluk oranlarını sağlamıştır. / Combinations of Music and Lomb-Scargle methods with the RF achieved the highest accuracy rates in seizure detection.

### Sonuç (Conclusion)

Yüksek çözünürlüklü PSD yöntemleri ve topluluk öğrenme temelli sınıflandırıcıların bir arada kullanımı, epileptik nöbet tespiti için etkili ve güvenilir bir yaklaşım sunmaktadır. / The integration of high-resolution PSD methods and ensemble learning-based classifiers offers an effective and reliable approach for epileptic seizure detection.

### Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

# Epiliktik Nöbet Tespiti İçin Yüksek Çözünürlüklü Güç Spektral Yoğunluğu Yaklaşımları

*Araştırma Makalesi / Research Article*

Nuri İKİZLER<sup>1\*</sup>, Güneş EKİM<sup>1</sup>

<sup>1</sup>Trabzon Meslek Yüksekokulu, Elektronik ve Otomasyon Bölümü, Karadeniz Teknik Üniversitesi, Türkiye  
(Geliş/Received : 22.12.2024 ; Kabul/Accepted : 21.01.2025 ; Erken Görünüm/Early View : 08.02.2025)

## ÖZ

Epilipsi, dünya çapında milyonlarca insanı etkileyen bir nörolojik hastalık olup, epileptik nöbetlerin hızlı ve doğru bir şekilde tespiti, hastaların yaşam kalitesini artırmada büyük öneme sahiptir. Bu çalışmada, EEG sinyallerinden epileptik nöbet tespiti için çeşitli güç spektral yoğunluğu yöntemleri ve sınıflandırıcılar kullanılarak farklı analizler yapılmıştır. Her bir yöntemin spektral çözünürlük ve frekans bileşenlerini ayırt etme yeteneklerinin gösterdiği değişikliği tespit etmek için Music, Lomb-Scargle, Multitaper, Welch, Periodogram, Burg gibi farklı yöntemler denenmiştir. Her sınıf için referans sinyaller oluşturulmuş, bu referans sinyallerle karşılaştırılarak spektral enerji, spektral entropi ve maksimum spektral sapma gibi ayırt edici özellikler çıkarılmıştır. Bu öznelik vektörleri, sınıflandırıcı olarak seçilen Rastgele Orman ve k-En Yakın Komşu algoritmalarında kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen sonuçlara göre, yüksek çözünürlüklü güç spektral yoğunluğu yöntemleri olan Music ve Lomb-Scargle ile Rastgele Orman sınıflandırıcısı en yüksek doğruluğa ulaşmıştır. Bu çalışma, epileptik nöbet tespiti alanında yüksek çözünürlüklü güç spektral yoğunluğu yöntemleri ve güçlü topluluk öğrenme tabanlı sınıflandırıcıların birlikte kullanımının, nöbet tespit doğruluğunu anlamlı şekilde artırabileceğini ortaya koyarak literatüre önemli bir katkı sunmaktadır.

**Anahtar Kelimeler:** Epiliktik nöbet tespiti, Music yöntemi, Lomb-Scargle yöntemi, rastgele orman sınıflandırıcısı.

## High-Resolution Power Spectral Density Approaches For Epilictic Seizure Detection

### ABSTRACT

Epilipsy is a neurological disorder that affects millions of people worldwide, and the rapid and accurate detection of epileptic seizures is crucial in improving patients' quality of life. This study performs various analyses using different power spectral density methods and classifiers for epileptic seizure detection from EEG signals. Methods such as Music, Lomb-Scargle, Multitaper, Welch, Periodogram, and Burg are tested to identify changes in their ability to distinguish spectral resolution and frequency components. Reference signals are created for each class, and discriminative features such as spectral energy, spectral entropy, and maximum spectral deviation are extracted by comparing these reference signals. These feature vectors are used in classification with Random Forest and k-Nearest Neighbor algorithms. The results indicate that the high-resolution spectral power density methods, Music and Lomb-Scargle, along with the Random Forest classifier, achieved the highest accuracy. This study makes a significant contribution to the literature by demonstrating that the combined use of high-resolution spectral power density methods and powerful ensemble learning-based classifiers can significantly improve seizure detection accuracy.

**Keywords:** Epilictic seizure detection, Music method, Lomb-Scargle method, random forest classifier.

### 1. GİRİŞ (INTRODUCTION)

Epilipsi, beyin nöronlarının anormal ve aşırı elektriksel aktivitesi sonucu ortaya çıkan, nörolojik bir bozukluktur. Bu durum, geçici bilinç kaybı, istemsiz kasılmalar, duyuşal değişiklikler ve bazen de davranışsal değişikliklerle kendini gösteren epileptik nöbetlerle karakterizedir. Nöbetler, beyin bölgelerindeki elektriksel düzensizliklerin türüne, şiddetine ve yayılımına bağlı olarak farklı biçimlerde görülebilir. Örneğin, fokal nöbetler yalnızca belirli bir beyin bölgesinde başlarken, jeneralize nöbetler her iki hemisferi etkileyerek daha geniş çaplı semptomlara yol açabilir. Nöbetlerin tipi ve süresi hastadan hastaya değişiklik göstermekle birlikte, bu durumun hayat kalitesine olan olumsuz etkisi büyüktür [1]. Epilipsi, özellikle nöbetlerin öngörülemezliği nedeniyle bireylerde sosyal izolasyon, iş gücü kaybı ve psikolojik sorunlara yol açabilmektedir.

Bu nedenle, epilepsi tanı ve tedavisinde nöbetlerin doğru bir şekilde tanımlanması ve sınıflandırılması büyük önem taşır. Epiliktik nöbetlerin otomatik olarak tespit edilmesi, klinik değerlendirme süreçlerini hızlandırarak ve sürekli izlem ihtiyacını azaltarak hem sağlık hizmetlerinin etkinliğini artırmakta hem de hastaların güvenliğini sağlamaktadır [2].

Günümüzde elektroensefalografi (EEG) verilerine dayalı otomatik nöbet tespit sistemleri, epilepsi yönetiminde devrim niteliğinde bir katkı sunmaktadır. EEG cihazları, beyin elektriksel aktivitesini izleyerek beyin dalgalarındaki anormal aktiviteleri kaydeder. Bu kayıtlardaki belirgin paternler, epileptik nöbetlerin tanımlanmasında önemli ipuçları sağlar. Otomatik tespit sistemleri, EEG sinyallerindeki bu anormallikleri algılamak üzere tasarlanmış algoritmalarından yararlanır. Özellikle makine öğrenmesi ve yapay zekâ destekli

algoritmalar, bu sinyalleri analiz edip nöbet başlangıcını gerçek zamanlı olarak tespit edebilmektedir [3].

Bu tür sistemler, geleneksel yöntemlerden farklı olarak, nöbetlerin gözden kaçma riskini azaltır ve nöbet tespitini hızlandırır. Klinik ortamlarda sürekli EEG izleme imkânı olmayan hastalar için bu sistemler, nöbetlerin ev ortamında bile güvenilir bir şekilde izlenmesine olanak tanır. Böylece, nöbet başlangıcının anında tespiti mümkün olur ve hastaların veya bakıcıların hızla müdahale edebilmesine olanak sağlar. Özellikle ciddi nöbet durumlarında hızlı müdahale, nöbetin şiddetini ve süresini azaltabilir, hatta bazen hayati önem taşıyan komplikasyonların önüne geçebilir [4].

Ayrıca, otomatik nöbet tespit sistemleri doktorların tedavi süreçlerini daha etkin bir şekilde yönetmelerine yardımcı olur. Örneğin, nöbet frekansı, süresi ve zamanı hakkında düzenli veri sağlayarak tedavi düzenlemelerinde daha hassas ve kişiye özel ayarlamalar yapılmasını sağlar. Böylelikle, ilaç dozajlarının ve tedavi yöntemlerinin optimizasyonu mümkün hale gelir. Nöbetlerin izlenmesi, aynı zamanda tedaviye verilen yanıtın değerlendirilmesine ve epilepsi hastalarının yaşam kalitesinin artırılmasına yönelik kritik bilgiler sunar. Sonuç olarak, bu sistemler epilepsi yönetimini kolaylaştırır ve hastaların daha bağımsız ve güvenli bir yaşam sürmelerine katkıda bulunur.

Epileptik nöbetlerin otomatik tespiti için geliştirilmiş algoritmalar ve yöntemler, EEG verilerinin analiz edilmesi ve nöbet paternlerinin algılanması üzerine odaklanmıştır. Bu amaçla çeşitli sinyal işleme teknikleri, makine öğrenimi yöntemleri ve derin öğrenme modelleri yaygın olarak kullanılmaktadır [5]. EEG sinyallerindeki frekans bileşenlerinin analiz edilmesi, nöbet başlangıcını tespit etmede önemlidir. Yaygın olarak kullanılan yöntemlerden biri olan Fourier Dönüşümü, EEG sinyalinin frekans spektrumunu çıkararak nöbet sırasındaki anormal frekans bileşenlerini belirler. Özellikle, Welch ve periodogram gibi spektral yoğunluk tahmin yöntemleri, frekans analizi için tercih edilir [6]. Spektral analiz, özellikle belirli frekans bantlarında meydana gelen değişiklikleri hassas bir şekilde tespit etmede kullanılır.

EEG sinyallerinin hem zaman hem de frekans bilgisini içermesi nedeniyle, Dalgacık Dönüşümü nöbet tespitinde sıkça kullanılmaktadır. Dalgacık Dönüşümü, EEG sinyalini farklı zaman-frekans çözünürlüğünde analiz ederek geçici sinyallerin (örneğin nöbet anındaki kısa süreli yüksek frekans bileşenlerinin) tanımlanmasını sağlar. Özellikle, Ayrık Dalgacık Dönüşümü (DWT) gibi ayrık dalgacık yöntemleri, nöbet ve nöbet dışı durumların ayrımında yüksek doğruluk sağlamaktadır [7-9]. EEG sinyallerinin modellenmesinde kullanılan bir diğer yöntem, Doğrusal Öngörümlere Kodlamadır (LPC). Bu yöntem, sinyalin bir dizi doğrusal kombinasyonla temsil edilmesini sağlar ve nöbet sırasındaki spektral değişiklikleri yakalamada etkilidir. LPC tabanlı özellik çıkarımı, nöbetlerin tespit edilmesi için faydalı olan spektral paternleri belirlemede öne çıkmaktadır [10].

EEG sinyallerindeki belirli istatistiksel özellikler (ortalama, varyans, çarpıklık, basıklık) ve zaman-frekans işaretleri nöbetlerin belirlenmesinde yardımcıdır. Bu özellikler, özellikle sınıflandırma algoritmalarına girdi olarak verilerek nöbet ve nöbet dışı durumların ayrımını sağlamaktadır. Zaman bölgesi özellikleri, basitliği ve hızlı hesaplanabilirliği nedeniyle tercih edilir [11].

Destek Vektör Makineleri (SVM), k-En Yakın Komşu (k-NN), Rastgele Orman (RF) ve Naive Bayes (NB) gibi makine öğrenmesi algoritmaları, EEG verilerinde nöbet paternlerini tespit etmek için yaygın olarak kullanılmaktadır [12]. Bu algoritmalar, EEG sinyallerinden çıkarılan özellikleri öğrenerek nöbet ile normal durum arasındaki farkı sınıflandırır. Özellikle, RF, k-NN ve SVM, yüksek doğruluk oranları sunarak nöbet tespitinde sıklıkla tercih edilmektedir [13].

