



TIPTEKNO'17

TIP TEKNOLOJİLERİ KONGRESİ

12-14 Ekim 2017 / TRABZON

Karadeniz Teknik Üniversitesi, Prof.Dr. Osman Turan Kongre Merkezi



Biyomedikal ve Klinik
Mühendisliği Derneği



Elektrik-Elektronik Mühendisliği Bölümü
Bilgisayar Mühendisliği Bölümü

İnteraktif Sunumlar 2

Poster Alanı

Hilbert Dönüşümü Ve Teager Enerji Kullanılarak EEG İşaretlerinde Epileptik Nöbet Tespiti Detection of Epileptic Seizure from EEG Signals by Using Teager Energy and Hilbert Transform

Morteza Yadekar¹, Nasser Lotfivand²

¹ Department of Electronic Engineering, Tabriz Branch, Islamic Azad University, Tabriz, Iran;
morteza.yadekar@gmail.com

² Department of Electronic Engineering, Tabriz Branch, Islamic Azad University, Tabriz, Iran;
Lotfivand@laut.ac.ir

Özetçe—Beynin elektriksel aktivitesi ile ilgili elektroensefalografi (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 sağlıklı bireylerin EEG işaretleri ile epilepsi nöbeti geçiren bireylerin EEG işaretleri sınıflandırılmaya çalışılmıştır.

Bu çalışmada kullanılan EEG verileri, Physionet¹ bilimsel sitesi veri tabanındaki A ve B işaret gruplarından alınmıştır. A işaret grubu sağlıklı deneklerden alınan dört yüz adet yüzey EEG işaretini kapsamaktadır. B işaret grubu ise hasta deneklerden epileptik nöbet esnasında alınan yüz adet bölütleme EEG işaretleri 16 bit analog sayısal dönüştürücü kullanılarak 256 örnekleme frekansı ile bilgisayar ortamına aktarılmıştır. Bu sinyaller saniyede, 3 ila 23 yaş aralığında, 10-20 standardına numunelenmiştir.

Hilbert dönüşümü ve teager enerji kullanılarak Öznitelikler çıkarılmıştır. