



## DALGACIK DÖNÜŞÜMÜ KULLANILARAK EEG İŞARETLERİNDE EPİLEPTİK NÖBET TESPİTİ DETECTION OF EPILEPTIC SEIZURES IN EEG SIGNALS VIA APPLYING WAVELET TRANSFORM

Mehmet NERGİZ<sup>1</sup>, Mehmet Sıraç ÖZERDEM<sup>2</sup>, Mehmet AKIN<sup>2</sup>

<sup>1</sup> Bilgisayar Mühendisliği Bölümü  
Dicle Üniversitesi  
mnergiz@dicle.edu.tr

<sup>2</sup> Elektrik Elektronik Mühendisliği Bölümü  
Dicle Üniversitesi  
{sozerdem, makin}@dicle.edu.tr

### Özetçe

Beynin elektriksel aktivitesi ile ilgili elektroansefalografi (EEG) kayıtları nörolojik hastalıkların tanısında kullanılan en kullanışlı araçlardan biridir. Nörolojik hastalıkların en bilinenlerinden biri olan epilepsi, yaklaşık olarak dünya nüfusunun %1'ini etkileyen bir hastalıktır. Bu çalışmada hem gözü açık hem de gözü kapalı sağlıklı bireylerin EEG işaretleri ile epilepsi nöbeti geçiren bireylerin EEG işaretleri sınıflandırılmaya çalışılmıştır.

Bu çalışmada kullanılan EEG verileri, Bonn Üniversitesi Epileptoloji bölümü veri tabanındaki A, B ve E işaret gruplarından alınmıştır. A ve B işaret grupları sırasıyla gözler açıkken ve gözler kapalıyken sağlıklı deneklerden alınan yüzer adet yüzey EEG işaretini kapsamaktadır. E işaret grubu ise hasta deneklerden epileptik nöbet esnasında alınan yüz adet bölümlenmiştir.

Öznitelik olarak işaretlerin 4. seviyedeki yaklaşım alt bandının varyansı çıkarılmıştır. A ve E işaret grupları, çıkarılan öznitelikler kullanılarak çapraz-sağlama ile toplamda 10 kere sınıflandırılmaya tabi tutulmuştur. Destek Vektör Makinasının kullanıldığı sınıflandırma işlemi % 98,5'lik bir doğruluk elde edilmiştir. Aynı işlem B ve E işaret grupları çapraz-sağlama ile toplamda 10 kere sınıflandırılmaya tabi tutulmuş olup, % 97,5'lik bir doğruluk elde edilmiştir. Elde edilen performans sonuçları umut vericidir.

### Abstract

Electroencephalographic (EEG) records which are related to the electrical activity of the brain are one of the most useful tools which are used in diagnosis of neurologic diseases. Epilepsy as one of the most known neurologic diseases is a disease which effects 1% of the world. In this study, it has been tried to classify the EEG signals of the sick individuals

during epileptic seizures and the EEG signals of the healthy individuals with both closed as well as open eyes .

The EEG data used in this study has been acquired from A, B and E signal groups of the database of Epileptology Department of Bonn University. A and B signal groups are composed of one hundred EEG signals for each group of the subjects with open eyes and closed eyes respectively. E signal group is composed of one hundred signal segments which have been taken during epileptic seizures from sick individuals.

The variance of the 4th level approximation subband of the signals has been extracted as signal feature. A and E signal groups have been classified 10 times by cross validation using the extracted feature. The accuracy of the classification which is applied using Support Vector Machine (SVM) has been acquired as 98,5 %. In the same way, B and E signal groups have been classified 10 times by cross validation using the extracted feature and the accuracy has been acquired as 97,5 %. The obtained performance is promising.

