



## Epileptik EEG Sinyallerinin Sınıflandırılması için Bir Boyutlu Medyan Yerel İkili Örüntü Temelli Öznitelik Çıkarımı

Ömer Türk<sup>1\*</sup>, Mehmet Sıraç Özerdem<sup>2</sup>

<sup>1</sup>Mardin Artuklu Üniversitesi, Midyat Meslek Yüksekokulu, Mardin, Türkiye

<sup>2</sup>Dicle Üniversitesi, Elektrik-Elektronik Mühendisliği, Diyarbakır, Türkiye

### Makale Bilgisi

Başvuru: 18/05/2017  
 Düzeltilme: 07/09/2017  
 Kabul: 07/09/2017

### Anahtar Kelimeler

Epilepsi Tespiti  
 k-NN  
 Bir Boyutlu Medyan Yerel  
 İkili Örüntü

### Keywords

Epilepsy Detection  
 k-NN  
 One Dimension Median  
 Local Binary Pattern.

### Öz

Elektroensefalogram (EEG), epilepsi tespitinde yaygın olarak kullanılan önemli bir veri kaynağıdır. Bu çalışmada da Bonn Üniversitesi Epileptoloji bölümü veritabanından alınan ve A, B, C, D, E olmak üzere 5 işaret grubundan oluşan EEG kayıtları kullanılmıştır. Bir boyutlu medyan yerel ikili örüntü (1B-MYİÖ) yöntemi uygulanarak elde edilen özniteliklerin k-En Yakın Komşu (k-NN) sınıflandırıcısı ile sınıflandırılması amaçlanmıştır. Çalışmada geliştirilen 1B-MYİÖ yönteminin öznitelik olarak sınıflandırma başarısı değerlendirilmiştir. Bu sınıflandırma için karışıklık matrisi hesaplanarak model başarımları ölçümlü yapılmıştır. Çalışmada A-E veri setleri için sınıflandırma performansı %100, A-D veri setleri için %99.00, D-E veri setleri için %98.00, E-CD veri setleri için %99.50 ve A-D-E veri setleri için de %96.00 olarak bulunmuştur. Çalışmada kullanılan 1B-MYİÖ yönteminin, literatürde kullanılan birçok yöntemden daha iyi sonuç verdiği görülmüştür.

### One Dimensional Median Local Binary Pattern Based Feature Extraction For Classifying Epileptic EEG Signals

### Abstract

Electroencephalogram is an important data source that widely used in detecting epilepsy. In this study, EEG records consisting of five markers A, B, C, D, E that obtained from the database of Epilopy of Bonn University Epileptology Department was used. The feature vectors that obtained by applying the one dimension median local binary pattern (1D-MLBP) method were classified by using k nearest neighbor (kNN) algorithm. The classification performance related to 1D-MLBP method developed was evaluated as an attribute. For this classification, the performance criteria was evaluated by calculating the confusion matrix. In this study, the classification performance for the A-E data sets was found to be 100.0%, 99.00% for the A-D data sets, 98.00% for the D-E data sets, 99.50% for the E-CD data sets and 96.00% for the A-D-E data sets. It has been seen that 1D-MLBP method used in the study gives better results than many methods used in the literature.

## 1. GİRİŞ (INTRODUCTION)

Epilepsi nöbeti, sinir hücrelerinde geçici olarak meydana gelen anormal elektriksel aktivitedir. Yaklaşık dünya nüfusunun %0.5 ile %1'inin bu bozukluğa maruz kaldığı belirtilmektedir [1]. Epilepsi tanısı için kullanılan en yaygın yöntemlerden biri, EEG aktivitesidir. EEG elektrotları kafa derisine yerleştirilerek beyindeki nörolojik aktiviteleri kayıt eder [2]. Acil durumlarda uzman kişiler bulunmadığında, epileptik nöbet tespiti çok zor ve zahmetlidir. Bu neden, otomatik epilepsi tespitini çok önemli bir noktaya taşımaktadır.

EEG kayıtlarından epilepsi tespiti için sınıflandırma yönteminde izlenen yol; EEG kaydının alınması ve artefaktlardan arındırılarak işlenebilir forma getirilmesi, özniteliklerin çıkarılması ve sınıflandırıcılar ile özniteliklerin sınıflandırılması aşamalarından oluşmaktadır. Epileptik nöbet tespiti, bir girdi sinyalinin, epileptik nöbet sinyali veya nöbet yok sinyali olarak sınıflandırılması olarak düşünülebilir.

