



# **Epilepsi Tespitinde Gürbüz Yerel Ortalama Ayırışım ve Ampirik Kip Ayırışım Yöntemlerinin Performans Analizi**

Oğuzkaan Çatalakaya<sup>1</sup>, Tuba Hazman<sup>2</sup>, Sabrina Turturova<sup>3</sup>, Tuğba Şentürk<sup>4</sup>, Fatma Latifoğlu<sup>5\*</sup>

<sup>1</sup> Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Bölümü, Kayseri, Türkiye (ORCID: 0000-0001-6585-1728), [oguzkaancatalakaya111@gmail.com](mailto:oguzkaancatalakaya111@gmail.com)

<sup>2</sup> Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Bölümü, Kayseri, Türkiye (ORCID: 0000-0002-9562-4718), [hazmantuba@gmail.com](mailto:hazmantuba@gmail.com)

<sup>3</sup> Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Bölümü, Kayseri, Türkiye (ORCID: 0000-0002-1570-791X), [sabrina.tur.01@mail.ru](mailto:sabrina.tur.01@mail.ru)

<sup>4</sup> Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Bölümü, Kayseri, Türkiye (ORCID: 0000-0002-1323-5752), [tuğba.senturk@inonu.edu.tr](mailto:tuğba.senturk@inonu.edu.tr)

<sup>5\*</sup> Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Bölümü, Kayseri, Türkiye, (ORCID: 0000-0003-2018-9616), [flatifoglu@erciyes.edu.tr](mailto:flatifoglu@erciyes.edu.tr)

(3rd International Conference on Applied Engineering and Natural Sciences ICAENS 2022, July 20-23, 2022)

(DOI: 10.31590/ejosat.1145969)

**ATIF/REFERENCE:** Çatalakaya, O., Hazman, T., & Turturova, S. Şentürk, T., Latifoğlu, F. (2022). Epilepsi Tespiti İçin Gürbüz Yerel Mod Ayırışım ve Ampirik Kip Ayırışım Yönteminin Performans Analizi. *Avrupa Bilim ve Teknoloji Dergisi*, (39), 132-137.

## **Öz**

Beynin elektriksel aktivitesi ile ilgili bilgi sağlayan elektroansfalografı (EEG) verileri nörolojik hastalıkların tanısında yaygın olarak kullanılmaktadır. Yaklaşık olarak dünya nüfusunun %1'ini etkileyen hastalıklardan biri olan epilepsi tespitinde de EEG sinyalleri önemli bilgiler sağlamaktadır. Bu çalışmada EEG sinyalleri kullanılarak epilepsi nöbetinin nöbet öncesi tespiti amaçlanmıştır. Bu amaç doğrultusunda epilepsi ve sağlıklı bireylerden alınan farklı durumlardaki EEG sinyalleri kullanılarak ön işleme adımları gerçekleştirildikten sonra EEG sinyallerinden, Gürbüz Yerel Ortalama Ayırışım (Robust Local Mean Decomposition, RLMD) ve Ampirik Kip Ayırışım (AKA) yöntemi kullanılarak elde edilen alt bant sinyallerinden öznelikler çıkarılmıştır. Elde edilen öznelikler ve Yapay Sinir Ağları (YSA) ile sınıflandırma çalışmaları yapılmıştır. Yapılan çalışmalar doğrultusunda EEG sinyallerinin farklı durumlarına ait sınıflandırma sonuçları doğruluk, duyarlılık, özgüllük, kesinlik ve f1 skoru performans parametreleri kullanılarak ortaya konmuştur.

**Anahtar Kelimeler:** Epilepsi, EEG, Gürbüz Yerel Ortalama Ayırışım Yöntemi, Ampirik Kip Ayırışım Yöntemi, Yapay Sinir Ağları

## **Performance Analysis of Robust Local Mean Decomposition and Empirical Mode Decomposition Methods in the Detection of Epilepsy**

### **Abstract**

Electroencephalography (EEG) data, which provides information about the electrical activity of the brain, are widely used in the diagnosis of neurological diseases. EEG signals also provide important information in the detection of epilepsy, which is one of the diseases affecting approximately 1% of the world's population. In this study, it was aimed to detect the epileptic seizure before the seizure by using EEG signals. For this purpose, after preprocessing steps were performed by using EEG signals in different situations from epilepsy and healthy individuals, features were extracted from EEG signals from subband signals obtained by using Robust Local Mean Decomposition (RLMD) and Empirical Mode Decomposition (EMD) methods. Classification studies were carried out with the obtained features and Artificial Neural Networks (ANN). In line with the studies, the classification results of the different states of the EEG signals were revealed using the performance parameters of accuracy, sensitivity, specificity, precision and f1 score.