Son yıllarda, yapay sinir ağları ve özellikle derin öğrenme yöntemleri, otomatik nöbet tespitinde yüksek performans göstermektedir. Geleneksel Sinir Ağları (CNN), EEG sinyallerinin özelliklerini otomatik olarak çıkararak nöbetlerin tespit edilmesini sağlar. Ayrıca, Tekrarlayan Sinir Ağları (RNN) ve Uzun-Kısa Dönem Hafıza (LSTM) ağları, EEG sinyallerindeki ardışık zamansal paternleri yakalamada oldukça başarılıdır. Derin öğrenme modelleri, büyük veri kümeleri üzerinde eğitildiğinde, nöbetlerin yüksek doğrulukla tanınmasını sağlamaktadır [14, 15].

Bazı çalışmalarda ise, farklı yöntemler birleştirilerek hibrit sistemler oluşturulmuştur. Örneğin, dalgacık dönüşümüyle elde edilen özellikler SVM veya RF gibi bir sınıflandırıcıyla analiz edilebilir. Bu hibrit yaklaşımlar, her iki yöntemin güçlü yönlerini bir araya getirerek nöbet tespit performansını artırmaktadır [16].

Bu çalışmanın amacı, EEG sinyalleri üzerinden epileptik nöbetleri yüksek doğrulukla tespit etmek için yüksek çözünürlüklü güç spektral yoğunluğu yöntemlerini (Music, Lomb-Scargle, Multitaper, Welch, Periodogram, Burg) ve etkili sınıflandırıcıları (Rastgele Orman ve k-En Yakın Komşu) bir araya getirerek kapsamlı bir analiz yapmaktır. Bu doğrultuda, her bir yöntemle elde edilen spektral çözünürlüklerin ve frekans bileşenlerinin, nöbet tespitinde ayırt edici özellikler sağlama kapasitesi değerlendirilecektir. Çalışmada, her bir EEG sınıfı için referans sinyaller oluşturulacak ve bu referanslar ile yapılan karşılaştırmalardan spektral enerji, spektral entropi, maksimum spektral sapma gibi ayırt edici özellikler çıkarılacaktır. Bu öznelik vektörleri, epileptik nöbet tespiti için Rastgele Orman ve k-En Yakın Komşu sınıflandırıcılarına girdi olarak verilir ve her yöntemin nöbet ayırt etme başarısı karşılaştırılacaktır.

Bu çalışmada, epileptik nöbet tespitinde yüksek çözünürlüklü güç spektral yoğunluğu yöntemleri ile güçlü topluluk öğrenme tabanlı sınıflandırıcıların birlikte kullanımının, geleneksel yöntemlerle karşılaştırıldığında doğruluk oranını nasıl etkilediği araştırılacaktır. Literatürde yer alan geleneksel yöntemler genellikle belirli frekans analiz teknikleri ve sınıflandırıcılar ile sınırlı kalırken [17], bu çalışma geniş bir spektral yöntem

yelpazesini bir araya getirerek her bir yöntemin nöbet paternlerini ayırt etme potansiyelini değerlendirmekte ve nöbetlerin hızlı ve güvenilir bir şekilde tespit edilmesine yönelik kapsamlı bir yaklaşım sunmaktadır. Böylece, epileptik nöbet tespitinde daha yüksek performanslı ve güvenilir sistemlerin geliştirilmesine yönelik katkılar sağlanarak epilepsi hastalarının tedavi süreçlerinde destek sağlanması amaçlanmaktadır.

## 2. MATERYAL VE METOD (MATERIAL and METHOD)

### 2.1. Veri Seti (Data Set)

Bu çalışmada Bonn Üniversitesi Epileptoloji Bölümü tarafından sağlanan, kamuya açık EEG veri seti

kullanılmıştır [18]. EEG verileri, 12 bit çözünürlüğe sahip 128 kanallı bir EEG kayıt sistemi ile 173,61 Hz örnekleme frekansında kaydedilmiş ve tüm kanalların ortalama değeri alınarak tek kanala indirgenmiştir. Her veri seti, 23,6 saniyelik kayıt süreleri boyunca alınmış 100 adet tek kanallı EEG segmentinden oluşmakta ve her bir segment 4097 örnek içermektedir. EEG sinyalleri, 40 Hz kesim frekansında alçak geçiren filtre ile filtrelenmiş ve göz hareketleri ile kas aktivitesinden kaynaklanan artefaktlardan arındırılmıştır. Kayıtlar, uluslararası 10-20 elektrot yerleşim sistemine göre yapılmıştır.

- Set A: Gözleri açık durumdaki 5 sağlıklı gönüllüden, kafatasının dışından yüzeysel olarak kaydedilmiş EEG verilerini içerir (Z.zip).

**Çizelge 1.** Çalışmada kullanılan Güç spektral yoğunluğu yöntemlerinin avantaj dezavantajları ve temel bağıntıları (Advantages, disadvantages and basic relations of the Spectral Power Density methods used in the study)

Yöntem	Matematiksel Gösterim	Avantaj ve Dezavantajlar
Periodogram	$\hat{P}_{xx}(f) = \frac{1}{N}  X(f) ^2$	Fourier dönüşümüyle frekans bileşenlerinin güçlerini hesaplar. Basit, yüksek frekans çözünürlüğü sunar. Gürültüye duyarlıdır ve varyansı yüksektir [19]. Burada; X sinyalin Fourier dönüşümü, N ise örnek sayısıdır.
Welch	$\hat{P}_{xx}(f) = \frac{1}{N_W} \sum_{k=0}^{K-1} \sum_{n=0}^{N-1} x[n+kL] w[n] e^{-j2\pi f n}$	Sinyali parçalara ayırarak her parçanın periodogramını ortalamasıyla PSD tahmini yapar. Gürültü azaltır, stabil sonuç verir. Hesaplama maliyeti yüksek, pencere seçiminde hassastır [20]. Burada; K segment sayısı, W pencere fonksiyonudur.
Multitaper	$\hat{P}_{xx}(f) = \frac{1}{K} \sum_{k=1}^K \left  \sum_{n=0}^{N-1} x[n] w_k[n] e^{-j2\pi f n} \right ^2$	Birden fazla pencere kullanarak spektral sızıntıyı azaltır ve güvenli tahmin sağlar. Zaman alıcıdır, yüksek hesaplama maliyetlidir [21]. Burada K segment sayısı, W, taper fonksiyonlarıdır.
Yule-Walker	$P(f) = \frac{\sigma^2}{\left  1 - \sum_{k=1}^p \phi_k e^{-j2\pi f k} \right ^2}$	AR model parametrelerini kullanarak PSD tahmini yapar. Hızlı ve düşük hesaplama maliyetlidir. Frekans çözünürlüğü sınırlıdır [22]. Burada; $\sigma$ beyaz gürültü fonksiyonu, $\phi$ otokorelasyon fonksiyonudur.
Kovaryans	$P(f) = F \{ R_x(k) \} = \sum_{k=-\infty}^{\infty} R_x(k) e^{-j2\pi f k}$	Otokorelasyon fonksiyonunun Fourier dönüşümüyle PSD tahmini yapar. Basit, fakat gürültüye duyarlı bir yöntemdir [20, 23]. Burada R(k) sinyalin otokorelasyonudur.
Modifiye Kovaryans	$P(f) = F \{ \hat{R}_x(k) \} = \sum_{k=-\infty}^{\infty} \hat{R}_x(k) e^{-j2\pi f k}$	Kovaryans yönteminin iyileştirilmiş şeklidir, daha hassas otokorelasyon tahmini sağlar. Düşük frekans bileşenlerini daha iyi yakalar. Yüksek hesaplama gücü gerektirir [20]. Burada R(k) sinyalin iyileştirilmiş otokorelasyon fonksiyonudur.
Lomb-Scargle	$P(f) = \frac{1}{2} \left[ \frac{\left( \sum_{i=1}^N (y_i - \bar{y}) \cos(\omega f_i + \phi_i) \right)^2}{\sum_{i=1}^N \cos^2(\omega f_i + \phi_i)} + \frac{\left( \sum_{i=1}^N (y_i - \bar{y}) \sin(\omega f_i + \phi_i) \right)^2}{\sum_{i=1}^N \sin^2(\omega f_i + \phi_i)} \right]$	Düzensiz örnekleme verilerinde Fourier analizi yaparak PSD tahmini sağlar. Gürültüye karşı hassastır [23]. Burada y sinyal, $\phi$ ise sinyalin varyansıdır.
Music	$P_{MUSIC}(f) = \frac{1}{\sum_{i=p+1}^M  e_i^H v(f) ^2}$	Özdeğer ayrışımıyla PSD tahmini yaparak dar bantlı sinyallerin frekanslarını tespit eder. Yüksek çözünürlüklü ve sinyal bileşenlerinin net ayrımını yapar. Fakat karmaşık ve hesaplama maliyeti yüksektir [24]. Burada V frekans vektörüdür.
Burg	$P(f) = \frac{\sigma^2}{\left  1 + \sum_{k=1}^p a_k e^{-j2\pi f k} \right ^2}$	AR modeli kullanarak hata minimizasyonu ile PSD tahmini yapar, refleksiyon katsayıları kullanır. Yüksek çözünürlük sağlar. Fakat karmaşık ve hesaplama maliyeti yüksektir [22]. Burada a; modelin yansıma katsayılarıdır.

- Set B: Gözleri kapalı, sakin ve uyanık durumdaki 5 sağlıklı gönüllüden, kafatasının dışından alınan yüzey EEG kayıtlarını içerir (O.zip).
- Set C: 5 epileptik hastada, nöbet durumu dışında, kafatasının içinden kaydedilen EEG verilerini içerir (N.zip).
- Set D: 5 epileptik hastada, nöbet dışı durumdayken kafatasının içinden alınan EEG kayıtlarını içerir (F.zip).
- Set E: Aynı 5 epileptik hastada, nöbet esnasında kafatasının içinden alınan EEG verilerini içerir (S.zip).

## 2.2. Güç Yoğunluk Spektrumu (Power Spectral Density)

Güç Yoğunluk Spektrumu (PSD), bir sinyalin frekans bileşenlerinin güçlerini gösteren bir spektral analiz yöntemidir. PSD, sinyalin toplam gücünü belirli bir frekans aralığında yoğunluk şeklinde sunar ve bu sayede sinyalin frekans dağılımının incelenmesine olanak tanır. Başka bir ifadeyle, sinyalin belirli frekans bileşenlerine sahip olup olmadığını ve bu bileşenlerin ne kadar güçlü olduğunu belirlemesine yardımcı olur.

Özellikle zamanla değişen sinyallerde frekans içeriklerini incelemek için kullanılan önemli bir araçtır. Sunulan çalışmada güç yoğunluğu spektrumunun hesaplanmasında kullanılan farklı yöntemlerin genel

matematiksel gösterimleri ile avantaj ve dezavantajları Çizelge 1’de kısaca belirtilmiştir.