\*İletişim yazarı, e-mail: [omerturk@artuklu.edu.tr](mailto:omerturk@artuklu.edu.tr)

EEG sinyallerinin çok uzun olmasından dolayı, sinyalin tamamının işlenmesi hem zaman hem de maliyet gerektirmektedir. Bundan dolayı sinyalin karakteristiğini temsil edebilecek öznelik elde etme yöntemleri ortaya çıkmıştır. EEG sinyalinden öznelikler elde edilirken, sinyalin yerel değişimlerine duyarlı olan yöntemlerin kullanılması, sinyallerin birbirlerinden ayırt edilmesinde kolaylık sağlayacaktır. Bu bağlamda EEG sinyallerinden öznelik elde etme yöntemlerinden biri de sinyalin yerel değişimlerine duyarlı olan bir boyutlu yerel ikili örüntü yöntemidir (1B-YİÖ). Literatürde EEG sinyalinden 1B-YİÖ yöntemi kullanılarak özneliklerin çıkarılması ile ilgili olarak yapılan çalışmalar aşağıda sıralanmıştır.

Kumar T. S. ve diğerleri (2016) çalışmalarında; bir boyutlu yerel komşu tanımlayıcı örüntü yöntemi (1B-YKÖ) ve bir boyutlu yerel düğüm örüntüsü (1B-YDÖ) kullanarak, sağlıklı ve epileptik, nöbet öncesi ve nöbet esnasındaki EEG kayıtlarını sınıflandırmışlardır. Çalışmalarında normal ve epileptik EEG sinyalleri arasındaki sınıflandırma için 1B-YKÖ ve 1B-YDÖ öznelik teknikleri kullanarak sırasıyla % 99.82 ve %99.80 sınıflandırma doğruluğunu elde etmişlerdir [3].

Kaya Y. ve diğerleri (2014) çalışmalarında; 1B-YİÖ yöntemi kullanarak epileptik EEG sinyallerinden tek düze ve tekdüze olmayan öznelikler elde etmişlerdir. BayesNet ile yaptıkları sınıflandırmada tüm 1B-YİÖ yöntemi kullanarak elde ettikleri özneliklerde sınıflandırma doğruluğunu %93.00 - 99.50 aralığında ve tek düze olmayan 1B-YİÖ özneliklerle sınıflandırma doğruluğunu ise %92.80 - 99.50 aralığında bulmuşlardır [4].

Kaya Y., Sezgin N., Tekin R. (2014), tıkaçıcı uyku apnesi sendromunun tespiti için EEG, kas aktivite (EMG) ve horlama işaretlerini analiz ederek bu işaretlerdeki öznelikleri 1B-YİÖ yöntemi kullanarak çıkarmışlardır. Bu yöntem ile %99 'ün üzerinde bir sınıflandırma performansı elde etmişlerdir [5].

Ertuğrul Ö. F. ve diğerleri (2016) çalışmalarında; Parkinson hastalığının tespit edilmesi için kullandıkları sinyalden 1B-YİÖ yöntemi ile elde ettikleri vektör kümesinin çeşitli istatistiklerini kullanarak, makine öğrenme yöntemleri ile tespit etmeye çalışmışlardır. Çalışmalarındaki en yüksek performansı %88.60 olarak bulmuşlardır [6].

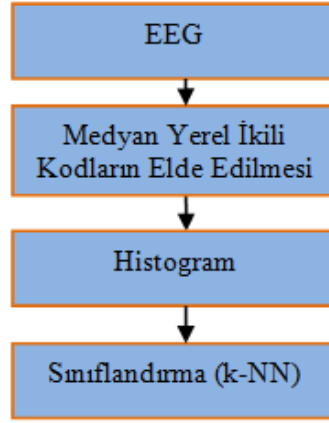
Kumar T. S. ve diğerleri (2015), nöbet esnasında ve nöbet öncesi EEG sinyallerine Gabor filtresi uygulayarak bölütlere ayırmışlardır. Elde edilen bölütlere 1B-YİÖ yöntemi uygulayarak elde edilen öznelikleri yakın komşu algoritması kullanarak % 98.33 'lük bir sınıflandırma doğruluğu elde etmişlerdir [7].

Bu çalışmada da daha önce literatürde kullanılan 1B-YİÖ yönteminden yola çıkılarak, sinyalin yerel değişimlerine daha duyarlı, uç noktaların etkisini de değerlendiren 1B-MYİÖ adı verilen yeni öznelik elde etme yöntemi geliştirilmiştir. Bu yöntem ile elde edilen öznelikler, gürültülü işaretlerin sınıflandırılmasında dahi başarılı sonuçlar ortaya koyan k-NN sınıflandırıcı ile sınıflandırılarak, literatürdeki diğer öznelik elde etme yöntemleri ile karşılaştırılmış ve EEG sinyallerine uygulanabilirliği değerlendirilmiştir.

## MATERYAL VE YÖNTEM (MATERIAL AND METHOD)

### 2.1. Önerilen Sınıflandırmaya Ait İşlem Akışı (Recommended Classification Process Flow)


Çalışmada, sağlıklı, nöbet öncesi ve nöbet esnasında kayıt edilen EEG sinyallerinden öznelik elde etmek için yeni bir yöntem olan 1B-MYİÖ yöntemi kullanılarak yerel ikili kodlar elde edilmiştir. Bu yerel ikili kodların dağılımını hesaplamak için histogram kullanılmıştır. Histogram uygulanması sonucu elde edilen öznelik vektörü k-NN ile sınıflandırılmıştır. Bu çalışmada önerilen sınıflandırmaya ait işlem akışı Şekil 1'de gösterilmiştir.



