

## EEG sınıflandırma amaçlı bir kompozit sistem

**Muhittin BAYRAM ve Hüseyin ACAR\***

*Dicle Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, 21280, Diyarbakır*

### Özet

*Bu çalışmada, sağlıklı ve nöbet esnasındaki EEG sinyallerini ayırtan bir sistem tasarımı amaçlanmıştır. Bunun için İlinti Boyutu, Dalgacık-entropisi ve Destek Vektör Makinesi(DVM) içeren kompozit bir sistem önerilmiştir. Çalışmada kullanılan EEG verileri, Bonn Üniversitesi Epileptoloji bölümü veritabanından alınmıştır. Bu veritabanından 50 adet sağlıklı ve 50 adet epileptik olmak üzere toplam 100 adet EEG bölütü kullanılmıştır. Bu bölütlere kaotik yöntemlerin uygulanabilmesi için öncelikle faz uzayları oluşturulmuştur. Faz uzayları üzerinden İlinti Boyutu değerleri hesaplanmıştır. Dalgacık analizi ile EEG bölütleri, literatürde standart olarak belirlenen alt-bantlara; delta=(0.5-4Hz), teta=(4-8Hz), alfa=(8-12Hz) ve beta=(12-32Hz) ayrıştırılmıştır. Bu bantlarda elde edilen EEG spektral bileşenlerin normalize enerjileri alınıp Shannon entropi'leri hesaplanmıştır.*

*Sağlıklı ve epileptik EEG sinyallerinden özellik çıkarmak için ilinti boyutu analizinden elde edilen özgün veri ve dalgacık-entropi analizinden elde edilen özgün veriler (4 adet alt bant entropi'leri) DVM'nin girişine verilmek üzere her bir EEG bölütü için 5'li bir öznitelik vektörü oluşturulmuştur. Elde edilen tüm öznitelik vektörlerinin sınıflandırılması için DVM kullanılmıştır. DVM sağlıklı ve epileptik olmak üzere toplam 50 EEG bölütü ile eğitilmiş ve geriye kalan 50 bölütle de test yapılmıştır. Sağlıklı ve epileptik EEG bölütlerinin hesaplanan ilinti boyutları ve dalgacık entropilerinin sınıflandırmada ayırt edici olduğu görülmüştür. Başarım değerlendirme ölçütleri kullanılarak önerilen kompozit sistemin %98 gibi bir başarı ile sınıflandırma yapabildiği tespit edilmiştir.*

**Anahtar Kelimeler:** EEG, Epileptik ataklar, İlinti boyutu, Dalgacık entropisi, Destek Vektör Makinesi, Sınıflandırma.

\*Yazışmaların yapılacağı yazar: Hüseyin ACAR. hacar@dicle.edu.tr; Tel: (412) 248 80 30 (3538)

## A composite system for EEG classification

### Extended abstract

*Objective of this study was to design a system for classifying Epileptic and normal EEG signals. For this purpose, a system composed of correlation dimension, wavelet-entropy and Support Vector Machine was proposed.*

*Epilepsy is a neurological disorder which can be seen all over the world. It can be diagnosed by brain's electrical activity. The determination of epileptic attacks or seizures by Electroencephalogram (EEG) signals is quite common in both clinical and research fields. Because EEG signals are non-stationary signals, they must be examined with the nonlinear analysis methods.*

*For the analysis of a chaotic signal or system, first of all, a trajectory of the attractor which represents the system, and depicts all states the systems acquire in the course of time must be created on the phase space. Provided that time series is the output of a chaotic system, the trajectory created on the phase space is anticipated to display a regular structure at times, and random at the other. It cannot be estimated in advance when and how long the trajectory is regular or random. However, some methods quantifying the degree of chaoticity of the system have been developed. With these methods, calculations are made using the trajectory created on the phase space by the system and the degree of chaoticity is quantitatively determined. Each method reflects chaoticity of the systems in different ways. In other words, each quantity obtained from the system defines a different feature vector. The excessive number of feature vectors means better recognition of the system. Since that means more parameters, the processing load also increases.*

*In the Literature, the Lyapunov exponents, the correlation dimension and the entropy, are widely used for analysis of the chaotic time series or*

*systems. In addition, time-frequency techniques can be used to analyze this kind of signals and systems.*

*Support Vector Machines (SVM) is one of the methods commonly used in classification. SVM tries to find the most appropriate plane (hyperplane) separating the two classes.*