### 1. Giriş

Elektroansefalogram (EEG) işaretleri beyin elektriksel aktivitesini yansıtır. Magnetoensefalografi (MEG) ve fonksiyonel manyetik rezonans görüntüleme (fMRI) gibi yaklaşımlarına nazaran EEG beyin aktivitelerini takip etmek için daha güvenli ve az maliyetlidir [7]. Beynin elektriksel aktivitesi ile ilgili elektroansefalografi kayıtları kullanılarak yapılan çalışmalar nörolojik hastalıkların tanısında kullanılan en önemli araçlardan biridir [1-3]. Bu hastalıkların en bilinenlerinden biri olan epilepsi dünya nüfusunun yaklaşık olarak %1'inin sahip olduğu bir nörolojik bozukluktur [6].

Geleneksel analiz temel olarak hekimin görsel muayenesi ile spektral güç değişikliklerinin tespitine dayanır. Farklı frekans bantları incelenir ve bu bantlara karşılık gelen spektral güç miktarları hesaplanır. Bu spektral güç miktarlarındaki

## Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uygulamaları

2. Gün 26 Eylül 2014 Cuma (14.45-16.15)

değişiklikler merkezi sinir sistemine ait işlevler ve işlev bozuklukları ile ilgilidir [4,5].

Epilepsi için değişik yaklaşımlarda otomatik tanı sistemleri geliştirilmiştir [8]. 1982'de Gotman çeşitli epilepsi nöbetlerini tespit edebilen bir bilgisayarlı sistem geliştirdi [9]. 1991'de Murro ve diğerleri, intrakranyal elektrotlar ile kaydedilmiş EEG işaretlerinin diskriminant analizini temel alan bir otomatik epilepsi nöbeti tespit sistemi geliştirdi [10]. 1997'de Qu ve Gotman, epilepsi nöbetlerinin başlangıç anının tespiti amacıyla EEG işaretlerinin hem zaman hem de frekans alanından elde edilen özelliklerinin en yakın komşu sınıflandırıcısı ile sınıflandırılmasını önerdi [11].

Birkaç araştırmacı tarafından yapay sinir ağı (YSA) tabanlı epileptik tanı sistemleri önerilmiştir [8]. Weng ve Khorasani, Gotman tarafından EEG işaretlerinden çıkartılan genlik, ortalama süre, değişim katsayıları, baskın frekans ve ortalama güç gibi öznitelikleri YSA ile sınıflandırmışlardır [12]. Pradhan ve diğerleri tarafından geliştirilen yöntem ile ham EEG işaretini Öğrenmeli Vektör Kuantalama (Learning Vector Quantization, LVQ) ağına uygulamışlardır [13]. Vivek Prakash Nigam ve diğerleri epilepsi tespiti amacıyla LAMSTAR ağı isimli yeni bir YSA'ya çıkıntı büyüklüğü ve çıkıntı ritmikliği olmak üzere EEG'de zaman alanından elde edilen iki adet özelliği uygulamışlardır [14].

Bu çalışmada ise hem gözü açık hem de gözü kapalı bireylerin sağlıklı EEG işaretleri ile epilepsi nöbeti geçiren bireylerin EEG işaretleri sınıflandırılmaya çalışılmıştır. Özellik çıkarma yöntemi olarak dalgacık dönüşümü, sınıflandırıcı olarak ise Destek Vektör Makinası ( DVM ) kullanılarak umut verici sonuçlar elde edilmiştir.