**Şekil 1.** Bu çalışmada önerilen işlem akışı (Proposed flow for this study)

## 2. VERİ SETİ (DATA SET)

Bu çalışmada kullanılan EEG verileri Bonn Üniversitesi veritabanından alınmıştır [8]. Veri seti A,B,C,D,E olmak üzere beş kümeden oluşmaktadır. A veri seti sağlıklı, gözler açık ve B veri seti sağlıklı, gözler kapalı olmak üzere, EEG kayıtları 10-20 uluslar arası elektrot konumlandırma sistemi kullanılarak alınmıştır. C veri kümesi nöbet öncesi hipokampal karşı yarım küre ve D kümesi nöbet öncesi epileptik bölgeden kayıt edilen EEG sinyalleridir. E kümesi EEG sinyali ise nöbet esnasında ve elektrotlar epileptik bölgede konumlandırılarak kayıt edilmiştir. Her bir küme 23.6 sn süreli ve tek kanallı 100 bölütden oluşmaktadır. Kullanılan EEG sinyalleri 0.53-40Hz bant geçiren filtre ile filtrelenmiştir. Filtrelenen EEG sinyallerinin örnekleme hızı 173.61 Hz 'dir. Çalışmada kullanılan EEG sinyallerinin örnek çizimleri Şekil 2 'de gösterilmiştir.



**Şekil 2.** Çalışmada kullanılan EEG veri setleri (EEG data sets used in this Study)

## 3. ÖZNETELİKLERİN ELDE EDİLMESİ (FEATURES EXTRACTION)

EEG sinyalleri doğası gereği ön görülemez işaretlerdir. Bu yapılarından dolayı EEG sinyallerinden öznetelik elde edilirken, ani değişimleri yakalamak için her bir verisinin (data point) dikkate alınması gerekmektedir. 1B-YİÖ yönteminde, sinyalin bazı değerleri eşik değeri olarak kullanıldığından hesaba katılmamaktadır. Ayrıca eşik değeri belirlenirken sinyalin bölütündeki sağ/sol komşu değerleri de dikkate alınmamaktadır. Bu dezavantajlar sinyalin ani değişimini özneteliklere yansıtımayabilir. Bundan yola

çıkarak çalışmamızda eşik değeri belirlerken, bölütün tüm değerlerini içine alan, bölütün değerlerine bağımlı, uç noktalarını ve merkeze yığılma ölçüsünü dikkate alan medyan değeri kullanılmıştır. Ayrıca veri setleri 8 'lik bölütlerle temsil edilerek, yerel değişimlere daha duyarlı bir öznelik elde etme yöntemi oluşturmak amaçlanmıştır.

#### 4.1 Medyan (Median)

Değişkene yönelik verilerin dağılımında sapma veya uç noktaların etkisinin olduğu durumlarda medyan dikkate alınır. Medyan, küçükten büyüğe doğru sıralanmış verilerin tam ortasında kalan değerdir ve merkeze yığılma ölçüsü olarak ifade edilir. EEG kayıtları da değişkenlik gösteren ve uç noktaların etkisinin olduğu verilerdir. Bundan dolayı bu çalışmada oluşturulan her bir veri bölütünün medyanı eşik değeri olarak kabul edilmiştir. Bir bölütteki veriler  $\{X_1, X_2, \dots, X_N\}$  ve bölütteki veri sayısı  $N$  olmak üzere, medyan aşağıdaki formül ile hesaplanır:

$$M = \begin{cases} \frac{X_{\frac{N}{2}} + X_{\frac{N}{2}+1}}{2} & N \text{ çift ise} \\ X_{\frac{N+1}{2}} & N \text{ tek ise} \end{cases} \quad (1)$$

#### 4.2. Bir Boyutlu Yerel İkili Örüntü (One-Dimensional Local Binary Pattern Algorithm)

Bir boyutlu yerel ikili (1B-YİÖ) yöntemi örüntü tanımada yaygın olarak kullanılan görüntü işleme yöntemidir [9]. Bu yöntem EEG sinyallerine de uygulanabilmektedir [10]. 1B-YİÖ yönteminde, bir sinyaldeki her veri örneği için, merkezi verinin değeri eşik değeri olarak kabul edilir. Bu eşik değerinin, sağ ve soldaki veri değerleriyle karşılaştırılması sonucu ikili kodlar üretilir.

EEG sinyalleri stokastik bir yapı gösterirler. Bu nedenle EEG sinyallerinden öznelik elde edilirken tüm değerlerinin dikkate alınması gerekir. 1B-YİÖ yönteminin; eşik değeri belirlenirken, veri bölütünün içindeki değerlerin dikkate alınmaması ve orta değer karşılaştırma işlemi kullanılıp, bölüt değeri dışında bırakılması gibi dezavantajları vardır.