*EEG data used in this study have been acquired from the database of University of Bonn, Department of Epileptology. From this database, 100 EEG segments (50 healthy and 50 epileptic segments) have been used. To apply chaotic methods to these segments, phase spaces have primarily been created, and then the Correlation Dimension values have been measured.*

*In this study, the normal and the epileptic EEG signals were examined. First of all, the correlation dimension of both the normal and the epileptic EEG signals were measured. All of the EEG signals have been separated into the standard subbands which are:  $\delta=(0.5-4\text{Hz})$ ,  $\theta=(4-8\text{Hz})$ ,  $\alpha=(8-12\text{Hz})$  and  $\beta=(12-32\text{Hz})$ . Then, the Shannon entropies of the EEG subbands are calculated; and then the feature vectors are formed by combining the values obtained with both methods. Finally, all the feature vectors are classified with SVM.*

*SVM was trained with 50 EEG segments in total, composed of 25 healthy and 25 epileptic EEG segments, and a test was conducted with the remaining 50 segments. The measured correlation dimensions and wavelet entropies of EEG segments were detected to be distinctive in classification. The composite system that was proposed using performance evaluation criteria showed a 98 % success rate in classification.*

**Keywords:** EEG, Epileptic attacks, Correlation dimension, Wavelet entropy, Support Vector Machine, Classification.

## Giriş

Epilepsi, dünyanın her tarafında görülebilen ve beyinin elektriksel aktivitesinden teşhis edilebilen nörolojik bir hastalıktır. Epileptik atakların veya nöbetlerin Elektroensefalogram (EEG) sinyalleri ile tespiti hem klinik hem de araştırma alanında oldukça yaygındır.

EEG, durağan olmayan sinyal grubuna girdiği için durağan olmayan işaretlerin analizi için geliştirilmiş yöntemlerle incelenmesi gerekir.



Literatürde, kaotik işaret veya sistemlerin analizi için Lyapunov üsteli (Iasemidis ve Sackellares, 1991), ilinti boyutu (Ding vd., 1993) ve istatistiksel bir metot olan entropi (Quian vd., 2001) yaygın bir şekilde kullanılmıştır. Ayrıca spektral analiz metotlarından olan çapraz korelasyon metodu ve SVM kullanarak (Chandaka vd., 2009) sağlıklı ve epileptik EEG işaretlerini % 94.5 doğrulukla tespit etmişlerdir. Dalgacık dönüşümü ve SVM kullanarak (Panda vd., 2010) epileptik ataklar % 91.2 başarımla tespit edilmiştir. Yine Dalgacık ve SVM kullanarak (Kumari ve Jose, 2011) ataklar % 98.75 başarımla bulunmuştur. Dalgacık Dönüşümü, Lyapunov üsteli ve SVM kullanarak (Murugavel vd., 2011) epileptik ataklar % 96 oranında tespit edilmiştir.

Bu çalışmada, epileptik ve normal (epilepsi olmayan) EEG sinyallerinin a) Bir kaotiklik ölçme ölçütü olan ilinti boyutları (İB) hesaplanmıştır; b) Ayrık Dalgacık (AD) ile EEG için literatürde standart olarak belirlenen alt-bantlara;  $\delta=(0.5-4\text{Hz})$ ,  $\theta=(4-8\text{Hz})$ ,  $\alpha=(8-12\text{Hz})$  ve  $\beta=(12-32\text{Hz})$  ayrıştırılmıştır. Bu bantlarda elde edilen EEG spektral bileşenlerin normalize enerjileri alınıp Shannon entropi'leri hesaplanmıştır. Bu iki metot ile elde edilen özgün değerlerden her bir EEG bölütü için bir öznelik kümesi veya matrisi oluşturulmuştur. Oluşturulan tüm öznelik vektörleri Destek Vektör Makinesi (DVM) ile sınıflandırılmaya çalışılmıştır. Burada önerilen bu kompozit sistemin iyi bir başarı (%98) ile EEG sınıflandırması yaptığı görülmüştür.