## 2.3. Öznitelik Vektörünün Çıkarılması (Extraction of Feature Vector)

Öznitelik vektörü, bir veriyi veya bir sinyali temsil eden özelliklerin bir araya getirilmesiyle oluşturulan bir vektördür. Sınıflandırma gibi makine öğrenmesi problemlerinde, her örnek için belirlenen özellikler bir araya getirilerek bir öznitelik vektörü oluşturulur. Bu özellikler, sınıflandırıcı algoritmanın öğrenmesi ve örnekleri doğru sınıflara ayırması için gerekli bilgiyi sağlar. Öznitelik vektörü ne kadar anlamlı ve temsil gücü yüksekse, sınıflandırma performansı o kadar artar. Özelliklerin iyi seçilmesi ve veriyle ilişkilendirilmesi, doğru sınıflandırma oranını yükseltebilir.

Çalışmamızda, 7 adet PSD’den elde edilmiş D öznitelik vektörü; spektral enerji farkı (D<sub>1</sub>), spektral entropi farkı (D<sub>2</sub>), spektral düzlük (D<sub>3</sub>), spektral bant genişliği farkı (D<sub>4</sub>), spektral varyans (D<sub>5</sub>), toplam harmonik bozulma (D<sub>6</sub>) ve maksimum spektral sapmadan (D<sub>7</sub>) oluşmaktadır. Çizelge 2’de bu özelliklerin genel matematiksel bağıntıları ile avantaj ve dezavantajları kısaca belirtilmiştir. Bu çizelgede f; frekans, PSD(f); sinyalin frekans bölgesindeki güç dağılımı, P değeri; temel frekans ve onun katlarına ait bileşenlerin genlikleridir.

**Çizelge 2.** Çalışmada kullanılan spektral özelliklerin avantaj dezavantajları ve temel bağıntıları (Advantages, disadvantages and basic relations of the spectral features used in the study)

Yöntem	Matematiksel Gösterim	Avantaj ve Dezavantajlar
Spektral Enerji	$E_{\text{Spektral\_Enerji}} = \int_{f_1}^{f_2} PSD(f) df$	Sinyallerin toplam enerji içeriğini kıyaslamada etkilidir. Gürültüye duyarlıdır, yalnızca enerji yoğunluklu sinyallerde etkilidir [25].
Spektral Entropi	$H_{\text{Spektral\_Entropi}} = -\sum_i p(f_i) \log(p(f_i))$	Sinyalin enerji dağılımını ölçer, enerji düzensizliği hakkında bilgi verir. Bilgi yoğunluğu ve düzen ölçümü sağlar. Hesaplama maliyeti yüksek ve düşük enerjili sinyallerde etkisizdir [26]. Burada p(f) sinyalin frekans spektrumundaki fi frekans bileşeninin enerji yoğunluğunun toplam enerjiye oranını ifade eder.
Spektral Düzlük	$F_{\text{Spektral\_Düzlük}} = \frac{\left(\prod_{i=1}^N PSD(f_i)\right)^{\frac{1}{N}}}{\frac{1}{N} \sum_{i=1}^N PSD(f_i)}$	Sinyal spektrumunun düzlüğünü ölçüp, spektrumda dar veya geniş tepe olup olmadığını gösterir. Gürültüye karşı hassas, düşük spektral çözünürlükte etkisizdir [27].
Spektral Bant Genişliği	$BG_{\text{Spektral\_BG}} = \sqrt{\frac{\int_{-\infty}^{\infty} (f - f_{ort})^2 PSD(f) df}{\int_{-\infty}^{\infty} PSD(f) df}}$	Sinyal spektrumunun genişlik farkını analiz eder, spektrumun yayılmasını değerlendirir. Frekans içeriği düşük sinyallerde etkisizdir [28].
Toplam Harmonik Bozulma	$THB = \frac{\sqrt{P_2^2 + P_3^2 + \dots + P_n^2}}{P_1}$	Temel frekansa göre harmoniklerin toplam katkısını ölçer. Harmonik yapıları analiz etmekte, distorsiyon ölçümünde etkilidir. Yüksek harmonikli sinyallerde başarılı değildir [29].
Maksimum Spektral Sapma	$\Delta_{\max} = \max  PSD_{\text{referans}}(f) - PSD_{\text{sinyal}}(f) $	Sinyalin spektrumu ile referans spektrum arasındaki maksimum sapmayı belirler. Sinyaller arasındaki farkları belirgin hale getirir. Sinyal çeşitliliği az olan uygulamalarda etkisi sınırlıdır [30].
Spektral Varyans	$\sigma_{\text{Spektral\_Varyans}}^2 = \frac{\int_{-\infty}^{\infty} (f - f_{ort})^2 PSD(f) df}{\int_{-\infty}^{\infty} PSD(f) df}$	Sinyalin frekans spektrumundaki varyasyon derecesini ölçer. Sinyaldeki değişim seviyesini yansıtır. Gürültüden etkilenir [31].

## 2.4. Sınıflandırıcılar ve Sınıflandırma Modeli Performansının Değerlendirilmesi(Classifiers and Evaluation of Classification Model Performance)

Bu çalışmada sınıflandırma süreci, iki farklı sınıflandırıcının performanslarının karşılaştırılması yoluyla değerlendirilmiştir. Bunlardan ilki olan k-NN, basit ve sezgisel bir sınıflandırma algoritmasıdır. Yeni bir örneğin sınıfını tahmin etmek için en yakın k komşusunun sınıflarına bakar ve bunlar arasında en yaygın olan sınıfı tahmin eder. Mesafe ölçümüne dayalı olduğu için yüksek boyutlu veri setlerinde dikkatli kullanılmasında gerekir. Model performansını önemli ölçüde etkileyen k değeri bir parametre olarak seçilir [32]. Diğer sınıflandırıcı ise RF algoritmasıdır ve birden çok karar ağacından oluşan bir toplu öğrenme modelidir. Her ağaç, veri setinin rastgele bir alt kümesi üzerinde eğitilir ve sonuçlar birleştirilir. Bu yöntem aşırı öğrenmeyi önler ve yüksek doğruluk sağlar. Gürültüye dayanıklıdır ve önemli özellikleri belirlemek için de kullanılabilir [5].

Modelin performansını değerlendirmek için doğruluk (Acc) ve hassasiyet (Sens) temel ölçütlerdir. Sınıflandırıcılar verilen veri seti üzerinde hem doğru hem de yanlış sınıflandırmalar yapabilir. Bu ölçütler, modelin başarısını farklı açılardan değerlendirir [33]. Doğruluk, modelin toplamda ne kadar doğru tahmin yaptığını gösterir. Gerçek pozitif (TP) ve gerçek negatif (TN) tahminlerin toplam tahminlere oranını hesaplar. Genel olarak, modelin doğru sınıflandırma oranını temsil eder ve performansı hakkında geniş bir bakış açısı sağlar.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Eşitlik (1)'de FP, yanlış pozitif ve FN, yanlış negatiftir.

Hassasiyet, geri çağırma veya doğru pozitif oranı olarak da bilinir ve modelin pozitif örnekleri doğru tanımlama yeteneğini ölçer. Gerçek pozitif durumların model tarafından doğru tahmin edilen oranı olarak tanımlanır.

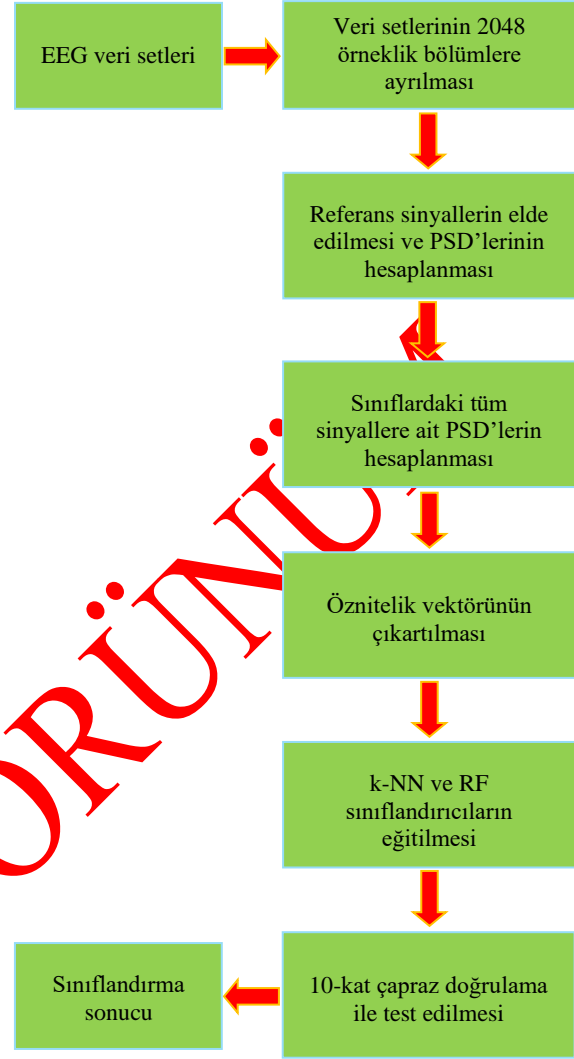
$$\text{Hassasiyet} = \frac{TP}{TP + FN} \quad (2)$$

Sınıflandırıcı performansı, özgüllük, F1 skoru ve ROC AUC (Alıcı İşletim Karakteristiği- Eğri Altında Kalan Alan) gibi çeşitli ölçütlerle değerlendirilebilir. Bu çalışmada hassasiyet ve doğruluğa öncelik verilmiştir. Hassasiyet, epileptik nöbet tespiti için yanlış negatifleri (kaçırılan nöbetleri) en aza indirmek açısından önemli olup, nöbetleri doğru bir şekilde algılama yeteneğini gösterir. Doğruluk ise genel sınıflandırma performansını ölçen bir kriter sunar. Bu ölçütler, yorumlanabilirlikleri ve tıbbi uygulamalardaki önemleri nedeniyle çalışmanın hedeflerine uygun olarak seçilmiştir.

## 3. DENEYSEL SONUÇLAR VE TARTIŞMA (EXPERIMENTAL RESULTS AND DISCUSSION)

MATLAB ve WEKA programları kullanılarak 16 GB RAM sahip Intel I5 12. Nesil bir CPU kullanılarak

gerçekleştirilen çalışmanın blok diyagramı Şekil 1'de verilmiştir.