#### 4.3. Bir Boyutlu Medyan Yerel İkili Örüntü Yöntemi (One-Dimensional Median Local Binary Pattern Method)

Çalışmamızda 1B-YİÖ yönteminden farklı olarak, sinyal bölütlerinin medyan değerini kullanan 1B-MYİÖ yöntemi kullanılmıştır. 1B-MYİÖ yönteminde, bir sinyaldeki her bölüt için, medyan değeri eşik değeri olarak kabul edilir. Bu eşik değerinin, bölütteki veri değerleriyle karşılaştırılması sonucu ikili kodlar üretilir. Bu işlemlere ait akış şeması Şekil 2 'de gösterilmiştir.

Çalışmada EEG kayıtlarından, 1B-MYİÖ yöntemi ile yerel ikili kodlar aşağıdaki gibi hesaplanmaktadır.

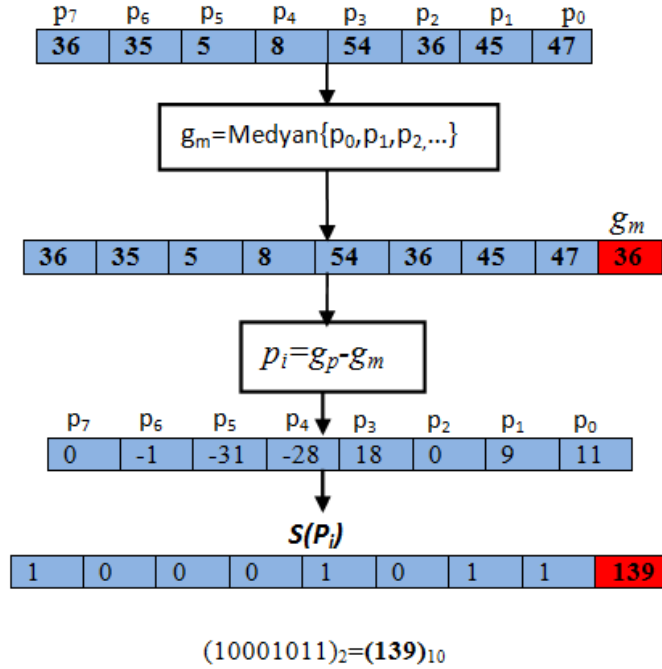
- Her sinyal, her biri 8 veri (data point) içeren bölütlere ayrıştırılır.
- Her sinyal bölütü için medyan değeri hesaplanır.
- Her bölütteki verilerin, medyan değerden farkı bulunur.
- Elde edilen fark değerleri 0 ve 0'dan büyük ise 1, değil ise 0 değeri atanır.
- Elde edilen ikili kodun onluk tabandaki karşılığı bulunur.

Medyan Yerel İkili Örüntü yöntemi formülü şu şekildedir:

$$YIÖ_p = \sum_{p=0}^{P-1} s(g_p - g_m)2^p \quad (2)$$

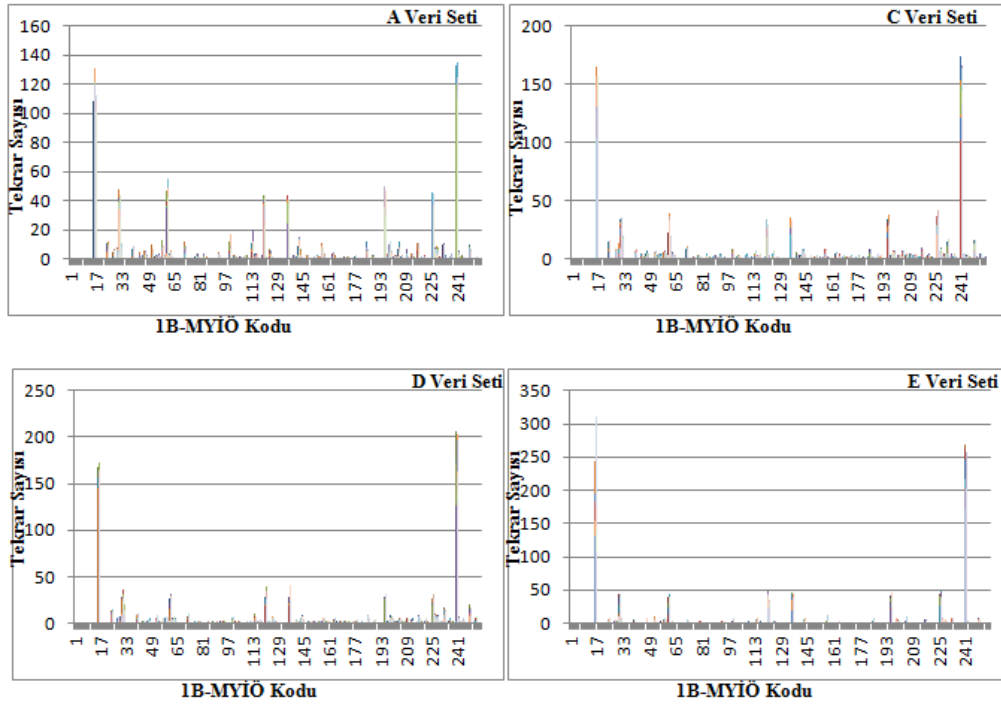
$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3)$$