## 2. Materyal ve Metot

### 2.1. Materyal

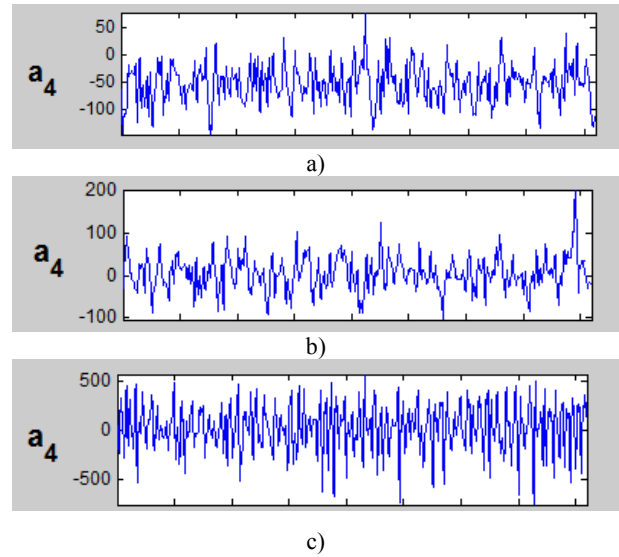
Bu çalışmada kullanılan EEG verileri, Bonn Üniversitesi Epileptoloji bölümü veri tabanından alınmıştır. Temel olarak veri seti beş işaret grubundan (A, B, C, D, E) oluşmaktadır. Her bir işaret grubunda 23,6 sn süreli ve tek kanallı olmak üzere 100 bölüt yer almaktadır. A ve B işaret grupları sırasıyla gözler açıkken ve gözler kapalıyken sağlıklı deneklerden alınan yüzey EEG işaretlerini kapsamaktadır. C işaret grubu, hasta deneklerden hipokampal karşı yarımküreden nöbet öncesi alınan EEG kayıtlarıdır. D işaret grubu ise hasta deneklerden ve nöbet öncesi epileptojenik bölgeden alınan EEG kayıtlarından oluşmaktadır. E işaret grubu ise hasta deneklerden epileptik nöbet esnasında alınan bölütlerden oluşmaktadır. EEG işaretleri 12 bit analog sayısal dönüştürücü kullanılarak 173,61 örnekleme frekansı ile bilgisayar ortamına aktarılmıştır. Deneklerden alınan EEG işaretlerine 0.53-40 Hz bant geçiren filtre uygulanmıştır [15].

### 2.2. Metot

Bu çalışmada uygulanan yöntem temel olarak iki aşamadan oluşmaktadır. Birinci aşamada dalgacık dönüşümü kullanılarak öznitelik çıkarma işlemi uygulanmaktadır. İkinci aşamada ise DVM kullanılarak sınıflandırma işlemi uygulanmaktadır.

### 2.2.1. Öznitelik Çıkarma

A, B ve E grubundaki işaretler öncelikle görsel olarak dalgacık dönüşümü toolbox'ı kullanılarak incelenerek işaretlerin alt bantlarında ayırt edici özellikler bulunmaya çalışılmıştır. Daubechies2 ana dalgacık fonksiyonu kullanılarak yapılan görsel analizler sırasında Şekil 1'de de gözlenebileceği gibi işaretlerin 4. seviyedeki yaklaşım katsayılarının sıklığının sağlıklı ve epileptik işaretler arasında çok fazla değişiklik gösterdiği fark edilmiştir.