## Material ve metot

### Veri setinin oluşturulması

Çalışmada kullanılan EEG verileri, Bonn Üniversitesi Epileptoloji bölümü veritabanından alınmıştır (Andrzejak vd., 2001). Veri seti beş kümeden (A, B, C, D, E) oluşmaktadır. Her bir kümede 23,6 sn süreli ve tek kanallı 100 bölüt yer almaktadır. A ve B kümeleri sırasıyla gözler açıkken ve gözler kapalıyken sağlıklı 5 denekten alınan yüzey EEG sinyallerini kapsamaktadır. C kümesi, hasta deneklerden hipokampal karşı yarımküreden nöbet öncesi alınan EEG kayıtlardır. D kümesi ise hasta deneklerden ve nöbet öncesi epileptojenik bölgeden alınan EEG kayıtlarından oluşmaktadır. E kümesi ise 5 hasta denekten epileptik nöbet esnasında alınan kayıtlardır. Deneklerden alınan EEG işaretlerine 0.53-40 Hz bant geçiren filtre uygulanarak kayıtlanmış ve 12 bit analog sayısal dönüştürücü kullanılarak 173.61Hz örnekleme frekansı ile bilgisayar ortamına aktarılmıştır.



Şekil 1: Sağlıklı ve epileptik EEG bölütleri

Çalışmada, sağlıklı (A kümesi) ve epileptik (E kümesi) EEG verileri kullanılmıştır. Şekil 1’de A ve E kümelerinden birer bölüt (A1, E1) gösterilmiştir. Buradaki genlik değeri  $\mu V$  düzeyinde olup her bir bölüt 23.6sn’dır.

Tablo 1: Sağlıklı ve epileptik EEG özellikleri

	A Kümesi	E Kümesi
Denek sayısı	5	5
Her kümedeki segment sayısı	100	100
Kullanılan segment sayısı	50	50
Segment uzunluğu	23.6 sn	23.6 sn
Kanal sayısı	Tek	Tek
Niteligi	Sağlıklı - Gözler açık	Hasta- Epileptik nöbet esnasında alınan EEG

Tablo 1’de sağlıklı ve epileptik EEG kayıtlarına ait bilgiler verilmiştir.

### Kaos analizi

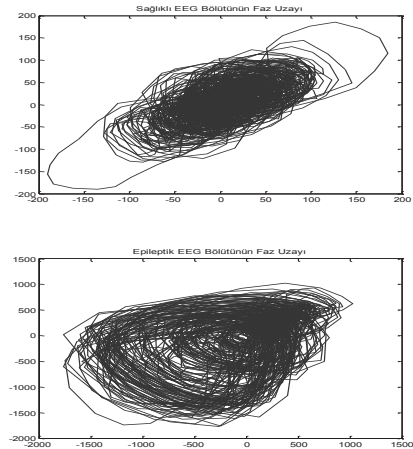
Kaotik bir işaretin veya sistemin analizi için öncelikle, sistemin zaman içinde alacağı tüm durumları gösteren, sistemi temsil eden çekicinin faz uzayında yörüngesinin oluşturulması gerekmektedir. Zaman serisinin faz uzayında oluşturulmasının nedeni daha büyük bir Öklid uzayı oluşturarak çekicinin yapısını herhangi bir belirsizlik olmadan görebilmektir. Eğer zaman serisi kaotik bir sistemin çıktısı ise, faz uzayında oluşan yörüngenin bazen düzgün bazen de gelişigüzel bir yapı sergilemesi beklenir. Yörüngenin ne kadar ve ne zaman düzgün veya gelişigüzel oluşu kestirilememektedir. Ancak sistemin kaotiklik derecesini niceleyen bir takım metotlar geliştirilmiştir. Bunlardan en bilinenleri Lyapunov üstelleri, ilinti boyutu, entropi gibi metotlardır. Bu metotlar, sistemin faz uzayında oluşturduğu yörüngenin üzerinden hesaplamalar yaparak kaotiklik derecesini kantitatif olarak belirler. Her bir metot sistemin kaotikliğini değişik şekillerde ifade etmektedir (Yılmaz ve Yıldız, 2009). Diğer bir deyişle, sistemden elde edilmiş her bir nicelik, sistem için ayrı bir öznelilik vektörü tanımlar. Öznelilik vektörlerinin sayısının fazlalığı sistemin daha iyi tanınması anlamına gelir.