Denklemden yer alan  $g_m$  terimi işaretin medyan değerini,  $g_p$  terimi bölütteki değeri ve P terimi ise bölütteki toplam veri sayısını ifade eder. Bu çalışmada 1B-MYİÖ yönteminin uygulanması için her bir EEG kanalı, her biri 8 ölçümden (data point) oluşan bölütlere ayrıştırılmıştır. Bir bölüt için örnek bir hesaplama akışı, Şekil 3 'te gösterilmiştir. Bu hesaplamada, bölütün medyan değeri belirlenir ve bölütteki değerlerden çıkarılır. Farklar, Denklem 3 'e göre ikili forma dönüştürülür. Elde edilen ikili sayıların birleşiminden elde edilen onluk sayı dikkate alınır.



Şekil 3. 1-Boyutlu medyan yerel ikili kod elde etme yöntemi (One dimensional median local binary code obtainment method)

1B-MYİÖ yöntemi ile elde edilen sinyal kodlarının uygun bir biçimde dağılımını elde etmek için histogram kullanılmaktadır. Histogram, yatay eksenin dönüşüm kodlarının aralığını ve dikey eksenin kodun frekansını içerdiği iki boyutlu uzayda yapısal dağılımı göstermektedir. Bu dağılım öznelik vektörünü temsil etmektedir. Elde edilen ikili kod 0-255 aralığında olmaktadır. Çalışmada her bir EEG veri setinden 256 adet öznelik vektörü elde edilmiştir. Elde edilen öznelik vektör grafikleri Şekil 4’te gösterilmiştir.



**Şekil 4.** Farklı EEG veri setlerine ait öznitelik vektör grafikleri (Feature vector graphics of different EEG data sets)

## 5. SINIFLANDIRICI (CLASSIFIER)

### 5.1. K En Yakın Komşu (k-NN) Algoritması (k-Nearest Neighbor algoritm)

Örüntü tanımadada, özel uzayda en yakın eğitim örneklerine dayalı nesnelere sınıflandırmak için k-NN algoritması kullanılan bir yöntemdir. Bu sınıflandırma algoritmasında; hangi sınıfa ait olduğu bilinmeyen verilerin (test örnekleri), örneği önceden sınıflandırılmış öğrenme örneklerine olan uzaklıkları hesaplanır ve en yakın olduğu düşünülen k tane veride bulunan en fazla sınıfa göre sınıflandırma yapılır [11].

Kısaca k-NN olarak ifade edilen K-En Yakın Komşu (K-Nearest Neighbor) sınıflandırma algoritmasının temelinde “birbirine yakın olan nesnelere muhtemelen aynı kategoriye aittir” mantığı yatar [12]. Bu çalışmada k değeri 3 olarak seçilmiştir.

Çalışmada kullanılan 5 farklı EEG veri setinin her biri 100 kanaldan oluşmaktadır. Her bir EEG veri seti için 256 adet öznitelik elde edilmiştir. Sınıflandırma aşamasında; elde edilen her bir veri setinin 3/4 oranı eğitim için, 1/4 oranı da test için kullanılmıştır.

## 6. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSION)

Çalışmada 5 veri seti (A,B,C,D,E) içeren EEG kayıtlarına IB-MYİÖ yöntemi uygulanarak elde edilen öznitelikler k-NN ile sınıflandırılmıştır. Sınıflandırıcıya verilen EEG kayıtlarının sınıfları Tablo 1 'de verilmiştir. Bu sınıfların k-NN ile sınıflandırma performansları da Tablo 2 'de gösterilmiştir.

**Tablo 1.** Veri setlerinin sınıflandırma sınıfları (Classification classes of data sets)

Grup	Sınıf-1	Sınıf-2	Sınıf-3
A-E	Sağlıklı(Gözler açık)	Epileptik(Nöbet)	-
A-D	Sağlıklı(Gözler açık)	Epileptik(Nöbet Öncesi)	-
D-E	Epileptik(Nöbet Öncesi)	Epileptik(Nöbet)	-
CD-E	Epileptik(Nöbet Öncesi)	Epileptik(Nöbet)	-
A-D-E	Sağlıklı(Gözler açık)	Epileptik(Nöbet Öncesi)	Epileptik(Nöbet)

Çalışmada A-E veri setleri için sınıflandırma performansı %100, A-D veri setleri için %99.00, D-E veri setleri için %98.00, CD-E veri setleri için %99.50 ve A-D-E veri setleri için de %96.00 olarak bulunmuştur.

