



Çocuklarda EEG Sinyallerinden İktal Evrede Epilepsi Sınıflandırılması

Epilepsy Classification in Ictal Stage From EEG Signals for Children

Deniz REÇBER ve Mehmet Feyzi AKŞAHİN

Biyomedikal Mühendisliği

Başkent Üniversitesi

Ankara, TÜRKİYE

recberdeniz@gmail.com, maksahin@gmail.com

Özetçe— Elektroensefalogram(EEG) beynin elektriksel aktivitenin kaydedilmesidir. EEG sinyalleri temel olarak birçok nörolojik rahatsızlıkların tespiti ve görüntülenmesi için kullanılmaktadır. Bununla birlikte epilepsi tanısı için de kullanılmaktadır. Epilepsi kronik bir hastalık olup dünya nüfusunun %1'i bu rahatsızlıktan etkilenmektedir. Epilepsi, bilinç kaybı ilişkili nöbetlerle, uzun dönem bilinç kaybını içeren ve hasta yaşam kalitesini etkileyen sonuçlar yaratmaktadır. EEG verilerinden epilepsi tespitinin belirlenmesi mümkün olabilmektedir. Fakat EEG verilerinin uzunluğu ve kompleks yapısından dolayı hekimler tarafından epilepsi tespiti oldukça zordur. Epilepsinin sınıflandırma ve tespiti amacıyla birçok çalışma bulunmaktadır. Bu çalışmaların çoğu yapay sinir ağları ve makine öğrenme ile gerçekleşmektedir. Bu çalışmada EEG verileri üzerinden zaman-frekans düzlemi analizi ile elde edilen özniteliklerle ve nöbet sırasındaki EEG verileri üzerinden makine öğrenme kullanılarak epilepsi tespiti yapılmıştır. Yapılan çalışma sonucu 23 farklı EEG kanalı içerisinde en başarılı eğitim sonuçlarından biri olan Lojistik Regresyon sınıflandırıcıdan gelen veriler test edildiğinde %87.5 oranında doğruluk, %75.0 hassasiyet ve %100 oranında özgüllük değerleri elde edilmiştir.

Anahtar Kelimeler — EEG, Epilepsi, Makine Öğrenme(ML), Lojistik Regresyon.

Abstract— An electroencephalogram (EEG) is a recording of the electrical activity of the brain. EEG signals are mainly used for the detection and visualization of many neurological disorders. It is also used for the diagnosis of epilepsy. Epilepsy is a chronic disease and 1% of the world's population is affected. Epilepsy results in seizures associated with loss of consciousness, including long-term loss of consciousness and affecting patient quality of life. It is possible to determine the detection of epilepsy from EEG data. However, there are some difficulty to detect epilepsy because of the length and complexity of EEG. There are many studies for the classification and detection of epilepsy. Most of these studies are realized with artificial neural networks and machine learning. In this study, epilepsy detection was performed by using machine learning over EEG data with the features obtained by time-frequency domain analysis during seizure. As a

result of the study, Logistic Regression classifier gave the best training results for 23 different EEG channels and tested. In the test results; 87.5% accuracy, 75.0% sensitivity and 100% specificity values were obtained.

Keywords — EEG, Epilepsy, ML, Logistic Regression.

I. GİRİŞ

Epilepsi, beyindeki hücrelerin kontrol edilemeyen, ani, aşırı ve anormal deşarjlarına bağlı olarak ortaya çıkan bir durumdur[1]. Bununla birlikte epilepsi dünyanın en yaygın 4. Nörolojik rahatsızlığı olarak da bilinmekte ve her yıl 2.4 milyon yeni tanı konulmaktadır[2]. Beyin aktivitesini değerlendirmek için yaygın olarak kullanılan yöntemlerden biri, Elektroensefalogram (EEG) sinyalleridir. EEG sinyallerini kullanarak epilepsi nöbetlerinin tespiti, epilepsi tanısı için oldukça önemlidir[3]. Hem tanı hem de tedavide EEG sinyallerindeki nöbetlerin tespit edilmesi gerekmektedir. EEG sinyallerinden elde edilen parametreler, epileptik nöbetin otomatik tespiti için önemli bir teşhis özelliği olarak kullanılabilir[4]. Literatürde epilepsinin tespiti için kısa zamanlı Fourier dönüşümü[5], dalgacık dönüşümü[6-7], çoklu dalgacık dönüşümü[8] gibi çeşitli metotlar kullanılmaktadır. Yine literatürde epilepsinin tespiti için yetişkinlerde frontal ve temporal bölgedeki sinyallerin incelenmesi de mevcuttur[9].