### Faz uzayının yeniden oluşturulması

Kaotik dinamiklerin hesaplanması için, zaman serisinin faz uzayında yeniden oluşturulması gerekmektedir. Faz uzayında aynı zaman diliminde iki veya daha fazla fonksiyonun birbiriyle karşılaştırılması yapıldığı için, durum uzayını yapılandırmak için en az iki fonksiyon gereklidir. Takens (1981) teoremine göre yalnızca bir zaman serisi varsa, zaman serisinin bir veya daha çok türevleri kullanılarak Denklem 1’deki gibi faz uzayı gerçekleştirilebilir.

$$y(n)=[x(n)+x(n+\tau)+x(n+2\tau)+\dots x(n+(m-1)\tau)] \quad (1)$$

Denklem 1’de kullanılan  $m$  yerleştirme boyutu ve  $\tau$  ise zaman gecikmesini ifade eder. Yerleştirme boyutu  $m$ , en yakın yanlış komşuluklar metodu ile zaman gecikmesi  $\tau$  ise karşılıklı bilgi fonksiyonun ilk yerel minimumundan hesaplanır (Yılmaz ve Yıldız, 2007). İşareti faz uzayına yerleştirmek için seçilecek  $\tau$  değeri, veri kümesindeki noktalar ne birbirinden ayırt edilemeyecek kadar küçük, ne de istatistiksel anlamda birbirinden tamamen bağımsız olacak şekilde büyük seçilmelidir (Yılmaz ve Yıldız, 2007). Zaman gecikmesi  $\tau$  değeri küçük olduğu zaman çeker lineerleşerek, büyük olduğu zaman da faz uzayında dağılarak özelliğini kaybeder. Bu çalışmada  $\tau =3$  (17ms) ve  $m=5$  olarak alınmıştır.



Şekil 2: Sağlıklı ve epileptik bölütlerin faz uzayları

Çalışmada kullanılan sağlıklı ve epileptik EEG verilerinin (A1, E1) faz uzayında gösterdikleri yapıyı belirtmek için örnek olarak, biri sağlıklı biri de epileptik olmak üzere, iki durum Şekil 2’de gösterilmiştir. Yatay ve dikey eksenler  $\mu V$  düzeyindeki genlik değerleridir.

### İlinti boyutu

Kaotik yapının bir göstergesi olan garip (kaotik) çekerlerin kaotiklik derecesini, bunlara ait fraktal boyutlar verir. İlinti boyutu, bu fraktal boyutlardan biridir ve sistemi yöneten değişkenlerin minimum sayısı ile ilişkilidir. Diğer bir açıdan, ilini boyutu sistemin serbestlik derecesini belirleyen bir ölçüttür (Yılmaz ve Yıldız, 2009).

Grasberger ve Procaccia (1983) algoritması, ilinti boyutunun hesaplanması için yaygın bir şekilde kullanılmaktadır. İlinti boyutunun hesaplanması için öncelikle Denklem 2’de verilen ilinti integrali ( $C(r)$ )’nin hesaplanması gerekir.

$$C(r) = \lim_{N \rightarrow \infty} \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N \Theta(r - |x_i - x_j|) \quad (2)$$

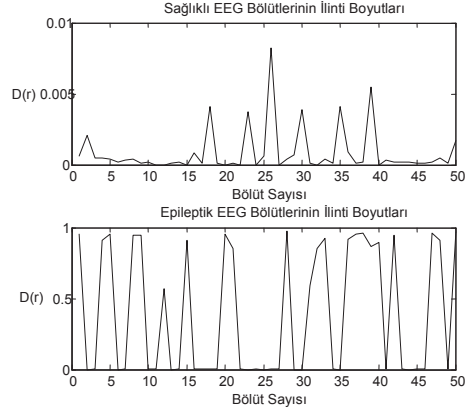
Bu algoritmaya göre; bir kümenin iki noktasının ( $x_i$ ,  $x_j$  ve  $i \neq j$ ) aynı  $r$  yarıçaplı hücrede olma olasılığı, iki noktanın  $r$ 'ye eşit veya  $r$ 'den küçük bir uzaklıkla ayrılmış olma olasılığına yaklaşık olarak eşittir (Yılmaz ve Yıldız, 2009). Bu denklemdeki  $|x_i - x_j|$  ise bu noktalar arasındaki Öklid uzaklığını göstermektedir.