**Keywords:** Epilepsy, EEG, Robust Local Mean Decomposition, Empirical Mode Decomposition Method, Artificial neural networks

## 1. Giriş

Epilepsi, beyindeki kısa süreli ve beklenmedik elektriksel bozulma ile karakterize edilen paroksimal rahatsızlığı olarak bilinen ve yaygın olarak görülen bir nörolojik hastalıktır. Merkezi sinir sisteminde (MSS) bir grup nöronun ani ve anormal deşarjlarla ortaya çıkan nöbetler halinde gözlenir [1]. Manyetik rezonans görüntüleme, Bilgisayarlı tomografi, Pozitron emisyon tomografisi, Magnetoensefalogram gibi yöntemler epilepsi teşhisinde kullanılabilir. Ancak bu yöntemler, pahalı olması ve x ışını gerektirmesi gibi dezavantajlara sahiptir. Girişimsel olmayan, beyin elektriksel aktivitesi hakkında bilgi veren EEG, giderek yaygın hale gelmekte olup, epilepsi tanısı ve dolayısıyla tedavinin yönlendirilmesinde en sık kullanılan yöntemlerden biridir [2-4]. EEG sinyalleri, kafa derisi veya intrakraniyal (kafa içi) alana elektrotlar yerleştirilerek kayıt alınan doğrusal ve durağan olmayan zaman serileridir [5]. EEG sinyalleri epileptik nöbetlerin saptanmasında ve ayırımında önemli bir rol oynamaktadır. Ancak nöbet öncesi EEG sinyallerinin karakteri yalnızca epilepsi hastalarında değil aynı zamanda normal insanların EEG sinyallerinde de bulunabilmektedir [2], [3]. Bu nedenle epilepsi nöbeti öncesi epilepsi nöbetinin EEG sinyalleri kullanarak tespiti zordur.

Uzman nörologlar tarafından uzun süreli EEG kayıtlarının incelenmesi sonucu nöbet tespiti yapılmaktadır. Kayıtların elde edilmesi ve incelenmesi zaman alıcı olmasından dolayı teşhisin gecikmesi dezavantaj oluşturmaktadır. Bu dezavantajları giderebilecek ve aynı zamanda EEG verilerinin doğru bir şekilde sınıflandırılmasını sağlayacak otomatik nöbet tespit sistemlerinin geliştirilmesi gerekmektedir. Bu nedenle, uygun bir öznitelik çıkarma yöntemini belirlemek ve etkili bir sınıflandırıcı oluşturmak otomatik nöbet saptama yönteminin geliştirilmesi için çok önemlidir [5]. Epilepsi tespitine yönelik olarak EEG sinyalleri literatürde pek çok yöntemle analiz edilmiştir. Zaman domeni, frekans domeni, zaman-frekans domeni ve doğrusal, doğrusal olmayan yöntemlerle incelenmiştir. Ayrık dalgacık dönüşümü (ADD) [6] ve Stockwell dönüşümü (SD) [7] ve Kısa Zamanlı Fourier dönüşümü (KZFD) [8] gibi zaman-frekans domeni analiz yöntemleri, Tekil Spektrum Analizi (TSA) [9], AKA [10] gibi zaman domeni analiz yöntemleri ve Lyapunov üstelleri, fraktal boyut, çeşitli entropi hesapları gibi doğrusal olmayan yöntemler [11] kullanılmıştır. Ek olarak fraktal boyut (FD) [12] yaklaşık entropi [13], en büyük Lyapunov üsteli [14], korelasyon boyutu (CD) [14] ve İçsel Kip Fonksiyonları (Intrinsic Mode Functions, IMF) [12] gibi yöntemler literatürde epilepsi teşhisine yönelik EEG sinyallerinin analizi için kullanılmıştır.

Mutlu [15] epileptik ve normal EEG sinyallerinin sınıflandırılabilmesi için bir Hilbert Titreşim Ayrışım (Hilbert Vibration Decomposition, HVD) yöntemini önermiştir. Bu çalışmada, HVD yöntemi ile EEG sinyallerinin anlık frekanslarına göre IMF elde edilmiştir. Alt band sinyallerinden çıkarılan özelliklerin farklı fonksiyonlar kullanılarak karar destek makinesi sınıflandırıcı ile sınıflandırma işlemi gerçekleştirilmiştir. Polychronaki ve ark. [16], EEG sinyalleri kullanarak epileptik nöbetlerin başlangıcını tespit etmek üzere farklı fraktal boyutların (Katz, Higuchi ve k-en yakın komşu (k-NN) algoritması) hesabı ile sınıflandırma performansını araştırmıştır. Parametre seçimi aşamasında Çalışmaya göre, k-NN algoritması, EEG sinyalleri kullanarak epileptik nöbetlerin başlangıcının tespiti için umut verici olduğu görülmektedir.