**Tablo2.** Sınıflandırma başarısı (Classification accuracy)

Sınıf	Başarı(%)
A-E	100
A-D	99.00
D-E	98.00
CD -E	99.50
A-D-E	96.00

Literatürde A-E, A-D, D-E, CD –E ve A-D-E veri setleriyle yapılan sınıflandırma başarıları sırasıyla Tablo 3, Tablo 4, Tablo 5, Tablo 6 ve Tablo 7 'de verilmiştir.

**Tablo 3.** Literatürde A-E veri seti sınıflandırma başarısı (A-E data set classification accuracy in literature)

A-E		
Çalışma	Kullanılan Yöntem	Başarı(%)
[13]	Bulanık Yaklaşım Entropi+DVM	100
	<b>Bu çalışmada ( 1B-MYİÖ+k-NN)</b>	<b>100</b>
[14]	FFT ve Karar Ağaç Sınıflandırıcı	98.70
[15]	Dalgacık Dönüşümü, faz, öklit uzaklığı	98.17
[16]	Yapay sinir Ağları	97.50
[17]	Ayrık Dalgacık Dönüşümü ve Yaklaşım Entropi	96.00
[18]	Çapraz Korelasyon ve DVM	95.50
[19]	Dalgacık Enerjisi ve YSA	95.20
[20]	Dalgacık öznitelik çıkarma	94.50
[4]	1D-YİÖ ve Bayes Net(LBP tümü)	97.50
[21]	Ayrık Dalgacık Dönüşümü ve YSA	96.00

Bu tablolar incelendiğinde, A-E veri setlerinin, bulanık yaklaşım entropi kullanılarak elde edilen öznitelik vektörü DVM sınıflandırıcıya verilmiştir [14]. Bu veri setleri için başarı performansı %100 bulunmuştur. Bu çalışma ile karşılaştırıldığında, çalışmamızın aynı sınıflandırma başarısı gösterdiği görülmüştür. Literatürde aynı veri setleri ile yapılan diğer bir çalışma, 1 boyutlu yerel ikili örüntü yöntemi kullanarak elde ettikleri öznitelik kümesini Bayes Net ile sınıflandırılmıştır [4]. Çalışmalarında tüm 1B-YİÖ öznitelikleri kullanarak başarı performansını; A-E veri setleri için %97.50, A-D veri setleri için %99.50, D-E veri setleri için %93.00, CD-E veri setleri için %97.00 ve A-D-E veri setleri için de %95.67 bulmuşlardır. Bu çalışma ile karşılaştırıldığında çalışmamızın A-E veri setleri için %100, A-D veri setleri için %99.00, D-E veri setleri için %98.00, CD-E veri setleri için %98.00 ve A-D-E veri setleri içinde %96.00 olarak bulunmuştur. Yine aynı veri setleri ile yapılan literatürdeki diğer çalışmalara bakıldığında, çalışmamızda [3,15-28] birçok çalışmaya göre daha iyi sınıflandırma başarısı elde edilmiştir.

**Tablo 4.** Literatürde A-D veri setleri sınıflandırma başarısı (A-D data set classification accuracy in literature)

A-D		
Çalışma	Kullanılan Yöntem	Başarı(%)
[4]	1-D-LBP ve Bayes Net(LBP tümü)	99.50
	<b>Bu çalışmada ( 1B-MYİÖ+k-NN)</b>	<b>99.00</b>

**Tablo 5.** Literatürde D-E veri seti sınıflandırma başarısı (D-E data set classification accuracy in literature)

D-E		
Çalışma	Kullanılan Yöntem	Başarı(%)
[22]	DTCWT + GRNN	98.00
	<b>Bu çalışmada ( 1B-MYİÖ+k-NN)</b>	<b>98.00</b>
[23]	Ağırlıklı Permütasyon Entropisi + DVM	96.50
[13]	Bulanık Yaklaşım Entropi+DVM	95.85
[4]	1-D-YİÖ ve Bayes Net(LBP tümü)	93.00
[24]	Permütasyon Entropisi ve DVM	79.94

**Tablo 6.** Literatürde CD-E veri setleri sınıflandırma başarısı (D-E data sets classification accuracy in literature)

CD -E		
Çalışma	Kullanılan Yöntem	Başarı(%)
[3]	Gabor filtresi + 1D-LBP + YSA	98.33
	<b>Bu çalışmada ( 1B-MYİÖ+k-NN)</b>	<b>98.00</b>
[4]	1-D-YİÖ ve Bayes Net(LBP tümü)	97.00
[25]	Doğrusal Tahmin	95.33

**Tablo 7.** Literatürde A-D-E veri setleri sınıflandırma başarısı (A-D-E data sets classification accuracy in literature)

A-D-E		
Çalışma	Kullanılan Yöntem	Başarı(%)
[26]	LNDP + YSA	98.65
[27]	Ayrık Dalgacık Dönüşümü + k-mean ve YSA	96.67
	<b>Bu çalışmada ( 1B-MYİÖ+k-NN)</b>	<b>96.00</b>
[13]	Bulanık Yaklaşım Entropi+DVM	95.67
[4]	1-D-YİÖ ve Bayes Net(LBP tümü)	95.67