Bu çalışma kapsamında güç spektral yoğunluğu ve ayrık zamanlı dalgacık dönüşümü yöntemlerinden elde edilen çeşitli öznitelikler kullanılarak epilepsinin iktal(nöbet) dönemde makine öğrenim yöntemi ile sınıflandırılması hedeflenmiştir. İlgili epokların dalgacık dönüşümü ile alt frekans bantlarına erişilerek alfa, beta, teta ve delta frekansları için güç spektral yoğunluğuna bakılmıştır. Elde edilen güç spektral yoğunluk için belirlenen öznitelikler; varyans, maksimum, minimum, standart sapma ve toplam değeridir.

II. KULLANILAN SINYALLER VE KAYIT ÖZELLİKLERİ

Kullanılan sinyaller MIT veritabanı <https://physionet.org/> dan alınmıştır. Sinyal verileri Boston Çocuk Hastanesinde kaydedilmiş ve epileptik nöbetler uzman hekimler tarafından skorlanmıştır. Alınan EEG verileri 23 kanaldan oluşmakta ve Bununla birlikte 256 Hz örnekleme frekansı ile örneklenmiştir. Kullanılan 23 farklı kanallar; FP1-F7, F7-T7, T7-P7, P7-O1, FP1-F3, F3-C3, C3-P3, P3-O1, FP2-F4, F4-C4, C4-P4, P4-O2, FP2-F8, F8-T8, T8-P8, P8-O2, FZ-CZ, CZ-PZ, P7-T7, T7-FT9, FT9-FT10, FT10-T8, T8-P8'dir.

III. YÖNTEM VE ANALİZLER

Çalışmada izlenen yöntemler kısaca şekil 1'deki gibi özetlenebilir.



Şekil 1. Çalışmanın blok diyagramı

A) Öznitelik Öncesi Uygulanan Yöntemler

Öncelikle, skorlaması yapılmış EEG kayıtlarından epilepsi nöbet evresini içeren sinyal ve normal sinyal seçilmiştir. Nöbet evresini barındıran ilgili epok değerine gidilerek o epoktaki sinyal verisi normal ve epileptik sinyal için ele alınmıştır. Daha sonrasında ilgili epok için ayrıık zamanlı dalgacık dönüşümü ve güç spektral yoğunluğu hesaplanmıştır.

1) Ayrıık Zamanlı Dalgacık Dönüşümü

Dalgacık dönüşümü yaygın olarak kullanılan sinyal işleme teknikleri için kullanılan bir yöntemdir. Fourier dönüşümü bir sinyal içerisindeki farklı frekans bileşenlerinden ne kadar bulunduğunu gösterme konusunda oldukça başarılıdır ancak bu frekans bileşenlerinin zamanın hangi anında bulunduğu veya tekrarlandığını gösteremez[10]. Bu sebeple dalgacık dönüşümü Fourier dönüşümünün aksine hem zaman hem de frekans bölgesini kapsayan sinyaldeki küçük değişim ve dalgalanmaların incelenmesine uygun bir yöntemdir. Ayrıık zamanlı dalgacık dönüşümü denklem 1'deki gibi matematiksel olarak integral dönüşüm ile ifade edilse de pratikte, analizde kullanılan dalgacıktan üretilen katsayılar kullanılarak dönüşüm yapılır. Alçak geçiren ve yüksek geçiren filtreler, giriş sinyali olarak analizi yapılan sinyali alır ve çıkışında katsayılardan oluşan, Nyquist kuralına göre örneklerinin yarısı atılmış bir sinyal üretir. Üretilen bu sinyal, girişteki sinyale ayrıık zaman dalgacık dönüşümü uygulanarak elde edilmiştir[11,12].