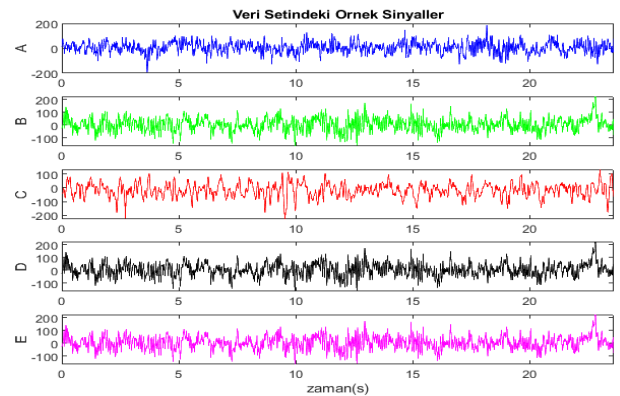
Bu çalışmada epilepsi ve sağlıklı bireylerden alınan farklı durumlardaki EEG sinyalleri kullanılarak epilepsinin erken tespitine yönelik özgün bir yöntem önerilmektedir. Hedeflenen bu yöntemde EEG sinyallerinden öznitelik çıkarmak ve alt-bantlara ayırtırmak için bu alanda literatürde ilk defa kullanılan çok değişkenli sinyali temel bir fonksiyona ihtiyaç duymadan çarpım fonksiyonu kullanarak ayırtıran RLMD tekniği kullanılmıştır. RLMD alt bant sinyallerinden ortalama değer, maksimum, minimum, standart sapma, entropi, hjorth parametrelerine ait öznitelikleri çıkarılmıştır. Elde edilen özellikler ve YSA ile sınıflandırma çalışmaları yapılmıştır.

Ayrıca RLMD yönteminin performansını karşılaştırmak için AKA yöntemi ile EEG sinyalleri alt bantlara ayırtırılmıştır ve özellik çıkarma sınıflandırma işlemleri RLMD-YSA yaklaşımında olduğu gibi benzer şekilde gerçekleştirilmiştir. Gerçekleştirilen bu çalışma ile epilepsinin erken tespitine yönelik yüksek sınıflandırma performansı sağlayan RLMD yöntemini kullanan yenilikçi yaklaşım ortaya konmuştur.

## 2. Materyal ve Metot

### 2.1. Veri Seti

EEG sinyalleri Bonn veri tabanından elde edilmiştir [17]. Veri seti sağlıklı ve epilepsi hastası olan toplam olarak 10 bireyden oluşmaktadır. EEG sinyalleri 173.61 Hz frekans değerinde örneklenecek elde edilmiş olup, kayıt süresi 23.6 saniyedir ve EEG sinyalleri 4097 örnekten oluşmaktadır. Bu veri tabanında 5 adet alt klasör bulunmaktadır. A, B, C, D ve E isimleri verilen kayıtların her biri 100 adet olmak üzere toplam 500 adet kayıttan oluşmaktadır. A klasörü içerisinde gözleri açık ve sağlıklı olan bireylerden elde edilen EEG sinyalleri; B klasörü içerisinde gözleri kapalı ve sağlıklı olan bireylerden elde edilen EEG sinyalleri; C klasöründe epilepsi hastalarından epilepsi nöbeti geçirmeden önce epileptik olmayan bölgeden kaydedilen EEG sinyalleri; D klasöründe epilepsi hastalarından epilepsi nöbeti geçirmeden önce epileptik bölgeden alınan EEG sinyalleri; E klasöründe ise epilepsi hastalarından epilepsi nöbeti sırasında kaydedilen EEG sinyalleri bulunmaktadır. EEG verileri, 0.45–40 Hz frekansları arasındaki frekans bileşenlerinin elde edilmesi amacı ile bant geçiren filtre ile filtrelenmiştir. Şekil-1’de örnek bir EEG sinyali verilmiştir.



Şekil 1. Veri setine ait örnek bir EEG sinyali

### 2.1.1. Ampirik Kip Ayrışım Yöntemi

Huang ve arkadaşları tarafından geliştirilen AKA yöntemi, durağan olmayan sinyalleri analizi etmek için önerilmiştir [18]. Bu yöntem de temel olarak karmaşıklık durumuna bağlı olarak sinyallerin aynı anda birden fazla farklı eş zamana sahip salınım

kiplerine sahip olabileceği durumu varsayılmaktadır. Böylece karmaşık bir sinyali nispeten durağan alt seriler olan ve modellenen IMF bileşenlerine ayrıştırılabilmektedir [19]. Burada, IMF karmaşık sinyallerin yerel karakteristik ölçeğine dayanılarak çıkarılmaktadır. AKA'da bir fonksiyon aşağıdaki iki koşulu sağlıyorsa IMF olarak tanımlanmaktadır. Bu koşullar;

- Sinyalin tamamında, ekstrem değerlerin toplamı ve sıfır geçişlerin toplamı eşit olmalıdır,
- Yerel maksimum ve minimum şeklinde tanımlanan zarfın ortalaması herhangi bir noktada sıfır olmalıdır [20].