Şekil 1. Sunulan çalışmanın blok diyagramı (The block diagram of the presented study)

EEG veri setleri her biri 4096 örnek değere sahip, 100' er adet sinyalden oluşmaktadır. Ancak, 100 sinyal yerine 200 sinyal kullanmak, sınıflandırma modeli için daha geniş bir veri kümesi sağlayacaktır. Bu sayede, modelin her sınıfa ait daha fazla örnek görerek sınıflar arası farkları daha iyi öğrenmesi mümkündür. Özellikle sınırlı sayıda sinyallerde modelin yeterince genel özellikleri öğrenmesi zordur. 200 sinyal ile sınıf temsil yeteneği artacak ve modelin genel doğruluğu yükselecektir. Sinyallerin ikiye bölünmesiyle her sınıfın frekans bileşenlerinde daha fazla çeşitlilik sağlanırken, nöbet olan ve nöbet olmayan durumların detaylı spektral özellikleri model tarafından daha ayrıntılı bir şekilde öğrenilebilir. Bu durumda özellikle epileptik nöbetlerin otomatik tespitinde modelin duyarlılığını artıracaktır. Sinyallerin daha kısa süreli parçalara bölünmesi, her bir sinyalde daha yüksek frekans bileşenlerinin vurgulanmasına yol açar. Özellikle nöbet durumunda görülen frekans değişikliklerinin kısa süreli sinyallerde

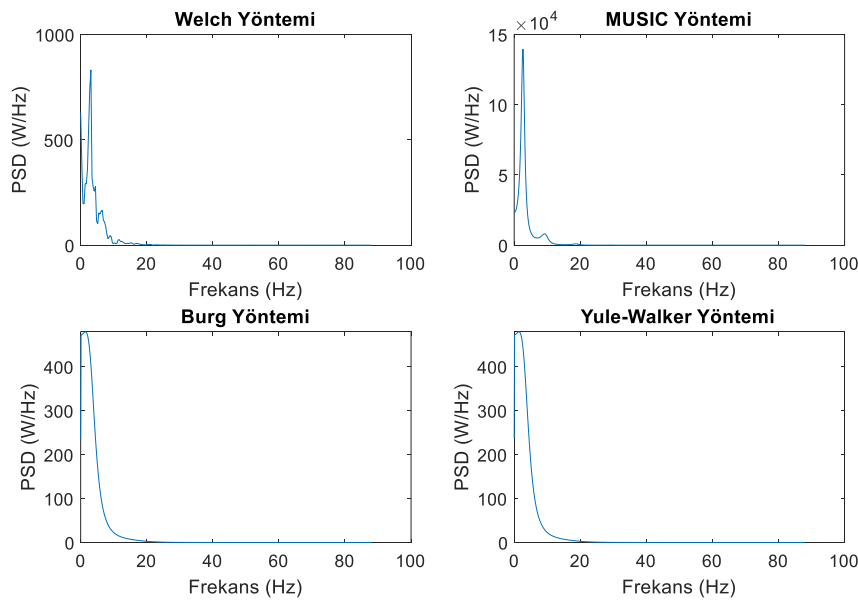
daha belirgin hale gelmesi, PSD yöntemleri ile elde edilen özelliklerin ayırım gücünü artırıcı bir unsurdur. Bu durumda, modelin nöbet başlangıçları ve normal durumlar arasındaki farkları daha hassas bir şekilde öğrenmesi sağlanacaktır. Ayrıca, sinyal sayısının artması, modelin veri seti üzerinde aşırı öğrenme riskini azaltır. Aşırı öğrenme, modelin sadece eğitim verisine uyum sağlamasına yol açarak yeni veriler üzerindeki doğruluğunu düşürebilir. Ancak, sinyal sayısının artması modelin her sınıfa ait genel özellikleri öğrenmesine katkı sağlayacaktır. Kısa süreli sinyallerde nöbet durumuna özgü enerji değişimleri ve düzensizliklerin etkisi artar. Spektral enerji farkı, spektral entropi gibi özellikler, kısa sinyallerde daha belirgin hale gelip ve sınıflandırıcıların bu özellikleri daha iyi kullanmasını sağlayacaktır. Bu nedenlerden ötürü sunulan çalışmanın ilk aşamasında bu veri setlerindeki sinyaller ikiye bölünerek 2048 örneklilik, 200'er sinyal olarak alınmıştır.

Çalışmanın ikinci aşamasında yer alan referans sinyal kullanımı, her sınıfa ait tipik bir temsil oluşturmayı ve diğer sinyalleri bu referans sinyalle karşılaştırarak sınıflar arası ayrımı güçlendirmeyi amaçlamaktadır. Referans sinyal, sınıfın genel özelliklerini en iyi temsil eden ortalama sinyal olarak tanımlanmıştır. Bu referans sinyal kullanımı, nöbet ve nöbet dışı durumları ayırt etmek için önemli avantajlar sunar. Referans sinyal ile diğer sinyaller arasındaki farkların ölçülmesi, sınıfların belirli frekans bileşenleri bakımından nasıl ayrıştığını daha iyi ortaya koyacaktır. Epileptik nöbet tespitinde, nöbet durumundaki frekans bileşenleri normal durumdan önemli ölçüde farklıdır. Referans sinyal ile nöbet olan ve nöbet olmayan sinyallerin karşılaştırılması, bu farkların spektral olarak net bir şekilde analiz edilmesini sağlayacaktır. Referans sinyal kullanımı, her bir sinyal ile referans sinyal arasındaki spektral enerji farkı, spektral entropi farkı, maksimum spektral sapma gibi özelliklerin

kolayca çıkarılmasını sağlamaktadır. Ayrıca her sınıf için bir referans sinyalin oluşturulması, spektral karşılaştırmaların tüm sinyaller için aynı temel üzerinden yapılmasını sağlar. Bu tutarlılık, sınıflandırıcının her sinyal üzerinde aynı türden bir analiz yapabilmesine olanak tanır. Böylece, sınıflandırıcının her sınıfa ait tipik frekans bileşenlerini doğru bir şekilde öğrenmesi ve ayırt etmesi mümkün olur.

Referans sinyaller, her bir sınıfa ait sinyallerin genlik değerleri üzerinden örnek bazında aritmetik ortalama alınarak oluşturulmuştur. Bu işlem, her sinyalin aynı uzunlukta olması ve aynı zaman dilimlerini temsil etmesi sağlandıktan sonra gerçekleştirilmiştir. Bir sınıfta yer alan tüm sinyaller aynı örnekleme oranı ve uzunluğa sahiptir, her örnek için tüm sinyallerin genlik değerlerinin toplamı alınarak sinyal sayısına bölünmüştür. Bu sayede, o sınıfa ait tüm sinyallerin genlik ve frekans bileşenlerini temsil eden bir ortalama sinyal elde edilmiştir. Elde edilen referans sinyal, sınıfın tipik özelliklerini yansıtan bir temel olarak kullanılmış ve diğer sinyallerle spektral karşılaştırmalar yapılırken bir referans noktası olarak görev görmüştür.

Çalışmamızda güç spektral yoğunluğu hesaplanmasında Burg, Kovaryans, Modifiye Kovaryans, Multitaper, Music, Periodogram, Welch, Yule-Walker ve Lomb-Scargle yöntemleri kullanılmıştır. Bu yöntemlerden bazıları ile elde edilen spektral güç yoğunlukları Şekil 2'de verilmiştir. Elde edilen spektral güç yoğunluklarından faydalanılarak spektral enerji farkı, spektral entropi farkı, spektral düzlük, spektral bant genişliği farkı, spektral varyans, toplam harmonik bozulma ve maksimum spektral sapma değerleri hesaplanmış ve bu değerler öznitelik vektörü olarak kullanılarak, RF ve k-NN ile sınıflandırma işlemi gerçekleştirilmiştir.



Şekil 2. Welch, Music, Burg ve Yule-Walker yöntemleriyle elde edilen güç spektral yoğunluğu grafikleri (Spectral power density graphs obtained by the Welch, Music, Burg and Yule-Walker methods)



Çizelge 3 ve Şekil 3'te farklı görevler için çeşitli PSD yöntemlerinin doğruluk ve hassasiyet değerleri karşılaştırılmıştır. Bu görevler, iki sınıflı (A-E, C-D) ve çok sınıflı (A-C-E, C-D-E, A-B-C-D-E) sınıflandırmaları içermektedir.

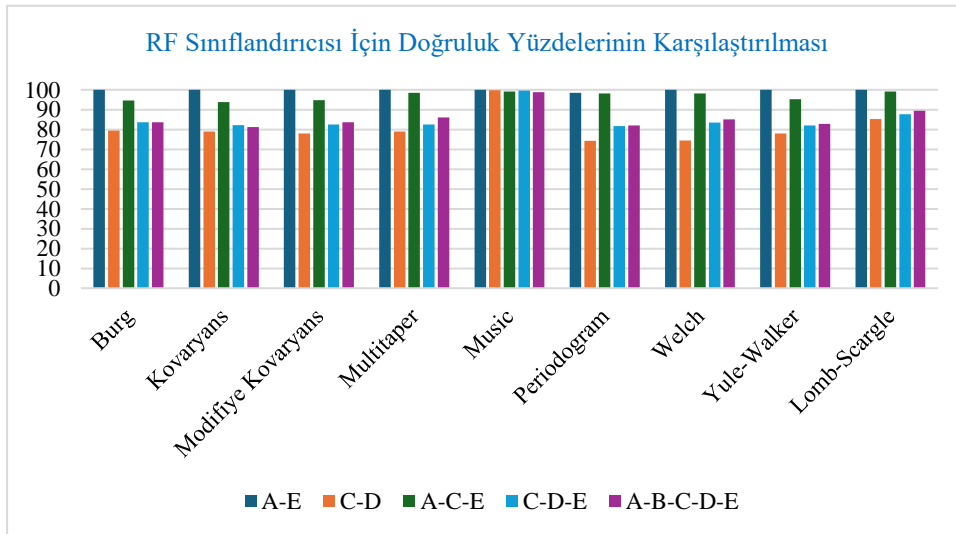
A-E görevinde, tüm yöntemler yüksek doğruluk oranına sahiptir. Çoğu yöntem (Burg, Kovaryans, Modifiye Kovaryans, Multitaper, Music, Welch ve Yule-Walker) %100 doğruluk oranına ulaşırken, yalnızca Periodogram (%98,5) ve Lomb-Scargle (%100'e yakın) biraz daha düşük performans göstermiştir. Bu, iki sınıflı sınıflandırmalarda bu yöntemlerin etkili olduğunu ve sınıflar arasındaki ayrımın belirgin olduğunu göstermektedir. C-D görevinde doğruluk oranlarında belirgin bir düşüş gözlemlenmiştir. Özellikle Burg, Kovaryans, Modifiye Kovaryans, Multitaper ve Yule-Walker gibi yöntemlerde doğruluk %78-79 aralığında seyretmiştir. Ancak Music yöntemi %99,75 doğruluğa ulaşarak diğer yöntemlerden belirgin şekilde ayrılmaktadır. Lomb-Scargle yöntemi de %85,25 ile Music'ten sonra en yüksek doğruluğu sağlamıştır. Bu da Music ve Lomb-Scargle'in iki sınıflı karmaşık verilerde

daha güçlü performans gösterdiğini düşündürmektedir. Çok sınıflı görevlerde (A-C-E, C-D-E, A-B-C-D-E) yöntemler arasındaki performans farkları belirgin hale gelmektedir. Özellikle Music, tüm çok sınıflı görevlerde oldukça yüksek doğruluk oranları (%98,8'e kadar) sunarak öne çıkmaktadır. Lomb-Scargle yöntemi de A-C-E ve C-D-E görevlerinde %99,17'ye kadar ulaşan doğruluk oranlarıyla dikkat çekmektedir. Diğer yöntemler (Burg, Kovaryans, Modifiye Kovaryans gibi) ise çok sınıflı görevlerde daha düşük doğruluk oranları göstermektedir. Özellikle A-B-C-D-E görevi gibi daha yüksek sınıf sayısına sahip sınıflandırmalarda bu fark belirginleşmektedir.