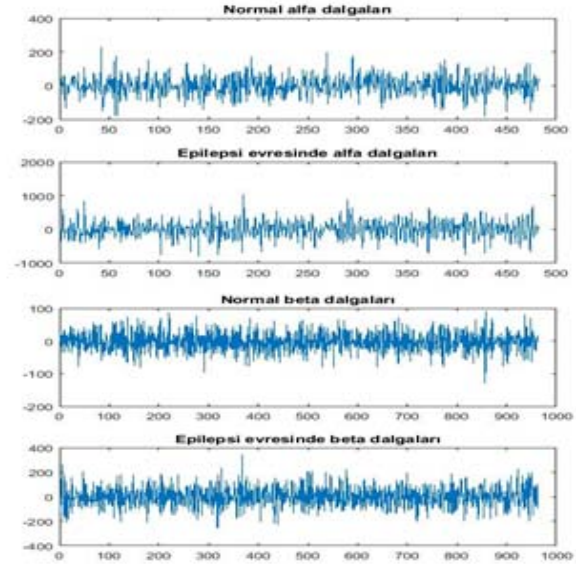
$$w(j, k) = 2^{-\frac{j}{2}} \int_{-\infty}^{+\infty} X(t) \Psi(2^{-j}t - k) dt \quad (1)$$

İncelenen epokta ise dalgacık dönüşümü 5. Dereceden Daubechies dalgacık(db2) tercih edilerek gerçekleştirilmiştir. Bunun sebebi tablo 1'de görüldüğü üzere her bir alt frekans bandını incelenebilmesidir.


Tablo I. Alt bant frekanslarının elde edilmesi

256 Hz Örnekleme Frekansı	Derece	
CA1	CD1	1
CA2	CD2	2
CA3	Beta	3
CA4	Alfa	4
Delta	Teta	5

Dalgacık dönüşümü sonrası elde edilen Alfa, Beta, Delta ve Teta alt bant frekansları şekil 2 ve 3'deki gibidir.



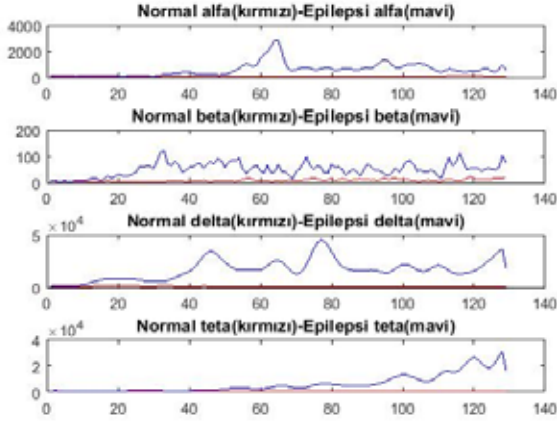
Şekil 2. Alfa ve Beta alt bant frekanslarının grafikleri



Şekil 3. Delta ve Teta alt bant frekanslarının grafikleri

2) Güç Spektral Yoğunluğu

Pwelch komutu kullanılarak Welch'in güç spectral yoğunluğu tahmini 256 Hz örnekleme frekansında elde edilmiştir. Şekil 6'daki gibi epilepsi nöbet evresi ile sağlıklı sinyal arasında büyük bir fark ortaya çıkmıştır.



Şekil 4. Alt bant frekanslarının güç spektral yoğunluğu

Daha sonraki elde edilecek özneliklerin daha elverişli kullanılabilmesi için mutlak değeri alınarak kullanılmıştır.

B) Seçilen Öznelikler

1) Varyans

Varyans kavramı, dağılıma ait her bir değer dağılımın ortalamasından ne kadar uzak olduğuyla ilgilidir. Varyans söz konusu sapmaların ortalama değerini ölçmektedir. Denklem (2) ile ifade edilir ve X değişkeni, μ ortalamayı ve N değer sayısını ifade etmektedir.

$$\sigma^2 = \frac{\sum (X - \mu)^2}{N} \quad (2)$$

3) Maksimum Değeri

Maksimum komutu, oluşturulan her bir alt dizideki maksimum değerlerine ulaşmak için kullanılmıştır. Yani dalgacık dönüşümü ile elde edilen alfa, beta, teta ve delta alt frekans bantlarının ilgili epoktaki güç spektral yoğunluğu mutlak değeri dizisinde maksimum değerini elde etmek için kullanılmıştır.