Belirtilen bu iki koşul bir IMF'nin hemen hemen periyodik bir fonksiyon olmasını ve ortalamasının sıfıra ayarlanmasını sağlamaktadır. AKA yöntemi literatürde EEG ve EKG gibi fizyolojik sinyalleri ayrıştırmak ve sinyallerden gürültüyü gidermek için kullanılmıştır. Slimane ve ark. [19] EKG sinyallerinden QRS kompleksini saptamak için AKA yöntemini kullanmıştır. Bajaj ve ark. [20] EEG sinyallerine AKA yöntemini kullanarak epilepsi hastalığının teşhisi için bir yöntem önerirken, Zhang ve ark. [21] EEG sinyallerinden gürültüyü gidermek için AKA yöntem tabanlı bir algoritma geliştirmiştir.

Bu çalışmada ise EEG sinyalleri AKA yöntemi kullanılarak alt banda ayrılmıştır ve alt bant sinyallerinden elde edilen özellikler ile epilepsi tespiti gerçekleştirilmiştir.

### 2.1.2. Gürbüz Yerel Ortalama Ayrıştırma

Yerel ortalama ayrışma (Local Mean Decomposition, LMD) ilk olarak Smith [22] tarafından sunulmuştur. Doğrusal olmayan ve durağan olmayan sinyal analizi için kullanılabilen yeni bir yinelemeli ayrıştırma yöntemidir. LMD yöntemini kullanarak, karmaşık EEG sinyalleri, frekans modülasyonlu bir sinyale ve bir zarf sinyaline demodüle edilebilir hale getirilmektedir. Bu iki sinyalin çarpımı, fiziksel olarak önemli olabilen çarpım fonksiyonlarıdır (product function, PF) [22]. AKA ile karşılaştırıldığında, LMD, kübik spline çizgileri yerine sinyal zarfını hesaplamak için düzleştirilmiş araçları ve yerel büyüklükleri kullanmaktadır [23]. Az miktarda hesaplama ve hızlı işlem kabiliyeti sayesinde epilepsi gibi nörolojik hastalıklarda LMD'yi gerçek zamanlı nöbet tahmini için uygun hale getirmektedir. LMD yönteminin geliştirilmesi sonucu ortaya çıkan RLMD yöntemi ile orijinal sinyali daha az karmaşık alt sinyallere ayrıştırmak hedeflenmiştir [22]. RLMD, genlik modüleli ve frekans modüleli sinyallerde ayrışım yapmak için uygulanmaktadır [24] ve işlem adımları aşağıda yer almaktadır.

1.  $X(t)$  sinyalindeki tüm maksimum ve minimum noktaları içeren ekstreme değerleri eşitlik 1 de görüldüğü gibi belirlenir.

$$n_{II}(k_I), I=1,2,\dots,M \quad (1)$$

Ekstrem değerlerin ortalaması eşitlik 2 de görüldüğü gibi belirlenir (2):

$$m_{II}(t) = \frac{n_{II}(k_I) + n_{II}(k_{I+1})}{2} \quad k_I = k_1, k_2, k_3, \dots, k_{M-1}, t \in [k_I, k_{I+1}] \quad (2)$$

Yerel genlikler eşitlik 3 te görüldüğü gibi belirlenir.

$$a_{II}(t) = \frac{n_{II}(k_I) - n_{II}(k_{I+1})}{2} \quad (3)$$

2.  $a_{II}(t)$  yerel genliği ve  $m_{II}(t)$  ortalama değeri kullanılarak kayan ortalama (Moving Average, MA) yöntemiyle  $\widehat{a}_{II}(t)$   $\widehat{m}_{II}(t)$  değerleri eşitlik 4 te verildiği gibi elde edilmektedir.

$$dh_{II}(t) = x(t) - \widehat{m}_{II}(t), \quad s_{II}(t) = \frac{h_{II}(t)}{\widehat{a}_{II}(t)} \quad (4)$$

Eğer  $s_{II}(t)$  sinyali  $[-1,1]$  aralığında bir çarpım sinyali değilse yeni  $s_{II}(t)$  sinyalini elde etmek için işlemlere devam edilir. Bu işlem  $s_{II}(t)$  sinyalini bir çarpım sinyali olana kadar devam ettirilir. Elde edilen  $s_{II}(t)$  sinyallerinin ani frekansı (Hilbert frekansı) eşitlik 5 te verildiği gibi elde edilir.

$$f_1(t) = \frac{d\varphi_1(t)}{2\pi dt}, \quad \varphi_1(t) = \arccos(s_{II}(t)) \quad (5)$$

Ani frekans genlikleri yerel genliklerin çarpımı ile elde edilir ve aşağıda verilen eşitlik 6 ile tanımlanmaktadır.

$$a_I(t) = a_{I1}(t)a_{I2}(t)a_{I3}(t) \dots a_{II}(t) = \prod_{q=1}^n a_{Iq}(t) \quad (6)$$

İlk çarpım sinyali eşitlik 7 de görüldüğü gibi elde edilir.

$$PF_1(t) = a_1(t)s_{In}(t) \quad (7)$$

3. İlk çarpım sinyalini ( $PF_1(t)$ )  $x(t)$  sinyalinden çıkarılarak elde edilen  $u_1(t)$  sinyali yeni orijinal sinyal olarak kabul edilir ve yeni çarpım sinyalini elde etmek için yukarıda bahsedilen işlem adımları uygulanır.  $x(t)$  sinyali eşitlik 8 de görüldüğü gibi çarpım sinyalleri ve artık sinyalin toplamından oluşmaktadır.