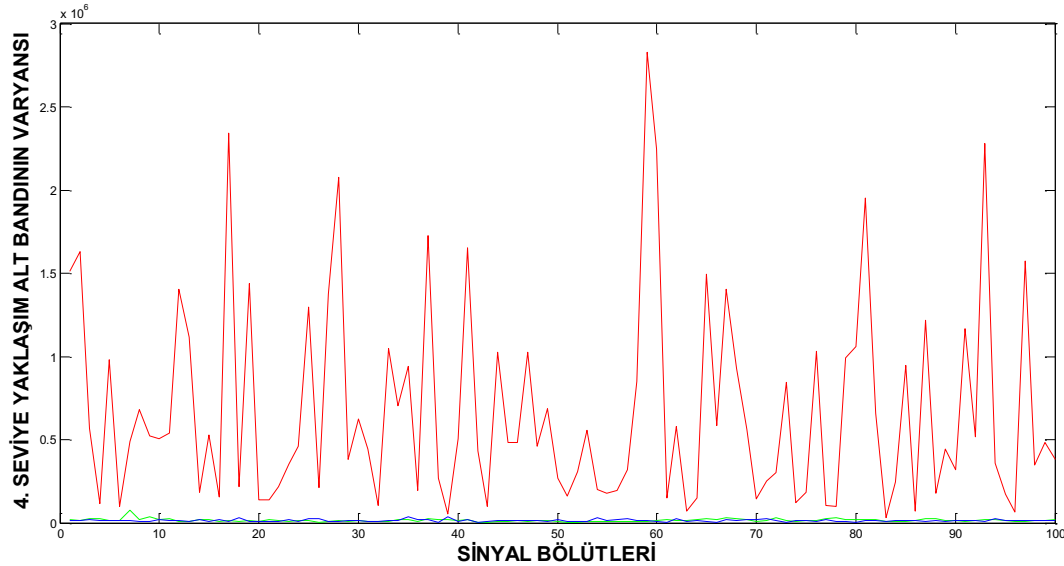
Şekil 1: 4. Seviyedeki yaklaşım alt bantları. a) A işaret grubundan bir örnek b) B işaret grubundan bir örnek c) E işaret grubundan bir örnek

A grubu işaretlerin 4. seviye yaklaşım alt bantının varyansı 3408 ile 35454 arasında, B grubu işaretlerin 4. seviye yaklaşım alt bantının varyansı 3030 ile 74291 arasında değişmekte iken E grubu işaretlerin 4. seviye yaklaşım alt bantının varyansı 32809 ile 2830180 arasında değerler almaktadır. Şekil 2'de A, B ve E işaret gruplarının 4. seviye yaklaşım alt bantlarının varyans dağılımları gösterilmektedir. A, B ve E işaret gruplarının 4. seviye yaklaşım alt bant sıklığında gözlenen bu farklılık bu çalışmada çıkarılan tek özniteliktir.

Sınıflandırma işleminden önce çıkarılan öznitelik değerleri 3000'e bölünerek normalizasyon işlemi uygulanmıştır. Bu tür bir sadeleştirme ile amaçlanan daha iyi bir sınıflandırma performansı yakalamaktır. 3000 rakamı deneysel olarak çok iyi bir sınıflandırma sonucu veren bir değer olmasının yanı sıra A, B ve E grubu işaretlerinin 4. seviye yaklaşım varyans değerlerinden en küçüğü olan 3030'a çok yakın yuvarlak bir rakam olması açısından da tercih edilmiştir. Söz konusu sadeleştirmeden sonra A grubu işaretlerin 4. seviye yaklaşım alt bantının varyansı 1 ile 11 arasında, B grubu işaretlerin 4. seviye yaklaşım alt bantının varyansı 1 ile 24 arasında, E grubu işaretlerin 4. seviye yaklaşım alt bantının varyansı 10 ile 943 arasında değerler almıştır

**Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uygulamaları**

2. Gün 26 Eylül 2014 Cuma (14.45-16.15)



Şekil 2: 4. Seviyedeki yaklaşım alt bantlarının varyans dağılımları. ( A sinyal grubundan mavi renk ile, B sinyal grubu yeşil renk ile, E sinyal grubu kırmızı renk ile gösterilmiştir )

**2.2.2. Sınıflandırma**

Bu çalışmada sınıflandırıcı olarak DVM kullanılmıştır. Literatürde en çok kullanılan DVM'lerden biri olduğu için libsvm tercih edilmiştir [16,17].