4) Minimum Değeri

Minimum komutu, oluşturulan her bir alt dizideki maksimum değerlerine ulaşmak için kullanılmıştır. Yani dalgacık dönüşümü ile elde edilen alfa, beta, teta ve delta alt frekans bantlarının ilgili epoktaki güç spektral yoğunluğu mutlak değeri dizisinde minimum değerini elde etmek için kullanılmıştır.

5) Standart Sapma

Standart sapma, bir serisindeki sayıların, serinin aritmetik ortalamasından farklarının karelerinin toplamının dizinin eleman sayısının bir eksiğine bölümünün kareköküdür. Standart sapma ile verilerin ne kadarının ortalamaya yakın olduğunu bulunmaktadır. Standart sapma değeri denklem 3'deki gibi hesaplanabilmektedir.

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (3)$$


6) Toplam Değeri

Toplam komutu, oluşturulan her bir alt dizideki değerlerin kedi içerisindeki toplam değerlerine ulaşmak için kullanılmıştır. Yani dalgacık dönüşümü ile elde edilen alfa, beta, teta ve delta alt frekans bantlarının ilgili epoktaki güç spektral yoğunluğu mutlak değeri dizisinde ayrı ayrı toplam değerini elde etmek için kullanılmıştır.

C) Sınıflandırma ve Başarının değerlendirilmesi

Öncelikle dalgacık dönüşümü yapılan ilgili epokta güç spektral yoğunluğunun mutlak değeri alındığında ve belirlenen öznelikler uygulandığında belirgin farklar olduğu gözlemlenmiştir. Daha sonrasında bu özneliklerden elde edilen değerler alfa, beta, delta ve teta alt frekans bantları için epilepsi sinyali ve epilepsi olmayan sinyal verileri ile birlikte bir matris oluşturulmuştur. Bu matrisin %50'si eğitim, %50'si ise test için kullanılmıştır. Sistem eğitilirken 5 katlamalı çapraz doğrulama kullanılmıştır. Sınıflandırıcıda epilepsinin var olduğu 1 epilepsinin olmadığı 0 olarak cevap niteliğinde belirlenmiştir. Yapılan eğitim çalışmasında en başarılı sınıflandırma yöntemlerinden biri %75'lik doğruluk oranıyla 'Logistic Regression' olduğu görülmüştür.

Bununla birlikte eğitilen sistemin doğruluk tablosu şekil 7'deki gibi olup gerçek pozitif ve yanlış negatif oranları da görülmektedir.



Şekil 5. Eğitilen sistemin doğruluk tablosu



Daha sonrasında eğitimi yapılan sistemin doğruluğu, özgülüğü ve duyarlılığı test verileri kullanılarak belirlenmiştir. Sistemin etkinliğinin belirlenmesi için gerçek pozitif (GP), yanlış pozitif (YP), gerçek negatif (GN) ve yanlış negatif (GN) değerleri belirlenerek sistemin doğruluk, özgülük ve duyarlılık değerlerine denklem 4,5 ve 6'daki gibi ulaşılmıştır.

$$\text{Doğruluk} = \frac{GP+GN}{GP+GN+YP+YN} \quad (4)$$

$$\text{Özgülük} = \frac{GN}{GN+YP} \quad (5)$$

$$\text{Duyarlılık} = \frac{GP}{GP+YN} \quad (6)$$

IV. SONUÇ

Sonuç olarak yapılan çalışmada epilepsi nöbet evresi ve sağlıklı EEG verisinin ayrıık zamanlı dalgacık dönüşümü sonrası güç spektral yoğunluğu belirlenen özniteliklerle beraber ilgili epokta 23 farklı kanalda incelenmiştir. İnceleme sırasında ayrıık zamanlık dalgacık dönüşümü için epok boyunca her bir alt frekans bandında frekans ve zaman düzleminde farklılıkların meydana geldiği görülmüştür.

Daha sonrasında sınıflandırma işleminde EEG verisinin %50'si eğitim %50'si ise test için kullanıldığında denklem 4-5-6 kullanılarak yapılan hesapla tablo II'deki gibi bir sonuç elde edilmiştir.

Tablo II.