PSD yöntemleri arasındaki performans farklılıklarını değerlendirirken her yöntemin spektral çözünürlük ve sinyal ayırıştırma yeteneklerini göz önünde bulundurulmalıdır. Music yöntemi, özellikle çok sınıflı görevlerde yüksek doğruluk ve duyarlılık sağlaması ile dikkat çekmektedir. Bu yöntem, sinyallerin yüksek spektral çözünürlükle analiz edilmesine olanak tanır ve frekans bileşenlerini daha net bir şekilde ayırt eder. Bu özellik, özellikle birden fazla sınıfın yer aldığı görevlerde

**Çizelge 3.** Farklı sınıflandırma görevleri için PSD yöntemlerinin Rastgele Orman sınıflandırıcısı ile elde edilen doğruluk ve hassasiyet değerleri (Accuracy (Acc) and sensitivity (Sens) values obtained with the Random Forest classifier of PSD methods for different classification tasks)

Yöntem	Sınıflandırma Görevleri (Rastgele Orman)									
	A-E		C-D		A-C-E		C-D-E		A-B-C-D-E	
	Acc(%)	Sens	Acc(%)	Sens	Acc(%)	Sens	Acc(%)	Sens	Acc(%)	Sens
Periodogram	98,5	0,985	74,25	0,770	98,17	0,985	81,67	0,740	82,0	0,850
Welch	100	1,000	74,5	0,780	98,17	0,990	83,5	0,805	85,1	0,910
Multitaper	100	1,000	79,0	0,815	98,5	1,000	82,5	0,795	86,0	0,930
Yule-Walker	100	1,000	78,0	0,770	95,17	0,965	82,0	0,755	82,8	0,900
Kovaryans	100	1,000	79,0	0,805	93,83	0,930	82,17	0,755	81,2	0,835
Modifiye Kovaryans	100	1,000	78,0	0,780	94,83	0,950	82,5	0,770	83,7	0,880
Lomb-Scargle	100	1,000	85,25	0,865	99,17	0,992	87,66	0,877	89,4	0,894
Music	100	1,000	99,75	0,995	99,17	0,980	99,67	0,990	98,8	0,960
Burg	100	1,000	79,5	0,800	94,67	0,945	83,67	0,785	83,6	0,875



**Şekil 3.** RF sınıflandırıcısı için farklı sınıflandırma görevlerinde, farklı PSD yöntemlerinin doğruluk yüzdelerinin karşılaştırılması (Comparison of accuracy percentages of different PSD methods on different classification tasks for the RF classifier)

sınıflar arası ayrımı daha belirgin hale getirerek doğruluğu artırmaktadır. Lomb-Scargle yöntemi, düşük örnekleme frekanslarında ya da düzensiz zaman aralıklarına sahip sinyallerin spektral analizinde etkilidir. Bu yöntem, özellikle C-D ve çok sınıflı (A-B-C-D-E gibi) görevlerde yüksek doğruluk sağlamıştır. Lomb-Scargle'in bu tür görevlerdeki başarısı, PSD hesaplamasında daha iyi spektral ayırım sağlamasından kaynaklanmaktadır. Bu da çeşitli frekans bileşenlerinin daha ayrıntılı analizine olanak tanır. Multitaper yöntemi, özellikle A-C-E görevinde %98,5 doğrulukla başarılı bir performans göstermiştir. Multitaper yönteminin düşük varyansa sahip spektral tahminler üretmek yüksek doğruluk sağlaması, çok sınıflı görevlerde sınıflar arası ayırımın yapılmasına katkıda bulunabilir. Diğer yöntemler (Burg, Kovaryans, Modifiye Kovaryans, Yule-Walker), A-E gibi basit iki sınıflı görevlerde %100 doğruluk oranına ulaşırken, daha karmaşık görevlerde düşük performans göstermiştir. Örneğin, C-D, A-B-C-D-E görevlerinde doğrulukları %80 seviyelerine kadar düşmüştür.

Öznitelik vektörlerinde kullanılan spektral enerji farkı, spektral bant genişliği farkı, spektral entropi farkı, spektral düzlük, spektral varyans, toplam harmonik bozulma, maksimum spektral sapma gibi özellikler, sinyallerin spektral karakteristiklerini belirginleştirmektedir. Özellikle, spektral enerji farkı ve maksimum spektral sapma, sinyallerdeki enerji yoğunluğu ve frekanslardaki ani değişiklikleri vurgulamakta, nöbet durumlarının tespit edilmesinde fayda sağlamaktadır. Music ve Lomb-Scargle gibi yöntemlerde bu özelliklerin daha belirgin hale geldiği ve sınıflandırma başarısını artırdığı gözlemlenmiştir. Spektral entropi farkı ve düzlük özellikleri ise, sinyalin düzenlilik seviyesini ve spektral bileşenlerin homojenliğini ölçerek, epileptik nöbet tespitinde önemli bilgiler sağlar. Music yönteminin yüksek spektral çözünürlüğü sayesinde spektral entropi ve düzlük gibi özelliklerin daha net ayırt edilebilmesi, sınıflandırma başarısını pozitif yönde etkilemiştir.

Rastgele Orman özünde çoklu karar ağaçlarının çoğunluk oylaması ile sonuç verdiği bir yöntemdir.

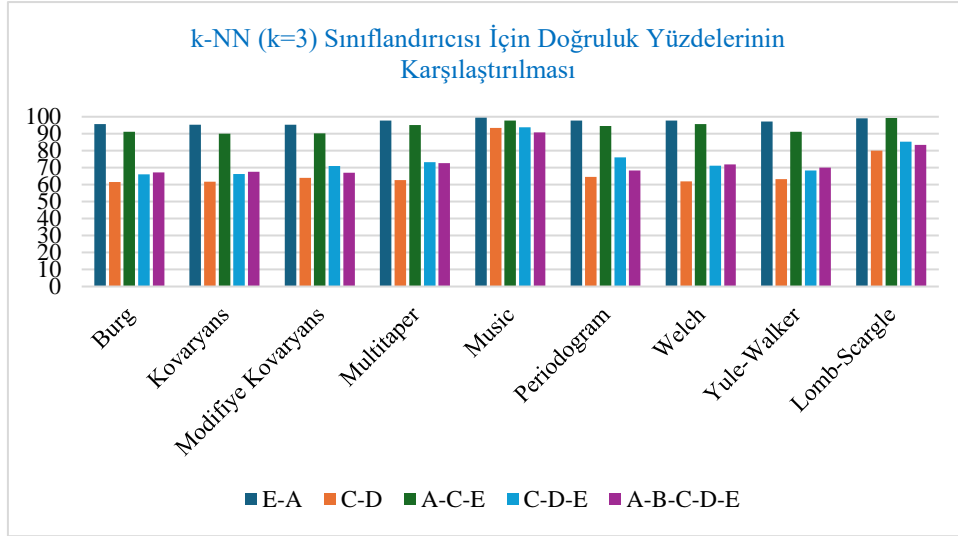
Epileptik nöbet tespiti gibi karmaşık ve çok sınıflı sınıflandırma görevlerinde oldukça etkili bir modeldir. Bu çizelgeye göre, Rastgele Orman, her PSD yöntemi ile çalışırken elde edilen özellikleri etkili bir şekilde ayırt edebilmiştir. Özellikle Music ve Lomb-Scargle gibi yüksek spektral çözünürlüklü PSD yöntemleri ile elde edilen özellikler, sınıflar arasındaki farkları daha belirgin hale getirmiştir. Bu durum, modelin bu özelliklerle daha yüksek doğruluk sağlamasına yol açmıştır. Music ve Lomb-Scargle gibi yöntemlerle Rastgele Orman'ın %99 üzerinde doğruluk oranına ulaşması, özelliklerin sınıflar arası ayrımını netleştirdiği durumlarda bu modelin oldukça başarılı sonuçlar sunduğunu göstermektedir.

Çizelge 4 ve Şekil 4'te, k-NN (k=3) sınıflandırıcısının farklı görevler için çeşitli PSD yöntemleri ile elde edilen doğruluk ve hassasiyet değerleri ve karşılaştırmaları belirtilmiştir.

A-E görevinde, PSD yöntemlerinin çoğu %95 üzerinde doğruluk sağlamıştır. Özellikle Music (%99,5) ve Lomb-Scargle (%99,0) yöntemleri, k-NN sınıflandırıcısı ile en yüksek doğruluğa ulaşmıştır. Bu sonuç, bu iki yöntemin iki sınıflı bir görevde sınıfları net bir şekilde ayırdığını ve k-NN modelinin de bu farkları başarıyla yakaladığını göstermektedir. C-D görevi, A-E'ye kıyasla daha düşük doğruluk oranlarına sahiptir. Çoğu yöntem için doğruluk %61-65 aralığındadır, ancak Music yöntemi %93,5 ile belirgin bir fark yaratmıştır. Lomb-Scargle de %80 doğruluğa ulaşmıştır. Bu iki yöntem, sınıflar arasındaki ayrımı netleştirmekte, ancak diğer yöntemler C-D görevinde düşük ayırım yeteneği göstermektedir. A-C-E görevinde, Music (%97,83), Lomb-Scargle (%99,17) ve Multitaper (%95,17) yöntemleri dikkat çekici doğruluk oranlarına ulaşmıştır. Özellikle Lomb-Scargle yöntemi %99,17 ile en yüksek doğruluğu sağlamaktadır. Bu, k-NN'nin, bu yöntemlerin sağladığı spektral özelliklerle sınıfları başarılı bir şekilde ayırdığını göstermektedir. C-D-E görevinde, Music (%93,83) ve Lomb-Scargle (%85,33) en yüksek doğruluk oranlarına ulaşmıştır. Multitaper (%73,17) ve Periodogram (%76) doğruluk sağlamaktadır, ancak diğer yöntemler daha düşük doğruluk göstermektedir. Music ve Lomb-Scargle, üçlü sınıflandırma görevlerinde de k-

**Çizelge 4.** Farklı sınıflandırma görevleri için PSD yöntemlerinin k-En Yakın Komşu sınıflandırıcısı ile elde edilen doğruluk ve hassasiyet değerleri (Accuracy (Acc) and sensitivity (Sens) values obtained with the k-Nearest Neighbor classifier of PSD methods for different classification tasks)

Yöntem	Sınıflandırma Görevleri (Rastgele Orman)									
	A-E		C-D		A-C-E		C-D-E		A-B-C-D-E	
	Acc(%)	Sens	Acc(%)	Sens	Acc(%)	Sens	Acc(%)	Sens	Acc(%)	Sens
Periodogram	97,75	0,975	64,5	0,675	94,50	0,950	76,0	0,710	68,4	0,720
Welch	97,75	0,975	62,0	0,680	95,67	0,950	71,17	0,600	71,9	0,750
Multitaper	97,75	0,975	62,75	0,660	95,17	0,970	73,17	0,660	72,6	0,765
Yule-Walker	97,25	0,980	63,25	0,640	91,17	0,930	68,33	0,565	70,1	0,730
Kovaryans	95,25	0,960	61,75	0,635	90,0	0,920	66,33	0,560	67,6	0,685
Modifiye Kovaryans	95,25	0,960	64,0	0,675	90,16	0,925	71,0	0,640	67,0	0,735
Lomb-Scargle	99,0	0,980	80,0	0,800	99,17	0,992	85,33	0,853	83,4	0,834
Music	99,5	1,000	93,5	0,895	97,83	0,985	93,83	0,905	90,7	0,890
Burg	95,6	0,960	61,5	0,645	91,17	0,930	66,0	0,575	67,3	0,765



**Şekil 4.** k-NN (k=3) sınıflandırıcısı için farklı sınıflandırma görevlerinde, farklı PSD yöntemlerinin doğruluk yüzdelere karşılaştırılması (Comparison of accuracy percentages of different PSD methods on different classification tasks for the k-NN classifier)

NN için güçlü ayırıcı özellikler sunmaktadır. Beş sınıflı görevde, doğruluk oranları genellikle düşük göstermiştir, ancak Music (%90,7) ve Lomb-Scargle (%83,4) en yüksek doğruluğu elde etmiştir. Bu, özellikle karmaşık çok sınıflı sınıflandırma görevlerinde, yüksek spektral çözünürlük sunan PSD yöntemlerinin önemini vurgulamaktadır.