Bu çalışmada, aynı öznelik çıkarım ve sınıflandırma yöntemi kullanılarak, A ve E işaretleri ile B ve E işaretleri arasında olmak üzere iki çeşit sınıflandırma yapılmıştır. A, B ve E işaretlerinin her biri için çıkartılan 100x1 boyutlarında öznelik vektörleri sınıflandırmaya çapraz-sağlama kullanılarak tabii tutulmuştur. A ve E işaretlerinden elde edilen toplam 200x1 boyutundaki öznelik vektörünün her seferinde 180x1 boyutluk kısmı eğitim, 20x1 boyutluk kısmı test için kullanılmak üzere çapraz-sağlama ile toplamda 10 kere sınıflandırılmaya tabii tutulmuştur. A ve E işaretleri arasındaki sınıflandırma sonuçları Tablo 1'de, bu sınıflandırmaya ait istatistik değeri Tablo 2'de gösterilmektedir. Aynı işlem B ve E işaretleri için de uygulanmıştır. B ve E işaretleri arasındaki sınıflandırma sonuçları Tablo 3'de, bu sınıflandırmaya ait istatistik değeri Tablo 4'de gösterilmektedir. İstatistik ölçütlerinde yer alan parametrelerin hesaplamaları, [18] referansında yer almaktadır.

Tablo 1: A ve E işaretlerinin sınıflandırması

	Tahmin Edilen A	Tahmin Edilen E
Gerçek A	98	1
Gerçek E	2	99

Tablo 2: A ve E işaretlerinin sınıflandırma sonuç istatistikleri

İstatistik Ölçütü	İstatistik Değeri
Duyarlılık	0,9890
Belirleyicilik	0,9802
Hassasiyet	0,9800
Pozitif Tahmini Değer	0,9800
Negatif Tahmini Değer	0,9900
Doğruluk	0,9850

Tablo 3: B ve E işaretlerinin sınıflandırması

	Tahmin Edilen B	Tahmin Edilen E
Gerçek B	96	1
Gerçek E	4	99

Tablo 4: B ve E işaretlerinin sınıflandırma sonuç istatistikleri

İstatistik Ölçütü	İstatistik Değeri
Duyarlılık	0,9897
Belirleyicilik	0,9612
Hassasiyet	0,9600
Pozitif Tahmini Değer	0,9600
Negatif Tahmini Değer	0,9900
Doğruluk	0,9750

libsvm sınıflandırıcısının varsayılan parametre değerleri kullanılmıştır. libsvm'nin varsayılan parametre değerleri Tablo 5'teki gibidir.



### Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uygulamaları

2. Gün 26 Eylül 2014 Cuma (14.45-16.15)

Tablo 5: libsvm'nin varsayılan parametreleri

Parametre İsmi	Parametre Değeri
DVM tipi	C-SVC
Kernel fonksiyon tipi	radial basis
Kernel fonksiyon derecesi	3
Kernel fonksiyon gama	1
Kernel fonksiyon coef0	0
C	1
Cache memory büyüklüğü	100 MB
Termination criteria tolerance	0.001
Shrinking Heuristics	1

### 3. Sonuçlar

Bu çalışmada Bonn Üniversitesi Epileptoloji bölümü veri tabanından alınmış olan ve her biri 100 bölütle oluşan A, B ve E EEG işaret grupları sınıflandırılmaya çalışılmıştır. A ve B işaret grupları sırasıyla gözler açıkken ve gözler kapalıyken sağlıklı deneklerden alınan yüzey EEG işaretlerini kapsamaktadır. E işaret grubu ise hasta deneklerden epileptik nöbet esnasında alınan bölütlelerden oluşmaktadır. Öznitelik çıkarma aşamasında dalgacık dönüşümü kullanılarak işaretlerin 4. seviye yaklaşım varyans değerleri elde edilmiştir. Sınıflandırıcı olarak literatürde popüler bir DVM olan libsvm kullanılmıştır. Öncelikle A ve E işaret grupları çapraz-sağlama ile toplamda 10 kere sınıflandırılmaya tabi tutularak % 98,5'lük bir doğruluk elde edilmiştir. Daha sonra B ve E işaret grupları ise çapraz-sağlama ile toplamda 10 kere sınıflandırılmaya tabi tutularak % 97,5'lük bir doğruluk elde edilmiştir. Çalışmanın elde ettiği performans sonuçları dalgacık dönüşümü yardımıyla tespit edilen bir alt bandın epileptik nöbet anına dair belirgin bir karakteristiği taşıdığını tespit etmesi açısından umut vericidir.