Denklem 2’de  $r$ 'nin değer aralıkları ( $|x_i - x_j| \leq r$ ) için  $C(r)$  bulunarak ilinti boyutu, Denklem 3’te verildiği gibi hesaplanır. İlinti boyutu,  $\log(C(r))$ 'nin  $\log(r)$ 'ye göre çizilen eğrinin doğrusal parçasının eğimi olarak hesaplanır.

$$D = \lim_{r \rightarrow 0} \left( \frac{\log C(r)}{\log(r)} \right) \quad (3)$$

Çalışmada kullanılan sağlıklı ve epileptik EEG sinyallerinin ilinti boyutları ayrı ayrı hesaplanmıştır. Epileptik atak esnasında ilinti boyutunun arttığı görülmüştür. Bu da nöbet esnasında, değişkenlerin artmasına işaret eder.

Şekil 3’de sağlıklı ve epileptik EEG verilerinin hesaplanan ilinti boyutlarının grafikleri gösterilmiştir.




Şekil 3: Sağlıklı ve epileptik bölümlerin ilinti boyutları

### Dalgacık entropi

Dalgacık entropi, dalgacık (wavelet) ve entropi terimlerinin birleşiminden oluşan bir kavramdır. Dalgacık entropi analizinde, sinyalin zaman-frekans içeriğinin düzensizliği belirlenir.

Dalgacık analizi, durağan olmayan sinyallerin özellik çıkarılmasında büyük bir öneme sahip olup, sinyalin tümleşik zaman-frekans bilgisini veren bir metottur. Sinyali belli alt spektral bantlara ayırıp ve bu bantlara odaklanmak için AD analizi tercih edilir. Şekil 4’te şematik olarak gösterildiği gibi, sinyal bir alçak bir de yüksek geçiren filtreden tekrarlı olarak geçirilir. Alçak geçiren filtreden süzülen alt bantlar “yaklaşık katsayıları”, yüksek geçiren filtreden süzülen alt bantlar ise “ayrıntı katsayılarını” oluşturur.

Şekil 4’te verilen AD, EEG alt bantlarına yönelik özel tasarlanmıştır. Sağlıklı ve epileptik EEG sinyallerinin yaklaşık katsayıları (cA) ve ayrıntı katsayıları (cD) şeklinde ifade edilmiştir.



Şekil 4: EEG bölütlerinin yaklaşık ve detay katsayılarının AD şeması

AD ile her EEG bölütüne ait yaklaşık ve detay katsayıları hesaplandıktan sonra her banttaki enerji hesaplanır ve Denklem 4'te verildiği gibi normalize edilir.

$$P_j = \frac{E_j}{E_{top}} \quad (4)$$

Burada  $j=1, 2, 3$  ve  $4$  olmak üzere bölütün alt bantlarını,  $P_j$  normalize enerjiyi,  $E_j$  alt bant enerjisini ( $cD_1, cD_2, cD_3, cA_3$ ) ve  $E_{top}$  bölütün toplam enerjisini ifade eder. Bu normalize alt bant enerjileri, EEG'yi üreten sistem için değişik durumlarda bulunma dağılımları niteliğinde olduğu düşünülebilir. Bu dağılımların karşılaştırılması, Denklem 5'teki Shannon entropi ile hesaplanır (Yordanova, 2002).

$$S = -\sum_j P_j \ln P_j \quad (5)$$

Burada elde edilen entropi değeri, sistemin düzensizliğinin ölçüsüdür. Bu ölçütün sistem hakkında genel bir bilgi sunduğu düşünülmektedir. Bu bilgi sistemin başka açıdan, bir öznitelik vektörünü tanımlamaktadır.

Çalışmada kullanılan sağlıklı ve epileptik verilerin dalgacık entropi değerleri hesaplanmış, sağlıklı ve epileptik bölütlerin ayırt edilmesinde bu metodun başarılı olduğu görülmüştür.


### Destek vektör makineleri

Destek Vektör Makineleri, sınıflandırmada yaygın olarak kullanılan yöntemlerden birisidir. DVM öznitelik uzayında iki sınıfı ayıran en uygun düzlemi (hiperdüzlem) bulmaya çalışır. DVM risk minimizasyonu yaparak hatayı en düşük değerine çeker (Vapnik, 1999).