Music yöntemi, çoğu görevde en yüksek doğruluğu sağlamış, özellikle çok sınıflı görevlerde (C-D-E ve A-B-C-D-E gibi) güçlü bir ayırıcı olarak öne çıkmıştır. Yüksek spektral çözünürlüğü ile bilinen Music, k-NN sınıflandırıcısına daha belirgin spektral özellikler sunarak, özellikle karmaşık sınıflandırma görevlerinde doğruluğu artırmaktadır. Elde edilen sonuçlar, Music yönteminin k-NN ile epileptik nöbet tespiti gibi ayrıntılı analiz gerektiren durumlarda etkili olduğunu göstermektedir. Lomb-Scargle yöntemi, A-E ve çok sınıflı görevlerde yüksek doğruluk oranları sağlayarak Music'ten sonra en başarılı yöntem olarak öne çıkmaktadır. Düzensiz zaman aralıklarında spektral analize olanak tanıyan Lomb-Scargle, özellikle C-D-E (%85,33) ve A-B-C-D-E (%83,4) görevlerinde etkili olmuştur. Bu sonuçlar, k-NN sınıflandırıcısının Lomb-Scargle ile belirgin frekans bileşenlerini ayırt edebilme yeteneğini ortaya koymaktadır. Multitaper yöntemi, A-C-E gibi üç sınıflı görevlerde (%95,17 doğruluk) dikkat çekici bir performans sergilemiştir. Bu yöntem düşük varyanslı spektral tahminler sunarak sınıf ayrımını artırmakta ve k-NN'nin bu özelliklerden faydalanmasını sağlamaktadır. Ancak çok sınıflı görevlerde (A-B-C-D-E gibi) performansı biraz daha düşük kalmaktadır. Diğer yöntemler (Burg, Kovaryans, Modifiye Kovaryans, Yule-Walker) ise, basit iki sınıflı görevlerde (örneğin A-E) %95 civarında doğruluk sağlamasına rağmen, çok sınıflı görevlerde daha düşük doğruluk oranlarına sahiptir. Örneğin, A-B-C-D-E gibi beş sınıflı görevde doğruluk %67-71 arasında kalmaktadır. Bu durum, k-

NN'nin bu yöntemler ile elde edilen spektral özellikler üzerinden karmaşık ayırım yapmada zorlandığını göstermektedir.

k-NN sınıflandırıcısı, belirli öznelik vektörlerine dayalı olarak sınıflar arasındaki mesafeyi hesaplar. Bu bağlamda, elde edilen özellikler (spektral enerji farkı, spektral bant genişliği farkı, spektral entropi farkı, spektral düzlük, spektral varyans, toplam harmonik bozulma ve maksimum spektral sapma) sınıflar arası ayırım yapmada kritik bir rol oynamaktadır. Spektral enerji ve maksimum spektral sapma özellikleri, nöbet esnasındaki ani enerji değişimlerini ve frekanslardaki büyük dalgalanmaları temsil etmektedir. Özellikle Music ve Lomb-Scargle gibi yüksek çözünürlüklü PSD yöntemleri ile bu özellikler daha belirgin hale gelmekte ve k-NN'nin performansını artırmaktadır. Spektral entropi ve spektral düzlük özellikleri, sinyalin düzensizlik ve homojenlik derecesini yansıtarak nöbet anında değişiklik gösterir. Özellikle Music yöntemi ile elde edilen yüksek çözünürlükteki entropi değerleri, k-NN'e nöbet durumlarını ayırt etmede önemli bilgiler sağlamaktadır. k-NN, özellikle düşük sınıf sayısına sahip basit sınıflandırma görevlerinde başarılı sonuçlar vermektedir. Ancak çok sınıflı görevlerde performansı, kullanılan PSD yöntemine göre farklılık göstermektedir. Music ve Lomb-Scargle yöntemleri, k-NN için belirgin özellikler sağladığından, özellikle çok sınıflı görevlerde yüksek doğruluk oranlarına ulaşılmıştır. Bu da k-NN'nin spektral çözünürlüğü yüksek yöntemler ile daha belirgin sınıf ayrımı yapabildiğini göstermektedir. Burg, Kovaryans ve Modifiye Kovaryans gibi yöntemler, özellikle karmaşık sınıflandırma görevlerinde k-NN ile daha düşük performans sergilemiştir. Bu yöntemlerin spektral çözünürlüğü daha düşük olduğundan, k-NN'nin sınıf ayrımını gerçekleştirmesi zorlaşmaktadır.

Çizelge 5'te RF ve k-NN sınıflandırıcılarının genel performans ve görev başarısı karşılaştırması verilmiştir.

**Çizelge 5.** Rastgele Orman ve k-En Yakın Komşu sınıflandırıcılarının genel performans ve görev başarısı karşılaştırması  
(Comparison of overall performance and task success of Random Forest and k-Nearest Neighbor classifiers)

Görev	Rastgele Orman	k-En Yakın Komşu (k=3)
A-E	RF genelde %100 doğruluğa ulaşmıştır (Burg, Kovaryans, Music, Welch vb.).	k-NN %95-99,5 arasında doğruluk sağlamıştır. En iyi performansı Music (%99,5) ve Lomb-Scargle (%99,0) göstermiştir.
C-D	RF %74-99,75 doğruluk aralığında (Music en yüksek %99,75 doğrulukla öne çıkmaktadır).	k-NN doğrulukları genelde %61-93,5 arasında kalmıştır (Music %93,5 ile en yüksek performansı sergilemiştir).
A-C-E	RF %82-99,17 doğruluğa ulaşmıştır (Music ve Lomb-Scargle %99 üzerinde).	k-NN %90-99,17 aralığındadır (Lomb-Scargle %99,17 ile en yüksektir).
C-D-E	RF %81-99,67 arasında doğruluk sağlamıştır (Music en yüksek %99,67).	k-NN doğrulukları %66-93,83 arasında kalmıştır (Music %93,83 ile en yüksek).
A-B-C-D-E	RF %81-98,8 doğruluğa ulaşmıştır (Music %98,8 en yüksek).	k-NN %67-90,7 arasında doğruluğa sahiptir (Music %90,7 en yüksek).

RF, çok sayıda sınıf içeren karmaşık sınıflandırma görevlerinde daha başarılıdır. Özellikle Music, Multitaper ve Lomb-Scargle gibi yüksek çözünürlüklü PSD yöntemleri ile %98,8'e varan doğruluk sağlamıştır. RF, farklı PSD yöntemleri ile geniş bir performans yelpazesi sunmaktadır. Örneğin, Music ve Lomb-Scargle yöntemleriyle en yüksek doğruluk oranlarını yakalarken, Burg ve Kovaryans gibi yöntemlerde bile görece yüksek doğruluk sağlamaktadır. Bu durum, RF'nin çeşitli PSD özelliklerinden faydalanarak esnek bir sınıflandırıcı olduğunu göstermektedir. RF, genelde yüksek doğruluk oranlarına ulaşırken duyarlılık konusunda da güçlü performans göstermektedir. Özellikle nöbet durumlarının tespiti için duyarlılık önemlidir ve RF'nin çok sınıflı görevlerde bile yüksek duyarlılık sağlaması, epileptik nöbet tespiti gibi kritik uygulamalarda avantaj sunar.

k-NN algoritması basit bir yaklaşım kullanır ve özellikle düşük sınıflı görevlerde (örneğin A-E gibi) başarılı sonuçlar verir. Music ve Lomb-Scargle gibi yöntemlerle %99'a yakın doğruluk sağlarken, düşük hesaplama gereksinimi nedeniyle hızlı bir sınıflandırma sunar. k-NN, sınıflar arasındaki benzerlikleri komşuluk temelli bir yaklaşımla değerlendirdiğinden, özellikle iyi ayrılan sınıflarda (örneğin A-E ve A-C-E gibi) etkili olabilir. Özellikle yüksek spektral çözünürlüğe sahip PSD yöntemleri (Music ve Lomb-Scargle) ile kombine edildiğinde bu komşuluk temelli yaklaşımın güçlü bir ayırım sağladığı görülmektedir.

PSD yöntemleri, EEG sinyallerinde frekans bileşenlerini analiz etmek için kullanılan farklı matematiksel yaklaşımları ifade eder. Bu yöntemlerin her biri, sinyalin spektral özelliklerini farklı seviyelerde ayrıştırır ve bu da sınıflandırma performansını önemli ölçüde etkiler.

Burg yöntemi, otoregresif model parametrelerini hesaplamak için kullanılır ve tahmin edici modelin hata enerjisini en aza indirir. Özellikle yüksek çözünürlükte spektrum tahmini sağlamasıyla dikkat çekmektedir, ancak kısa süreli sinyallerde performansı sınırlıdır. Burg yöntemi, E-A gibi basit iki sınıflı görevlerde yüksek doğruluk sağlasa da çok sınıflı görevlerde düşük performans göstermektedir. Bunun sebebi, AR model parametrelerinin sınıflar arası karmaşık yapıyı ayırt

etmede yetersiz kalmasıdır. Bu yöntem, özellikle yüksek çözünürlük gerektirmeyen görevlerde başarılı olabilir.

Kovaryans ve Modifiye Kovaryans yöntemleri de AR model tahminiyle güç spektral yoğunluğunu belirlemeye çalışır. Ancak Burg yönteminden farklı olarak, tahmin işlemi sinyal verisinin her iki yönünde (ileri ve geri) gerçekleştirilir, bu da daha kararlı bir spektrum tahmini sağlar. Modifiye Kovaryans yöntemi daha yüksek çözünürlükte ve daha geniş spektral tahmin sağlamayı amaçlar. Kovaryans yöntemlerinin, genelde iki sınıflı görevlerde başarılı olduğu görülmektedir. Ancak çok sınıflı görevlerde düşük doğruluğa sahiptir. Sinyal özelliklerini her iki yönlü analiz etmesine rağmen, sınıflar arası karmaşıklığı tam olarak yakalayamaması nedeniyle çok sınıflı sınıflandırmalarda sınırlı kalmaktadır.

Multitaper yöntemi, sinyalin spektrumunu tahmin etmek için birden fazla taper (pencereleme) fonksiyonu kullanır. Bu yöntem, spektral sızıntıyı azaltarak düşük varyansa sahip spektral tahminler vermektedir. Özellikle sinyallerin kısa süreli bileşenlerini analiz ederken çoklu pencereler ile daha hassas bir sonuç elde etmektedir. Multitaper yöntemi, A-C-E gibi üç sınıflı görevlerde güçlü bir performans sergilemiştir. Çok sınıflı sınıflandırmalarda (C-D-E gibi) kısmen başarılıdır çünkü düşük varyanslı tahminler elde edilmesine olanak tanır. Ancak daha karmaşık beş sınıflı görevlerde (A-B-C-D-E gibi) performansı nispeten düşmektedir. Multitaper, spektral sızıntıyı azaltması sayesinde bazı sınıflarda ayırt edici özelliklerin belirginleşmesini sağlar.