$$Cfu_1(t) = x(t) - PF_1(t), \quad x(t) = \sum_{p=1}^k PF_p(t) + u_k(t) \quad (8)$$

### 2.1.3. Özellik Çıkarma

Öznitelik çıkarımı bir sinyalin karakteristiğinin en iyi şekilde ortaya koyulması işlemidir. Bu çalışmada öznitelik çıkarımı için ortalama, maksimum ve minimum, standart sapma, entropi ve hjorth parametreleri gibi öznitelik çıkarım yöntemleri kullanılmıştır. Öz niteliklerin eldesi aşağıda yer alan Eşitlik 9-16 da görülmektedir.

$n=1, 2, 3, \dots, N$  olmak üzere;

- Ortalama:

$$X_{\text{mean}} = \sum_{i=1}^N \frac{x(n)}{N} \quad (9)$$

- Maksimum:

$$x_{\text{max}} = \max(x(n)) \quad (10)$$

- Minimum:

$$x_{\text{min}} = \min(x(n)) \quad (11)$$

- Standart Sapma:

$$x_{\text{std}} = \sqrt{\frac{1}{N} \sum_{n=1}^N (x(n) - x_{\text{ort}})^2} \quad (12)$$

Entropi:

$$x_{\text{entropy}} = - \sum_{i=1}^N x^2(n) \log x^2(n) \quad (13)$$

Hjort Parametreleri:

Hjorth parametreleri bir sinyalin ortalama değeri ve türevi ile ilişkili olarak elde edilen etkinlik, hareketlilik ve karmaşıklık parametrelerinden oluşan bir betimleyicilerdir. Bu parametreler 1970 yılında Hjorth tarafından EEG sinyallerinin analizi için önerilmiştir. Etkinlik değeri işaretin varyansına eşit olmaktadır ve zaman uzayında N örnekten oluşan bir X işaretinin etkinlik değeri eşitlik 14 kullanılarak hesaplanmaktadır.

$$A(Xi) = \sigma_{xi}^2 \frac{\sum_{i=1}^N (Xi - \bar{X})^2}{N-1} \quad (14)$$

Burada X, X işaretinin ortalamasını göstermektedir. Hareketlilik parametresi, işaretin ortalama frekansının bir ölçütüdür ve eşitlik 15 kullanılarak hesaplanmaktadır.

$$M(Xi) = \frac{\sigma_{\dot{X}i}}{\sigma_{Xi}} = \frac{\sqrt{\frac{\sum_{i=1}^N (\dot{X}i - \bar{\dot{X}})^2}{N-1}}}{\sqrt{A(Xi)}} \quad (15)$$

Burada  $\dot{X}$ , işaretin birinci dereceden türevine karşılık gelmektedir. Karmaşıklık parametresi ise işaretin sinüs işaretinden sapmasının bir ölçüsü olup, eşitlik 16 kullanılarak elde edilmektedir.

$$C(Xi) = \frac{\sigma_{\dot{X}i}/\sigma_{\ddot{X}i}}{\sigma_{\dot{X}i}/\sigma_{Xi}} \quad (16)$$

$\ddot{X}$ , işaretin ikinci dereceden türevini ifade etmektedir [25], [26].

#### 2.1.4. Yapay Sinir Ağları


Yapay sinir ağları (YSA), biyolojik sinir sistemlerinin bilgi işleme yöntemlerini örnekleyen matematiksel modellerdir. Birbirine bağlı olarak çalışan nöronlardan oluşan YSA, mimarisıyla veri sınıflandırması gibi uygulamalar için kullanılmaktadır [27]. Bir yapay sinir ağı girdi katmanı, ara katmanlar ve çıktı katmanı olmak üzere temel olarak üç katmandan oluşmaktadır. Girdi katmanı aracılığıyla ağa uygulanan bilgiler, ara katmanlarda ağırlık değerleri kullanılarak çıktı fonksiyonuna dönüştürülür ve çıktı katmanına gönderilir. Ağırlık istenilen çıktıları üretebilmesi için ağırlık değerlerinin uygun bir şekilde güncellenmesi gerekmektedir. Başlangıçta ağırlık değerleri rastgele atanır, sonra her bir örnek ağa girdi olarak uygulanarak ağırlık öğrenme kuralına göre ağırlıklar değiştirilir. Bu işlem ağırlık eğitimi olarak adlandırılır.

Ağırlıkların güncellenmesi ile doğru çıktılar üretilince test setindeki örnekler ağa gösterilir. Ağ test setindeki örneklere doğru cevaplar verirse eğitilmiş olarak kabul edilmektedir [28].