## 7. MODEL BAŞARIM ÖLÇÜTLERİ (MODEL SUCCESS MEASUREMENTS)

Model başarımı, doğru sınıfa atanan örnek sayısı ve yanlış sınıfa atılan örnek sayısı nicelikleriyle alakalıdır. Bu çalışmada Sınıflandırma performansı için en iyi model seçimi için 10 kat çapraz doğrulama yapılmış ve model başarımı değerlendirmesi için doğruluk, kesinlik ve duyarlılık ölçüleri hesaplanmıştır. Doğruluk, kesinlik ve duyarlılık ölçütlerinin bağıntıları Denklem 4, Denklem 5 ve Denklem 6 'da gösterilmiştir. Hesaplama için kullanılan değerler Tablo 8 'de verilmiştir.



**Tablo 8.** Karışıklık matrisi (Confusion matrix)

Gerçek Sınıf	Tahmin Edilen Sınıf	
	Sınıf=1	Sınıf=0
	TP	FP
	FN	TN

Burada TP (True Positive), FP (False Positive), FN (False Negative), ve TN (True Negatif) sonuç sayılarını ifade etmektedir. Doğruluk, kesinlik ve duyarlılık ölçütleri aşağıdaki gibi hesaplanmaktadır:

$$\text{Doğruluk} = \frac{TP+TN}{TP+FP+FN+TN} \quad (4)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (5)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (6)$$

Çalışmada, sağlıklı, nöbet öncesi ve nöbet esnasında kayıt edilen EEG sinyallerinin sınıflandırılması sonucu elde edilen model başarımları ölçümleri Tablo 9 ' da verilmiştir.

**Tablo 9.** Model başarımları ölçümleri (Model success measurements)

Sınıf	Doğruluk(%)	Kesinlik(%)	Duyarlılık(%)
A-E	99.00	98.00	100.0
A-D	98.00	97.61	99.53
D-E	96.50	96.96	97.00
CD -E	98.80	99.79	99.92
A-D-E	97.08	-	-

Literatürde Yapay Sinir Ağları (YSA) ve BayesNet kullanılarak yapılan çalışmalarda elde edilen model başarımları ölçüm sonuçları Tablo 10 'da gösterilmiştir.

**Tablo 10.** Literatürde model başarımları ölçümleri (Model success measurements in literature)

Çalışma	A-E			A-D			D-E			CD-E			A-D-E
	Doğ.	Kes.	Duy.	Doğ.	Kes.	Duy.	Doğ.	Kes.	Duy.	Doğ.	Kes.	Duy.	Doğ.
[3]YSA	99.82	99.75	99.90	99.25	99.40	99.10	98.18	99.15	97.20	98.88	99.80	97.05	98.22
Bu çalışmada (k-NN)	99.00	98.00	100	98.00	97.61	99.53	96.50	96.96	97.00	98.80	99.79	99.92	97.08
[4]BayesNet	98.00	97.00	99.00	99.50	100	99.00	95.50	95.00	96.00	97.00	98.00	95.00	95.67

Literatür çalışmalarına bakıldığında, çalışmamızın model başarımları ölçüm sonuçlarının başarılı olduğu görülmektedir.

## 8. SONUÇLAR (RESULTS)

Bu çalışmada 5 (epileptik veya sağlıklı) farklı EEG sinyaline Medyan Yerel İkili Örüntü yöntemi uygulanmıştır. Bu yöntem EEG sinyallerinin sınıflandırması için ayırt edici öznelikler çıkarmaktadır. Önerilen teknik, hesaplama açısından basit ve kolay bir uygulamadır. Çalışmada bu tekniğin sınıflandırmaya etkisi EEG veri setlerine uygulanarak değerlendirilmiştir. Önerilen yöntemle elde edilen sonuçlar literatürde yayınlanan sonuçlarla karşılaştırılmış ve önerilen yaklaşımın sonuçlarının başarılı olduğu görülmüştür.