Music yöntemi (Multiple Signal Classification), sinyal alt uzay ayrıştırmasına dayalı bir spektrum tahmin yöntemidir. Yüksek spektral çözünürlük sağlayarak dar frekans bileşenlerini bile ayırt edebilir. Bu yöntem, sinyalin oto-kovaryans matrisini analiz ederek frekans bileşenlerini net bir şekilde ayırır. Music, iki sınıflı (A-E) ve çok sınıflı (A-C-E, A-B-C-D-E gibi) görevlerde en yüksek doğruluk oranlarına ulaşmıştır. Yüksek spektral çözünürlüğü sayesinde, sinyaldeki ince frekans farklarını dahi yakalayarak sınıflandırıcılara (RF ve k-NN) önemli bilgiler vermiştir. Music'in sağladığı yüksek çözünürlük, özellikle çok sınıflı sınıflandırmalarda sınıf farklarını netleştirip sınıflandırıcıların doğruluğunu arttırmıştır.

Periodogram yöntemi, sinyalin Fourier Dönüşümü alınarak güç spektral yoğunluğunu hesaplayan klasik bir yaklaşımdır. Bu yöntemin, iki sınıflı görevlerde yüksek doğruluk sağladığı görülmektedir, ancak çok sınıflı görevlerde sınırlı kalmaktadır. Bu durum, düşük çözünürlüğün çok sayıda sınıf arasındaki ince farkları yeterince iyi yakalayamamasından kaynaklanmaktadır. Spektral sızıntı sorunları nedeniyle, özellikle çoklu sınıflandırma gerektiren görevlerde karmaşık frekans bileşenlerini yeterince ayırmadığı gözlemlenmiştir.

Epileptik nöbet tespitinde sıklıkla kullanılan Welch yöntemi, sinyalin belirli pencerelerle bölünmesi, her bir pencere için periodogram uygulanması ve bu periodogramların ortalamasının alınmasıyla güç spektral yoğunluğunu hesaplamaktadır. Bu yöntem, spektral sızıntıyı azaltarak daha pürüzsüz bir spektrum tahmini sunar. Welch yöntemi, E-A ve üç sınıflı görevlerde nispeten yüksek doğruluk sağlamış, çok sınıflı görevlerde ise performansı azalmıştır. Pürüzsüz spektrum tahmini, sinyal bileşenlerinin ortalama özelliklerini yansıtır, ancak ayrıntılı bileşenleri net bir şekilde yansıtmadığı için çok sınıflı sınıflandırmalarda diğer yöntemlere göre daha düşük performans sergilemiştir.

Yule-Walker yöntemi de bir oto-regresif model tahminine dayanır ve oto-kovaryans denklemleri kullanılarak güç spektral yoğunluğu hesaplanır. Bu yöntem, sinyalin tahmin edilen AR model parametreleriyle spektral analizini gerçekleştirir. Yule-Walker yöntemi, iki sınıflı görevlerde yüksek doğruluk sağlamış, ancak çok sınıflı görevlerde performansı düşmüştür. Düşük spektral çözünürlüğe sahip olduğundan, çok sınıflı görevlerde daha karmaşık frekans ayrımlarını yapamamış ve bu da sınıflandırıcının doğruluğunu olumsuz etkilemiştir.

Lomb-Scargle yöntemi, düzensiz zaman aralıklarında alınan verilerin spektrumunu hesaplamak için geliştirilmiştir. Frekans bileşenlerini detaylı bir şekilde ayırt edebilir ve yüksek çözünürlükte spektral tahminler sunabilen bir yöntemdir. Lomb-Scargle hem iki sınıflı hem de çok sınıflı görevlerde yüksek doğruluk oranlarına ulaşmıştır. Bu yöntemin spektral çözünürlüğü, özellikle sınıflar arasındaki ince farkları belirginleştirerek sınıflandırıcının doğruluğunu arttırmıştır. Sinyalin spektrumunu düzensiz zaman aralıklarında analiz etmesi, nöbet durumlarını ve normal durumları ayırt etmede önemli avantaj sağlamıştır.

Bu çalışmada Music-Rastgele Orman (RF) kombinasyonunun farklı sınıflandırma görevlerinde elde ettiği %98-%100 arasındaki doğruluk, literatürdeki benzer çalışmalardan özellikle C-D-E, A-C-E ve A-B-C-D-E gibi yüksek sayıda sınıf içeren sınıflandırma görevlerine göre daha yüksek doğruluk değerleri sunmaktadır [12, 16, 17, 19, 34]. Literatürde, farklı PSD yöntemleri ile farklı sınıflandırıcıları kullanılarak elde edilen doğruluklar genellikle %85-%100 arasında değişmektedir. %100 doğruluk değerleri özellikle ikili sınıflandırmalarda elde edilmiştir. Ancak bu çalışmada

elde edilen sonuçlar, Music ve Rastgele Orman kombinasyonunun epileptik nöbet tespitinde diğer benzer çalışmalara kıyasla daha yüksek doğruluk sağladığını ve bu kombinasyonun gelecekteki araştırmalarda kullanılacak güçlü bir yöntem olduğunu göstermektedir.

Epileptik nöbet tespiti için yaygın olarak kullanılan EEG veri tabanları arasında Bonn Üniversitesi EEG veri seti, CHB-MIT veri seti, TUH (Temple University Hospital) EEG veri seti ve Freiburg Epilepsi Merkezi veri seti öne çıkmaktadır. CHB-MIT veri seti, pediatrik hastalar üzerinde yapılan uzun süreli kayıtları içerirken, TUH veri seti, geniş hasta grupları ve daha uzun kayıt süreleri sunar. Freiburg veri seti ise yüksek çözünürlüklü elektrot yerleşimleri ve nöbet öncesi verileriyle dikkat çekmektedir. Ancak, Bonn Üniversitesi EEG veri seti, beş farklı sınıf (sağlıklı, nöbet dışı ve nöbet durumu gibi) için standart, temizlenmiş ve kolay erişilebilir segmentler sunarak diğer veri setlerinden ayrılır. Ayrıca, sinyaller artefaktlardan arındırılmış, 173.61 Hz. örnekleme oranında tek kanal olarak sağlanmıştır. Bu çalışmada Bonn Üniversitesi EEG veri seti tercih edilmiştir çünkü sınıfların ayrıştırılabilir olması, dengeli bir dağılım göstermesi ve yüksek doğrulukla sınıflandırma yapılabilmesine olanak tanınması, çalışmanın amaçlarına uygun bir veri yapısı sunmaktadır.

Tüm kanalların ortalamalarının alınması, farklı beyin bölgelerinden gelen sinyallerin özgün özelliklerini kaybetmesine yol açabilir. Bu yöntem, özellikle belirli bir bölgedeki anormal elektriksel aktivitenin analiz edilmesi gerektiği durumlarda, bölgesel bilginin kaybolmasına neden olabilir. Kanal bazında kaydedilen EEG verilerinin nöbet başlangıç noktalarını veya odaklarını tespit etmekte kritik önemi vardır, dolayısıyla bu bilgiler kaybedildiğinde, sınıflandırma veya tespit süreçlerinin hassasiyeti düşebilir. Bu çalışmada kullanılan verilerde, tüm kanalların ortalamasının alınmış olması, kanal bazındaki kritik bilgilerin kaybına yol açmıştır. Bu durum, nöbetin hangi bölgede başladığını veya beyin genelindeki aktivite dağılımını anlamayı zorlaştırabilir ve çalışmada elde edilen sonuçların genellenebilirliği açısından bir kısıt olarak değerlendirilebilir. Ancak bu veri setinin artefaktsız ve dengeli yapısı, literatürde diğer veri setlerine göre yaygın olarak tercih edilmesi çalışmanın temel hedeflerini desteklemektedir, bu nedenle, sınırlılıklara rağmen veri seti bu çalışmaya uygun görülmüştür. Öte yandan, bu veri seti, her bir bireyden kaydedilen 23,6 saniyelik bölümlerden oluşmaktadır. Ancak kayıt süresi göz önüne alındığında, bu bölümlerin her bir birey için tek bir oturumdan elde edilmiş olduğu aşikardır. Veri setinin sınırlı bir popülasyondan (5 birey) elde edilmiş olması, yöntemin geniş popülasyonlarda uygulanabilirliği açısından bir sınırlama oluşturmaktadır. Bu durum, çalışmanın bulgularının genellenebilirliğini kısıtlayabileceğinden, gelecekteki çalışmalarda daha geniş ve farklı popülasyonlardan veri kullanılması önemlidir.

#### 4. SONUÇ (CONCLUSION)

Bu çalışma, epileptik nöbetlerin otomatik tespitinde güç spektral yoğunluğu yöntemleri ve sınıflandırıcılar arasındaki etkileşimleri inceleyerek, nöbet tespitinin doğruluğunu artırmada önemli rol oynayan parametreleri belirlemeyi amaçlamıştır. Epileptik nöbetlerin erken ve doğru bir şekilde tespit edilmesi, hastaların yaşam kalitesini artıran ve tedavi sürecini destekleyen bir unsurdur. Bu bağlamda, PSD hesaplama yöntemleri, sınıflandırıcı seçimi ve özellik vektörü belirlemenin doğruluğa olan etkileri detaylı şekilde analiz edilmiştir.

Epileptik nöbet tespitinde doğruluğu artırmada en etkili PSD-sınıflandırıcı kombinasyonları Music ve Lomb-Scargle gibi yüksek çözünürlüklü PSD yöntemleri ile Rastgele Orman ve k-en yakın komşu sınıflandırıcılarının birleştirilmesi olmuştur. Bu PSD yöntemleri, spektral çözünürlüğü yüksek yapılarıyla nöbet anındaki frekans bileşenlerini net bir şekilde ayrıştırabilmektedir. Özellikle çok sınıflı görevlerde, bu yöntemler sınıflar arası farkları daha belirgin hale getirmekte ve bu sayede sınıflandırıcıların doğruluk oranlarını önemli ölçüde artırmaktadır. Music-Rastgele Orman ve Lomb-Scargle-Rastgele Orman kombinasyonları, nöbet tespitinde en yüksek doğruluk oranlarını sağlamıştır. Music yöntemi, sinyaldeki ince frekans farklarını belirginleştirerek RF'nin karmaşık frekans yapısını anlamasını kolaylaştırmaktadır. Benzer şekilde, Lomb-Scargle yöntemi de düzensiz zaman aralıklarında yüksek çözünürlüklü spektral tahmin yapabilme yeteneği sayesinde nöbet tespitinde başarılı olmuştur.

Bu çalışmada kullanılan öznelik vektörlerinde spektral enerji farkı, spektral bant genişliği farkı, spektral entropi farkı, spektral düzlük, spektral varyans, toplam harmonik bozulma ve maksimum spektral sapma gibi spektral özellikler bulunmaktadır. Özellikle spektral enerji farkı ve spektral entropi farkı gibi özellikler, nöbet anındaki ani enerji değişikliklerini ve frekanslarda meydana gelen düzensizlikleri yansıttığından, sınıflandırıcıların nöbet tespit doğruluğunu artıran önemli özelliklerdir. Music ve Lomb-Scargle gibi PSD yöntemleri ile bu özelliklerin daha net ayrıştırılması, sınıflandırma performansını yükseltmiştir.