### 4. Kaynakça

- [1] Übeyli, E.D., "Statistics over features: EEG signals analysis", *Computers in Biology and Medicine*, 39., 733 - 741, 2009.
- [2] A.M.Lindenberg, "The evolution of complexity in human brain development:an EEG study", *Electroencephalography and Clinical Neurophysiology*, 99(5), 405-411, 1996.
- [3] R.Agarwal, J.Gotman, D.Flanagan, B.Rosenblatt, "Automatic EEG analysis during long-term monitoring in the ICU", *Electroencephalography and Clinical Neurophysiology*, 107(1), 44-58, 1998.
- [4] Hazarika N., Chen J.Z., Tsoi A.C., Sergejew A., "Classification of EEG signals using the wavelet transform", *Signal Processing*, 59(1),61-72, 1997.
- [5] Güler N.F., Übeyli E.D., Güler İ., "Recurrent neural networks employing Lyapunov exponents for EEG signals classification", *Expert Systems with Applications*, 29(3), 506-514, 2005.

- [6] Iasemidis, L.D., Shiau, D.S., Chaovalitwongse, W., Sackellares, J.C., Pardalos, P.M., Principe, J.C., Carney, P.R., Prasad, A., Veeramani, B., Tsakalis, K., "Adaptive epileptic seizure prediction system" *IEEE Transaction on Biomedical Engineering*, 50, 616-627, 2003.
- [7] Song Y., "A review of developments of EEG-based automatic medical support systems for epilepsy diagnosis and seizure detection", *Journal of Biomedical Science and Engineering*, 4, 788-796, 2011.
- [8] Srinivasan V., Eswaran C., Sriraam N., "Artificial Neural Network Based Epileptic Detection Using Time-Domain and Frequency-Domain Features", *Journal of Medical Systems*, 29(6), 647-660, 2005.
- [9] Gotman, J., "Automatic recognition of epileptic seizures in the EEG", *Electroencephalogr. Clin. Neurophysiol.*, 54, 530-540, 1982.
- [10] Murro, A. M., King, D.W., Smith, J. R., Gallagher, B. B., Flanigin, H. F., ve Meador, K., "Computerized seizure detection of complex partial seizures", *Electroencephalogr. Clin. Neurophysiol.*, 79, 330-333, 1991.
- [11] Qu, H., ve Gotman, J., "A patient-specific algorithm for the detection of seizure onset in longterm EEG monitoring: Possible use as a warning device", *IEEE trans. Biomed. Eng.*, 44(2), 115-122, 1997.
- [12] Weng,W., ve Khorasani, K., "An adaptive structure neural network with application to EEG automatic seizure detection", *Neural Netw.*, 9(7), 1223-1240, 1996.
- [13] Pradhan, N., Sadasivan, P. K., ve Arunodaya, G. R., "Detection of seizure activity in EEG by an artificial neural network: A preliminary study", *Comput. Biomed. Res.*, 29, 303-313, 1996.
- [14] Nigam, V. P., ve Graupe, D., "A neural-network-based detection of epilepsy", *Neurol. Res.*, 26, 55-60, 2004.
- [15] <http://www.meb.uni-bonn.de/epileptologie/science/physik/eegdata.html>
- [16] Ben-Hur A., Weston J., "A user's guide to support vector machines", *Methods in Molecular Biology*, 223-239, 2012.
- [17] Chang C-C. ve Lin C-J., "LIBSVM: a library for support vector machines", 2001. <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [18] Si J., Zhang Z., Lin ., Schroeder M. ve Huang B., "MetaDBSite: a meta approach to improve protein DNA-binding sites prediction", *BMC Systems Biology*, 5(1), S7, 2011.