Gerçekleştirilen çalışmada, bir ara katmandan oluşan YSA mimarisini geliştirilmiştir. Ara katman nöron sayısı 1'den 10'a kadar artırılarak en iyi sınıflandırma performansını elde edildiği ara katman nöron sayısı belirlenmiştir. Gizli katmanlar için tanjnat sigmoidal aktivasyon fonksiyonu kullanılırken çıktı katmanında ise lineer aktivasyon fonksiyonu kullanılmıştır. Optimizasyon algoritması olarak Levenberg-Marquardt geri yayımlı optimizasyon algoritması kullanılmıştır. Ağırlık eğitimi

için iterasyon sayısı 100; öğrenme oranı ise 0.001 olarak ayarlanmıştır. Eğitimde aşamasında 5 katmanlı çapraz doğrulama ile yapılmıştır. Çapraz doğrulamada veri 5 eşit parçaya bölünerek her döngüde bu 5 eşit parçanın 1 tanesi test için geri kalanlarını ise ağırlık eğitimi kullanılmaktadır.

Bu çalışmada sınıflandırıcı performanslarının değerlendirilmesi amacıyla karmaşıklık matrisi (Şekil 2) kullanılarak doğruluk, duyarlılık, özgüllük, kesinlik ve f1 skoru parametreleri eşitlik 17-21 den de görüldüğü gibi hesaplanmıştır. Karmaşıklık matrisinde bulunan DN; Doğru Negatif, DP; Doğru Pozitif, YP; Yanlış Pozitif, YN; Yanlış Negatif değerini temsil etmektedir. Gerçek sınıflara karşılık doğru veya yanlış tahminlerin sayısal olarak ifade edilmesi amacıyla karmaşıklık matrisi kullanılmaktadır.



Şekil 2. Karmaşıklık matrisi

$$\text{Doğruluk} = \frac{DN + DP}{DP + DN + YP + YN} \quad (17)$$

$$\text{Duyarlılık} = \frac{DP}{DP + DN} \quad (18)$$

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (19)$$

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (20)$$

$$\text{F1 skoru} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (21)$$

### 3. Araştırma Sonuçları ve Tartışma

#### 3.1. Bulgular

Bu çalışmada EEG sinyallerine ön işlem gerçekleştirilmeden yöntem kısmında belirtilen öznelikler (7 adet; ortalama, maksimum ve minimum, standart sapma, entropi ve hjorth parametreleri) ile A-E, B-E, C-E ve D-E grupları YSA kullanılarak sınıflandırılmıştır. Sınıflandırma sonucunda elde edilen performans parametrelerine ait sonuçlar Tablo 1' de görülmektedir.

Tablo 1. A-E, B-E, C-E ve D-E gruplarına ait YSA kullanılarak sınıflandırılması ile oluşan değerler

	A-E	B-E	C-E	D-E
Doğruluk (%)	99.50 (±1.12)	99.50 (±1.12)	97.50 (±3.54)	93.50 (±5.48)
Duyarlılık (%)	99.09 (±2.03)	99.05 (±2.13)	96.52 (±4.86)	92.45 (±5.10)

Özgüllük (%)	100	100	99.00 (±2.24)	95.45 (±7.88)
Kesinlik (%)	100	100	98.95 (±2.36)	94.89 (±8.66)
F1 Skoru (%)	99.53 (±1.04)	99.51 (±1.10)	97.69 (±3.44)	93.50 (±5.81)

Ayrıca RLMD yöntemi kullanılarak EEG sinyalleri alt bantlara ayrıştırılmıştır ve alt bant sinyallerinden öznitelikler çıkarılarak sınıflandırma çalışması yapılmıştır. RLMD-YSA Modeli

kullanılarak elde edilen sınıflandırma sonuçlarını gösteren parametrelerine ait sonuçlar Tablo 2’ de yer almaktadır.

Tablo 2. A-E, B-E, C-E ve D-E gruplarına ait RLMD-YSA modeli kullanılarak sınıflandırılması ile oluşan değerler

	A-E	B-E	C-E	D-E
Doğruluk (%)	99.46 (±1.21)	97.90 (±2.21)	97.74 (±3.72)	92.50 (±4.30)
Duyarlılık (%)	98.18 (±4.07)	97.40 (±3.90)	97.27 (±6.10)	95.52 (±4.53)
Özgüllük (%)	100	99.09 (±2.03)	98.89 (±2.49)	90.74 (±7.35)
Kesinlik (%)	100	98.82 (±2.63)	99.00 (±2.24)	92.34 (±5.01)
F1 Skoru (%)	99.05 (±2.13)	98.04 (±1.98)	98.02 (±3.19)	92.76 (±3.01)

Epilepsinin EEG sinyalleri ile sınıflandırılması ve performansının değerlendirilmesi amacıyla AKA yöntemi de kullanılmıştır. EEG sinyalleri AKA yöntemi ile alt banda

ayrıştırılan sinyallerinden öznitelikler çıkarılmıştır. AKA-YSA Modeli kullanılarak elde edilen sınıflandırma sonuçlarını gösteren parametrelerine ait sonuçlar Tablo 3’ de yer verilmiştir.