Çalışmanın sonuçları, epileptik nöbetlerin otomatik tespiti için PSD yöntemleri ve sınıflandırıcı seçiminde bazı stratejilerin uygulanmasının gerekliliğini ortaya koymuştur. Bu doğrultuda, Music ve Lomb-Scargle gibi yüksek çözünürlüklü PSD yöntemleri, sinyallerdeki frekans bileşenlerini hassas bir şekilde ayırt etme kapasitesine sahiptir. Bu nedenle, farklı yüksek çözünürlüklü PSD teknikleri eklenerek, nöbet tespitinde yeni başarı seviyelerine ulaşılabilir. Rastgele Orman gibi sınıflandırıcıların çok sınıflı sınıflandırma görevlerinde daha iyi performans gösterdiği görülmüştür. İleriki çalışmalarda, farklı sınıflandırıcıları bir araya getirerek yeni modeller oluşturmak, nöbet tespitinde daha yüksek doğruluk sağlayabilir. Bu çalışmada kullanılan spektral özelliklere ek olarak, sinyalin zaman-frekans özelliklerini içeren farklı spektral öznelikler veya

zamansal istatistikler (örneğin ortalama, medyan, standart sapma gibi) eklenerek öznelik vektörü genişletilebilir. Bu, sınıflandırma algoritmalarının nöbet sinyallerini daha kapsamlı analiz etmesine olanak sağlayacaktır. Epileptik nöbet tespitinde daha karmaşık ve ayrıntılı özellik çıkarımını sağlayabilen derin öğrenme algoritmaları da değerlendirilebilir. Özellikle Geleneksel Sinir Ağları veya Tekrarlayan Sinir Ağları gibi yapılar, PSD yöntemlerinden elde edilen spektral özelliklerle kombine edilerek nöbet tespit performansı karşılaştırılmalı olarak incelenebilir.

Bu çalışma, epileptik nöbet tespitinin doğruluğunu artırma potansiyelini vurgulamaktadır ve elde edilen sonuçlar, klinik uygulamalarda kullanılacak daha güvenilir ve hassas otomatik nöbet tespit sistemlerinin geliştirilmesine katkı sağlayabilir. Özellikle yüksek çözünürlüklü PSD yöntemleri ve güçlü sınıflandırıcı kombinasyonları, nöbetlerin erken tespiti ve tedavi sürecinin optimize edilmesinde önemli bir rol oynayabilir. Klinik ortamlarda, bu yaklaşımlar, hasta izleme sistemlerinin doğruluğunu artırarak, nöbetlerin daha hızlı ve doğru bir şekilde tespit edilmesine imkân tanıyabilir; böylece hastaların tedaviye daha hızlı yanıt vermelerini ve yaşam kalitelerinin iyileştirilmesini sağlayabilir.

Sonuç olarak, çalışmada elde edilen veriler, nöbet tespitinde PSD yöntemlerinin seçimi ve sınıflandırıcı yapıların uygunluğu ile elde edilebilecek doğruluğun artırılabilirliğini göstermektedir. Özellikle yüksek spektral çözünürlüklü PSD yöntemleri ile topluluk öğrenme temelli sınıflandırma algoritmalarının bir arada kullanılması, epileptik nöbet tespitinde etkili ve güvenilir bir yaklaşım sunmaktadır.

#### ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

#### YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

**Nuri İKİZLER:** Bilimsel yayın araştırması, yöntem-uygunluk araştırması, verilerin toplanması ve düzenlenmesi, yöntemlerin uygulanması, sonuçların yorumlanması, makalenin oluşturulması.

**Güneş EKİM:** Bilimsel yayın araştırması, yöntem-uygunluk araştırması, verilerin toplanması ve düzenlenmesi, yöntemlerin uygulanması, sonuçların yorumlanması, makalenin düzenlenmesi.

#### ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

## KAYNAKLAR (REFERENCES)

- [1] Beghi E., "The epidemiology of epilepsy", *Neuroepidemiology*, 54(2): 185-191, (2020).
- [2] Moshé S.L., Perucca E., Ryvlin P. and Tomson T., "Epilepsy: new advances", *The Lancet*, 385(9971): 884-898, (2015).
- [3] Acharya U.R., Sree S.V., Swapna G., Martis R.J. and Suri J.S., "Automated EEG analysis of epilepsy: a review", *Knowledge-Based Systems*, 45: 147-165, (2013).
- [4] Maganti R.K. and Rutecki P., "EEG and epilepsy monitoring", *CONTINUUM: Lifelong Learning in Neurology*, 19(3): 598-622, (2013).
- [5] Siddiqui M.K., Morales-Menendez R., Huang X. and Hussain N., "A review of epileptic seizure detection using machine learning classifiers", *Brain informatics*, 7(1): 5, (2020).
- [6] Abdullayeva E. and Örnek H.K., "Diagnosing Epilepsy from EEG Using Machine Learning and Welch Spectral Analysis", *Traitement du Signal*, 41(2): 971-977, (2024).
- [7] Shen M., Wen P., Song B. and Li Y., "An EEG based real-time epilepsy seizure detection approach using discrete wavelet transform and machine learning methods", *Biomedical Signal Processing and Control*, 77: 103820, (2022).
- [8] Chen D., Wan S., Xiang J. and Bao F.S., "A high-performance seizure detection algorithm based on Discrete Wavelet Transform (DWT) and EEG", *PLoS one*, 12(3): e0173138, (2017).
- [9] Omidvar M., Zahedi A. and Bakhshi H., "EEG signal processing for epilepsy seizure detection using 5-level Db4 discrete wavelet transform, GA-based feature selection and ANN/SVM classifiers", *Journal of ambient intelligence and humanized computing*, 12(11): 10395-10403, (2021).
- [10] Altunay S., Telatar Z. and Erogul O., "Epileptic EEG detection using the linear prediction error energy", *Expert Systems with Applications*, 37(8): 5661-5665, (2010).
- [11] Hassan A.R., Bashar S.K. and Bhuiyan M.I.H., "On the classification of sleep states by means of statistical and spectral features from single channel electroencephalogram", *2015 International conference on advances in computing, communications and informatics (ICACCI)*, Kochi, India, 2238-2243, IEEE, (2015).
- [12] Ahmad I., Wang X., Zhu M., Wang C., Pi Y., Khan J.A., Khan S., Samuel O.G., Chen S. and Li G., "EEG-Based Epileptic Seizure Detection via Machine/Deep Learning Approaches: A Systematic Review", *Computational Intelligence and Neuroscience*, 2022(1): 6486570, (2022).
- [13] Tran L.V., Tran H.M., Le T.M., Huynh T.T., Tran H.T. and Dao S.V., "Application of machine learning in epileptic seizure detection", *Diagnostics*, 12(11): 2879, (2022).
- [14] Prasanna C.S., Rahman M.Z.U. and Bayleyegn M.D., "Brain epileptic seizure detection using joint CNN and exhaustive feature selection with RNN-BLSTM classifier", *IEEE Access*, 11: 97990-98004, (2023).
- [15] Shekoker K.S. and Dour S., "Automatic epileptic seizure detection using LSTM networks", *World Journal of Engineering*, 19(2): 224-229, (2022).
- [16] Subasi A., Kevric J. and Abdullah Canbaz M., "Epileptic seizure detection using hybrid machine learning methods", *Neural Computing and Applications*, 31: 317-325, (2019).
- [17] Sahu R., Dash S.R., Cacha L.A., Poznanski R.R. and Parida S., "Epileptic seizure detection: a comparative study between deep and traditional machine learning techniques", *Journal of integrative neuroscience*, 19(1): 1-9, (2020).
- [18] Handa P., Mathur M. and Goel N., "EEG Datasets in Machine Learning Applications of Epilepsy Diagnosis and Seizure Detection", *SN Computer Science*, 4(5): 437, (2023).
- [19] Harpale V.K. and Bairagi V.K., "Time and frequency domain analysis of EEG signals for seizure detection: A review", *2016 International Conference on Microelectronics, Computing and Communications (MicroCom)*, Durgapur, India, 1-6 IEEE, (2016).
- [20] Alkan A. and Kiyimik M.K., "Comparison of AR and Welch methods in epileptic seizure detection", *Journal of Medical Systems*, 30: 413-419, (2006).
- [21] Demirel B.U., Skelin I., Zhang H., Lin J.J. and Al Faruque M.A., "Single-channel EEG based arousal level estimation using Multitaper spectrum estimation at low-power wearable devices", *2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Mexico, 542-545, IEEE, (2021).
- [22] Faust O., Acharya R.U., Allen A.R. and Lin C.M., "Analysis of EEG signals during epileptic and alcoholic states using AR modeling techniques", *Irbm*, 29(1): 44-52, (2008).
- [23] Pamula V.R., Van Hoof C. and Verhelst M., "Compressed Domain Feature Extraction", *Analog-and-Algorithm-Assisted Ultra-low Power Biosignal Acquisition Systems*, 55-67, (2019).
- [24] Übeyli E.D. and Güler İ., "Features extracted by eigenvector methods for detecting variability of EEG signals", *Pattern Recognition Letters*, 28(5): 592-603, (2007).
- [25] Liu S., Wang J., Li S. and Cai L., "Epileptic seizure detection and prediction in EEGs using power spectra density parameterization", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 31: 3884 – 3894, (2023).
- [26] Das P., Manikandan M.S. and Ramkumar B., "Detection of epileptic seizure event in EEG signals using variational mode decomposition and mode spectral entropy", *2018 IEEE 13th International Conference on Industrial and Information Systems (ICIIS)*, Rupnagar, India, 42-47, IEEE, (2018).
- [27] Boashash B., Barki H. and Ouelha S., "Performance evaluation of time-frequency image feature sets for improved classification and analysis of non-stationary signals: Application to newborn EEG seizure detection", *Knowledge-Based Systems*, 132: 188-203, (2017).
- [28] Heers M., Helias M., Hedrich T., Dümpelmann M., Schulze-Bonhage A. and Ball T., "Spectral bandwidth of interictal fast epileptic activity characterizes the seizure onset zone", *NeuroImage: Clinical*, 17: 865-872, (2018).
- [29] Tapani K.T., Vanhatalo S. and Stevenson N.J., "Time-varying EEG correlations improve automated neonatal

- seizure detection”, *International journal of neural systems*, 29(04): 1850030, (2019).
- [30] Vidyaratne L.S. and Iftexharuddin K.M., “Real-time epileptic seizure detection using EEG”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(11): 2146-2156, (2017).
- [31] Chakraborty M. and Mitra D., “Epilepsy seizure detection using kurtosis based VMD’s parameters selection and bandwidth features”, *Biomedical Signal Processing and Control*, 64: 102255, (2021).
- [32] Gowrishankar K., Muthukumar V., Sudhakara P.R., Deivasigamani S. and Ang C.K., “A Novel SVM and K-NN Classifier Based Machine Learning Technique for Epileptic Seizure Detection”, *International Journal of Online & Biomedical Engineering*, 19(7): 99-124, (2023).
- [33] Juba B. and Le H.S., “Precision-recall versus accuracy and the role of large data sets”, *Proceedings of the AAAI conference on artificial intelligence*, 33(01): 4039-4048, (2019).
- [34] Tuncer E. and Bolat E.D., “Destek vektör makinaları ile EEG sinyallerinden epileptik nöbet sınıflandırması”, *Politeknik Dergisi*, 25(1): 239-249, (2022).

ERKEN GÖRÜNÜM