## KAYNAKLAR (REFERENCES)

- [1] Acharya U.R. et al., Automated EEG Analysis of Epilepsy: A Review, Knowledge Based Systems, 45,147–165, 2013.
- [2] Iasemidis L.D. ,et al. Adaptive Epileptic Seizure Prediction System , IEEE Transactions on Biomedical Engineering, 50 (5), 616–627, 2003.
- [3] Kumar T. S., Kanhangad V., Pachori R. B., Classification of Seizure and Seizure-Free EEG Signals Using Local Binary Patterns , Biomedical Signal Processing and Control, 15,33–40, 2015.
- [4] Kaya Y., Uyar M. , Tekin R. , Yıldırım S., 1D-Local Binary Pattern Based Feature Extraction For Classification of Epileptic EEG Signals, Applied Mathematics and Computation 243209–219, 2014.
- [5] Kaya Y., Sezgin N., Tekin R., Tıkayıcı Uyku Apnesi Sendromunun Tespiti için Tek Boyutlu Yerel İkili Örüntü Tabanlı Yeni Bir Yaklaşım, Sinyal İşleme Uygulamaları (SİU), 2014.
- [6] Ertuğrul Ö. F., Kaya Y. , Tekin R. , Almalı M. N., Detection of Parkinson's Disease by Shifted One Dimensional Local Binary Patterns from Gait, Expert Systems With Applications 56,156–163, 2016.
- [7] Aiswal K. J, Banka H. , Local Pattern Transformation Based Feature Extraction Techniques for Classification of Epileptic EEG signals, Biomedical Signal Processing and Control 34,81–92, 2017.
- [8] <http://www.meb.unibonn.de/epileptologie/science/physik/eegdata.html>
- [9] Ahonen T., Hadid A., Pietikainen M., Face Description With Local Binary Patterns: Application To Face Recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence, 28 (12) ,2037–2041, 2006.
- [10] Chatlani N., Soraghan J.J., Local Binary Patterns for 1-D Signal Processing, in:18th European Signal Processing Conference (EUSIPCO-2010), 95–99, 2010.
- [11] Lee S., Kang P., , Cho S., Probabilistic Local Reconstruction for k-NN Regression and Its Application to Virtual Metrology in Semi Conductor Manufacturing, Neurocomputing, 131,427–439, 2014.
- [12] Eren Ö., Alerjen proteinlerin otomatik olarak sınıflandırılması, Başkent üniversitesi Fen Bilimleri Enstitüsü Y.Lisans Tezi, 2008.
- [13] Kumar Y., Dewal M., Anand R., Epileptic Seizure Detection Using Dwt Based Fuzzy Approximate Entropy And Support Vector Machine, Neurocomputing133, 271–279, 2014.
- [14] Polat K., Günes S., Classification of Epileptiform EEG Using A Hybrid System Based on Decision Tree Classifier and Fast Fourier Transform, Applied Mathematics and Computation, 187 (2),1017–1026, 2007.

- [15] Lee S.H., Lim J.S., Ki J.-K. m, Yang J., Lee Y., Classification of Normal and epileptic Seizure EEG Signals Using Wavelet Transform, Phase-Space Reconstruction and Euclidean Distance, *Computer Methods and Programs in Biomedicine*, 116 (1), 10–25, 2014.
- [16] Nigam V.P., Graupe D., A Neural-Network-Based Detection of Epilepsy, *Neurological Research*, 26 (1), 55–60, 2014.
- [17] Ocak H., Automatic Detection of Epileptic Seizures in EEG Using Discrete Wavelet Transform and Approximate Entropy, *Expert Systems Application*, 36 (2), 2027–2036, 2009.
- [18] Chandaka S., Chatterjee A., Munshi S., Cross-Correlation Aided Support Vector Machine Classifier For Classification of EEG Signals, *Expert Systems Application* 36 (2), 1329–1336, 2009.
- [19] Guo L., Rivero D., Seoane J.A., Pazos A., Classification of EEG Signals Using Relative Wavelet Energy and Artificial Neural Networks, in: *Proceedings of The First ACM/SIGEVO Summit on Genetic and Evolutionary Computation*, ACM, 177–184, 2009.
- [20] Subasi A., EEG Signal Classification Using Wavelet Feature Extraction and Mixture of Expert Model, *Expert Systems Application* 32 (4) 1084–1093, 2007.
- [21] Isik H., Sezer E., Diagnosis of Epilepsy From Electroencephalography Signals Using Multilayer Perceptron and Elman Artificial Neural Networks and Wavelet Transform, *Journal of Medical System*, 36 (1) , 1–13, 2012.
- [22] Swami P., Gandhi T.K., Panigrahi B.K., Tripathi M., Anand S., A Novel Robust Diagnostic Model to Detect Seizures in Electroencephalography, *Expert Systems Application* 56, 116–130, 2016
- [23] Tawfik N.S., Youssef S.M., Kholief M., A Hybrid Automated Detection of Epileptic Seizures in EEG Records, *Computers and Electrical Engineering*, 2015.
- [24] Nicolaou N., Georgiou J., Detection of Epileptic Electroencephalogram Based on Permutation Entropy and Support Vector Machines, *Expert Systems Application*, 39, 202–209, 2012.
- [25] Joshi V., Pachori R.B., Vijesh A., Classification of Ictal and Seizure-Free EEG Signals Using Fractional Linear Prediction, *Biomedical Signal Processing Control* 9, 1–5, 2014.
- [26] Peker M., Sen B., Delen D., A Novel Method for Automated Diagnosis of Epilepsy Using Complex-Valued Classifiers, *IEEE Journal of Biomedical and Health Informatics*, 20(1), 108–118, 2016.
- [27] Orhan U., Hekim M., Ozer M., EEG Signals Classification Using the K-Means Clustering and A Multilayer Perceptron Neural Network Model, *Expert Systems Application*, 38 (10), 13475–13481, 2011.