En yaygın DVM, lineer olarak birbirinden ayrılan iki sınıfın doğrusal modeldir. Bu çalışmada doğrusal DVM kullanılmış ve denklem 6'daki gibi formüle edilmiştir.

$$w \cdot x + b = f(x) \quad (6)$$

Burada  $w$ ; ağırlıklandırmayı,  $x$ ; girişleri ve  $b$  ise sapmayı göstermektedir. Denklem fonksiyonu  $f(x)=0$  hiperdüzlemi,  $f(x)=+1$  epileptik EEG sınıfını ve  $f(x)=-1$  ise sağlıklı sınıfı temsil etmektedir. Şekil 5'te sağlıklı ve epileptik EEG verilerinin DVM ile öznitelik uzayında sınıflandırılmaları görülmektedir. Daire (O) epileptik sınıfı, kare (□) ise sağlıklı sınıfı temsil etmektedir. Dolgulu daire ve kareler ise destek vektörlerini göstermektedir.



Şekil 5: DVM ile iki kümeyi öznitelik uzayında ayırma

### Başarım değerlendirme ölçütleri

Sistemin performansını değerlendirmek için Denklem 7-11'de verilen başarımlar değerlendirme ölçütleri kullanılmıştır.

$$\text{Duyarlılık} = \frac{GP}{GP + YN} \quad (7)$$

$$\text{Özgüllük} = \frac{GN}{GN + YP} \quad (8)$$

$$PKD=GP/(GP+YP) \quad (9)$$

$$NKD=GN/(GN+YN) \quad (10)$$

$$\text{Doğruluk}=(GP+GN)/(GP+GN+YP+YN) \quad (11)$$

Burada GP (Gerçek Pozitif), YP (Yanlış Pozitif), GN (Gerçek Negatif) ve YN (Yanlış Negatif) olarak kodlanmıştır.

Bu başarımlar değerlendirme ölçütleri; “Duyarlılık (sensitivity)”, “Özgüllük (specificity)”, “Pozitif Sonucun Kestirim Değeri (PKD)”, “Negatif Değerin Kestirim Değeri (NKD)” ve “Doğruluk” olarak bilinir (Subaşı, 2004). Bu ölçütler her bir EEG bölütü için hesaplanmıştır.

Duyarlılık, sınıflayıcının gerçek epileptikler içinden epileptikleri ayırma yeteneğini; Özgüllük, sınıflayıcının gerçek sağlıklılar içinden sağlıklıları ayırma yeteneğini; PKD, sınıflayıcı epileptik sonuç verdiğinde, gerçekten epileptik olma olasılığını; NKD, sınıflayıcı sağlıklı sonuç verdiğinde, gerçekten sağlıklı olma olasılığını; Doğruluk, ise doğru olarak sınıflanmış örneklerin tüm örnek uzayına oranını tespit etmek için kullanılmıştır.

### Bulgular ve tartışma

Bu çalışmada, 5 sağlıklı denekten 50 bölüt ve 5 hasta denekten 50 epileptik bölüt olmak üzere toplam 100 adet EEG bölütü kullanılmıştır. Sağlıklı ve epileptik EEG sinyallerinden (bölütlerinden) özellik çıkarmak için ilinti boyutu analizinden elde edilen özgün veri ve dalgacık-entropi analizinden elde edilen özgün veriler (4 adet alt bant entropi’leri) DVM’nin girişine verilmek üzere her bir EEG bölütü için bir öznelik vektörü oluşturulmuştur.

Öznelik vektörlerinden bir tanesi, örnek olarak Tablo 2’de verilmiştir. Elde edilen tüm öznelik vektörlerin sınıflandırılması için DVM kullanılmıştır. DVM sağlıklı ve epileptik EEG den oluşan toplam 50 EEG bölütü ile eğitilmiş ve geriye kalan 50 bölütü de test yapılmıştır.

### Sonuç

Sonuç olarak, bu çalışmada EEG işaretlerinin kaotiklik derecelerine göre epileptik veya

işlem sonucunda % 98 gibi bir başarımlar oranı elde edilmiştir.

Tablo 2: Sağlıklı ve epileptik EEG’nin öznelik vektörleri

Öznelik Değerleri	Sağlıklı EEG	Epileptik EEG
Delta	-0,4627	-8,706
Teta	-0,0419	-0,848
Alfa	-0,0082	-0,1725
Beta	-0,0033	-0,0567
İB	0,0110	0,0237

DVM çıkışında elde edilen verileri ve sistemin başarımlarını daha detaylı incelemek ve değerlendirmek için Denklem 7-11 başarımlar değerlendirme ölçütleri kullanılmıştır. Bu ölçümler sonucunda elde edilen değerler Tablo 3’te verilmiştir. Tablo 3’te sağlıklı EEG verileri (-1), epileptik EEG verileri ise (+1) olarak etiketlenmiştir.