Tablo 3. A-E, B-E, C-E ve D-E gruplarına ait AKA-YSA modeli kullanılarak sınıflandırılması ile oluşan değerler

	A-E	B-E	C-E	D-E
Doğruluk (%)	99.50 (±1.12)	98.00 (±1.12)	97.00 (±3.26)	90.50 (±2.74)
Duyarlılık (%)	98.75 (±2.79)	97.13 (±2.64)	98.10 (±2.64)	93.36 (±7.34)
Özgüllük (%)	100	99.26 (±1.66)	98.04 (±2.68)	89.14 (±5.76)
Kesinlik (%)	100	98.57 (±3.20)	97.99 (±2.76)	87.63 (±9.35)
F1 Skoru (%)	99.35 (±1.44)	97.78 (±1.36)	96.92 (±3.37)	89.86 (±4.09)

## 4. Sonuçlar ve Tartışma

Epilepsi verilerine ait EEG sinyalleri ile ilgili literatürde pek çok analiz yöntemi mevcuttur. Bu çalışmada epilepsi bireylerden elde edilen EEG sinyallerini YSA, RLMD-YSA ve AKA-YSA yöntemleri ile A-E, B-E, C-E ve D-E grupları arasında sınıflandırılarak, önerilen yöntemlerin performansları analizi elde edilmiştir.

A-E grubuna ait arasındaki sınıflandırma sonuçlarına bakıldığında YSA kullanılarak elde edilen sınıflandırma sonucunun özgüllük ve kesinlik değerleri YSA, RLMD-YSA ve AKA-YSA sınıflandırma yöntemlerinde %100 olarak elde edilmiştir. Diğer metrikler bakıldığında, YSA ve AKA-YSA modellerinde sınıflandırıcı doğruluk değeri %99.50 iken RLMD-YSA %99.46 doğruluğu elde edilmiştir.

B-E grubu incelendiğinde YSA ile sınıflandırması sonucu özgüllük ve kesinlik değerleri %100 elde edilirken doğruluk, duyarlılık ve F1 skor değerleri bu model de yüksek performans sergilemiştir.

D-E grubunda; özgüllük, kesinlik ve F1 skoru AKA-YSA modeli kullanılarak sınıflandırılması ile oluşan değerler diğer sınıflandırma yöntemlerine göre düşük performans sergilemiştir. Bu gruba ait doğruluk sonuçları (D; epilepsi hastalarından epilepsi nöbeti geçirmeden önce epileptik bölgeden alınan, E; epilepsi hastalarından epilepsi atağı sırasında kaydedilen sinyaller) YSA ile sınıflandırıldığında %93.50 ulaşırken;

özgüllük hariç diğer metriklerde de yüksek sonuçlar elde edilmiştir.

Yapılan bu çalışmada epilepsinin EEG sinyallerinden tespitine yönelik YSA, RLMD-YSA, AKA-YSA yöntemlerinin performansı analiz edilmiştir.

Gelecek çalışmalarda önerilen bu yöntemlerin farklı EEG veri setlerine uygulanması, ayrıca çeşitli hastalıkların tespitinde literatürde yeni kullanılmaya başlanılan RLMD yönteminin uygulanması planlanmaktadır.

## 5. Teşekkür

Bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı kapsamında 1919B012111299 numaralı proje ile desteklenmiştir. Bu sebeple TÜBİTAK 'a teşekkürlerimizi sunarız.

## Kaynakça

- [1] Ghassemi, N., Shoeibi, A., Rouhani, M., & Hosseini-Nejad, H. (2019, October). Epileptic seizures detection in EEG signals using TQWT and ensemble learning. In *2019 9th International Conference on Computer and Knowledge Engineering (ICCKE)* (pp. 403-408). IEEE.