	Doğruluk	Duyarlılık	Özgülük
Eğitim	%75	%50	%100
Test	%87.5	%75	%100

Bilindiği üzere epilepsi dünya nüfusunun %1'lik bir dilimini etkilemekte ve her yıl 2.4 milyon yeni tanı konulmaktadır. EEG sinyalinin kompleks yapısı ve uzunluğundan dolayı birçok nörolojik rahatsızlık gibi epilepsinin de tespit edilmesi oldukça zor bir durumdur. Bu sebeple epilepsinin teşhisi açısından bu tarz çalışmaların doktor ve yetkili kişiyi destekleyecek nitelikte bir uygulama olacağı ve objektif kararların verilmesinde katkı düşünölmektedir.

Yetişkin bireylerde epilepsi frontal-temporal bölgede yoğunluk gösterirken yapılan çalışmada 23 kanal incelemesinde çocuklarda ise central bölgede yoğunluk gösterdiği görülmüştür. Farklı yöntemler ve yaklaşımların belirtilen doğruluk ve hassasiyet parametrelerini arttırabilecek nitelikte olduğu düşünölmektedir.

Yapılan çalışmanın kapsamı daha fazla EEG verisi ile genişletilerek doğruluk ve hassasiyet parametrelerinin de yükseltilmesi düşünölmektedir. Bununla birlikte epilepsinin yoğunluk bölgesinin çocuklarda beyin hangi bölgesinde olduğunu da belirleyebilecek nitelikte olacağı öngörülmektedir.

KAYNAKLAR

- [1] Akdeniz, Gülsüm, et al. "Epileptic source localizations based on EEG and SDE measurements." *Biomedical Engineering Meeting (BIYOMUT), 2010 15th National*. IEEE, 2010.
- [2] JT Olivia, JLG Rosa "Classification for EEG Report Generation and Epilepsy Detection" *Neurocomputing* 2019.
- [3] L.D. Iasemidis, D.-S. Shiau, W. Chaovalitwongse, J.C. Sackellares, P.M. Pardalos, J.C. Principe, P.R. Carney, A. Prasad, B. Veeramani, K. Tsakalis, Adaptive epilep-tic seizure prediction system, *IEEE Trans. Biomed. Eng.* 50 (May (5)) (2003)616–627.
- [4] S. Altunay, Z. Telatar, O. Erogul, Epileptic EEG detection using the linear pre-diction error energy, *Expert Systems with Applications* 37 (August (8)) (2010)5661–5665.
- [5] R. Schuyler, A. White, K. Staley, K.J. Cios, Epileptic seizure detection, *IEEE Engi-neering in Medicine and Biology Magazine* 26 (March/April (2)) (2007) 74–81.
- [6] S. Ghosh-Dastidar, H. Adeli, N. Dadmehr, Mixed-band wavelet-chaos-neuralnetwork methodology for epilepsy and epileptic seizure detection, *IEEE Trans-actions on Biomedical Engineering* 54 (September (9)) (2007) 1545–1551.
- [7] H. Ocak, *Optimal classification of epileptic seizures in EEG using wavelet analysis and genetic algorithm*, *Signal Processing* 7 (July) (2008) 1858–1867.
- [8] L. Guo, D. Rivero, A. Pazos, *Epileptic seizure detection using multiwavelet trans-form based approximate entropy and artificial neural networks*, *Journal ofNeuroscience Methods* 193 (October (1)) (2010) 156–163.
- [9] Pedro Sudbrack-Oliveira, et al. "Sleep architecture in adults with epilepsy: a systematic review" *Sleepmedicine* 2018.
- [10] Juan Pablo Martinez, Rute Almeida, Salvador Olmos, Ana Paula Rocha, Pablo Laguna, *A Wavelet-Based ECG Delineator: Evaluation on Standard Databases*, *IEEE Transactions On Biomedical Engineering*, Vol. 51, No. 4, April 2004, pp. 570- 581.
- [11] C.S. Burrus, R.A. Gopinath, and H. Guo, *Introduction to Wavelets and Wavelet Transforms*. Upper Saddle River, NJ: Prentice Hall, 1998.
- [12] G. Strang and T. Nguyen, *Wavelets and Filter Banks*. Cambridge, MA: Wellesley-Cambridge Press, 1996.