Tablo 3: Hata Matrisi

		Öngörülen	
		Epileptik(+1)	Sağlıklı(-1)
Gerçek	Epileptik (+1)	GP (24)	YN (1)
	Sağlıklı (-1)	YP (0)	GN (25)

Bu başarımlar değerlendirme ölçütlerine göre elde edilen nihai sonuçlar Tablo 4’te gösterilmiştir.

Tablo 4: Başarımlar değerlendirme ölçütleri

Başarımlar %	Duyarlılık	Özgüllük	PKD	NKD	Doğruluk
		96	100	100	96.15

sağlıklı olarak ayırtılmaya yönelik bir metot önerilmiştir. Bu metot ile sınıflandırma

işleminde dikkate değer bir başarı sağlandığı görülmüştür.

## Kaynaklar

- Andrzejak, R.G., Lehnertz, K., Mormann, F., Rieke, C., David, P. and 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**, pp (061907)1-8.
- Chandaka, S., Chatterjee, A., Munshi, S., (2009). Cross-correlation aided support vector machine classifier for classification of EEG signals, *Expert systems with applications*, v.36, issue.2 part1, 1329-1336.
- Ding, M. and Grebogi, C. and Ott, E. and Sauer, T. and Yorke, J. A., (1993). Estimating Correlation Dimension from a Chaotic Time Series: when does a Plateau Onset Occur?, *Physica D*, **69**, 404 – 424.
- Grassberger, P., Procaccia, I., (1983). Measuring The Strangeness of strange attractors, *Physica D*, **9**, 189-208.
- Iasemidis, LD., Sackellares, JC., (1991). The evolution with time of spatial distribution of the largest Lyapunov exponent on the human epileptic cortex, In: Duke D., Pritchards W., editors, *Measuring Chaos in Human Brain*. Singapore: World Scientific, 49–82.
- Murugavel, A.S.M., Ramakrishnan, S. Balasamy, K., Gopalakrishnan, T., (2011). Lyapunov features based EEG signal classification by multi-class SVM, 2011 World Congress on Information and Communication Technologies (WICT),197-201.
- Quiñero Quiroga R., Rosso, O.A., Başar, E., Schürmann, M., (2001). Wavelet-entropy in event-related potentials: A new method shows ordering of EEG-oscillations. *Biological Cybernetics*, **84**, 291-299.
- Panda, R., Khobragade, P.S., Jambhule, P.D., Jengthe, S.N., Pal, P.R., Gandhi, J.K., (2010). Classification of EEG signal using wavelet transform and SVM for epileptic seizure detection, Proceedings of 2010 International Conference on Systems in Medicine and Biology, 405-408.
- Kumari, S.S.R., Jose, P. J., (2011). Seizure detection in EEG using time frequency analysis and SVM, 2011 International Conference on Emerging Trends in Electrical and Computer Technology (ICETECT), 626-630.
- Subaşı, A., (2004). Automatic recognition of alertness level from EEG by using neural network and wavelet coefficients, *Expert Systems with Applications*, 1-11.
- Takens, F., (1981). Detecting Strange Attractors in Turbulence, *Lecture Notes in Mathematics*, **898**,366-381.
- Vapnik, V. N., (1999). *The Nature of Statistical Learning Theory*, Springer-Verlag, New York.
- Yılmaz, D., Yıldız, M., (2007). Kalp Hızı Değişkenliği Üzerindeki Cep Telefonu Etkisinin Lyapunov Üsteli Hesabı ile değerlendirilmesi, *IEEE 15. Sinyal İşleme ve Uygulamalar Kurultayı (SIU)*, Eskişehir.
- Yılmaz, D., Yıldız, M., (2009). Cep Telefonlarının Kalp Atım Hızı Değişkenliğine Etkisinin İlini Boyutu Hesabı ile Analizi, *14. Biyomedikal Mühendisliği Ulusal Toplantısı (BİYOMUT)*, 20-24, İzmir.
- Yordanova, J., Kolev, V., Rosso, O.A., Schürmann, M., Sakowitz, O.W., Özgören, M. and Başar, E., (2002). Wavelet entropy analysis of event-related potentials indicates modality-independent theta dominance, *Journal of Neuroscience Methods*, **117**, 99-109.