- [2] Pachori, R. B., & Patidar, S. (2014). Epileptic seizure classification in EEG signals using second-order difference plot of intrinsic mode functions. *Computer methods and programs in biomedicine*, 113(2), 494-502.
- [3] Mader Jr, E. C., & Olejniczak, P. W. (2010). Epilepsy syndromes. *Epilepsy and intensive care monitoring: principles and practice*. New York, 119-150.
- [4] Vidyaratne, L. S., & Iftekharuddin, K. M. (2017). Real-time epileptic seizure detection using EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(11), 2146-2156.
- [5] Li, M., Chen, W., & Zhang, T. (2016). Automatic epilepsy detection using wavelet-based nonlinear analysis and optimized SVM. *Biocybernetics and biomedical engineering*, 36(4), 708-718.
- [6] Hamad, A., Houssein, E. H., Hassanien, A. E., & Fahmy, A. A. (2016, December). Feature extraction of epilepsy EEG using discrete wavelet transform. In *2016 12th international computer engineering conference (ICENCO)* (pp. 190-195). IEEE.
- [7] Yan, A., Zhou, W., Yuan, Q., Yuan, S., Wu, Q., Zhao, X., & Wang, J. (2015). Automatic seizure detection using Stockwell transform and boosting algorithm for long-term EEG. *Epilepsy & Behavior*, 45, 8-14.
- [8] Samiee, K., Kovacs, P., & Gabbouj, M. (2014). Epileptic seizure classification of EEG time-series using rational discrete short-time Fourier transform. *IEEE transactions on Biomedical Engineering*, 62(2), 541-552.
- [9] Atoufi, B., Zakerolhosseini, A., & Lucas, C. (2009, October). Improving EEG signal prediction via SSA and channel selection. In *2009 14th International CSI Computer Conference* (pp. 349-354). IEEE.
- [10] Hassan, A. R., & Haque, M. A. (2015, November). Epilepsy and seizure detection using statistical features in the complete ensemble empirical mode decomposition domain. In *TENCON 2015-2015 IEEE region 10 conference* (pp. 1-6). IEEE.
- [11] Valenza, G., Romigi, A., Citi, L., Placidi, F., Izzi, F., Albanese, M., ... & Barbieri, R. (2016, August). Predicting seizures in untreated temporal lobe epilepsy using point-process nonlinear models of heartbeat dynamics. In *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 985-988). IEEE.
- [12] Sharma, M., Pachori, R. B., & Acharya, U. R. (2017). A new approach to characterize epileptic seizures using analytic time-frequency flexible wavelet transform and fractal dimension. *Pattern Recognition Letters*, 94, 172-179.
- [13] Srinivasan, V., Eswaran, C., & Sriraam, N. (2007). Approximate entropy-based epileptic EEG detection using artificial neural networks. *IEEE Transactions on information Technology in Biomedicine*, 11(3), 288-295.
- [14] Adeli, H., Ghosh-Dastidar, S., & Dadmehr, N. (2007). A wavelet-chaos methodology for analysis of EEGs and EEG subbands to detect seizure and epilepsy. *IEEE Transactions on Biomedical Engineering*, 54(2), 205-211.
- [15] Mutlu, A. Y. (2018). Detection of epileptic dysfunctions in EEG signals using Hilbert vibration decomposition. *Biomedical Signal Processing and Control*, 40, 33-40.
- [16] Polychronaki, G. E., Ktonas, P. Y., Gatzonis, S., Siatouni, A., Asvestas, P. A., Tsekou, H., ... & Nikita, K. S. (2010). Comparison of fractal dimension estimation algorithms for epileptic seizure onset detection. *Journal of neural engineering*, 7(4), 046007.
- [17] Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., & Elger, C. E. (2001). Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. *Physical Review E*, 64(6), 061907. Available from: <https://repositori.upf.edu/handle/10230/42894>
- [18] Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... & Liu, H. H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, 454(1971), 903-995.
- [19] Slimane, Z. E. H., & Naït-Ali, A. (2010). QRS complex detection using empirical mode decomposition. *Digital signal processing*, 20(4), 1221-1228.
- [19] Chen, C. F., Lai, M. C., & Yeh, C. C. (2012). Forecasting tourism demand based on empirical mode decomposition and neural network. *Knowledge-Based Systems*, 26, 281-287.
- [20] Pachori, R. B., & Bajaj, V. (2011). Analysis of normal and epileptic seizure EEG signals using empirical mode decomposition. *Computer methods and programs in biomedicine*, 104(3), 373-381.
- [21] Zhang, D. X., Wu, X. P., & Guo, X. J. (2008, May). The EEG signal preprocessing based on empirical mode decomposition. In *2008 2nd International Conference on Bioinformatics and Biomedical Engineering* (pp. 2131-2134). IEEE.
- [22] Smith, J. S. (2005). The local mean decomposition and its application to EEG perception data. *Journal of the Royal Society Interface*, 2(5), 443-454.
- [23] Xie, L., Lang, X., Chen, J., Horch, A., & Su, H. (2016). Time-varying oscillation detector based on improved LMD and robust Lempel–Ziv complexity. *Control Engineering Practice*, 51, 48-57.
- [24] Yongbo, L. I., Shubin, S. I., Zhiliang, L. I. U., & Xihui, L. (2019). Review of local mean decomposition and its application in fault diagnosis of rotating machinery. *Journal of Systems Engineering and Electronics*, 30(4), 799-814.
- [25] Kutlu, F. (2014). Melez sınıflandırma yaklaşımı ile EEG işaretlerinden epileptik dönemlerin algılanması (Doctoral dissertation, Karadeniz Teknik Üniversitesi).
- [26] Ekhlası, A., Nasrabadi, A. M., & Mohammadi, M. R. (2021). Direction of information flow between brain regions in ADHD and healthy children based on EEG by using directed phase transfer entropy. *Cognitive Neurodynamics*, 15(6), 975-986.
- [27] Er kaymaz, H., Ozer, M., & Orak, İ. M. (2015). Detection of directional eye movements based on the electrooculogram signals through an artificial neural network. *Chaos, Solitons & Fractals*, 77, 225-229.
- [28] Öztemel, E., (2012). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık Eğitim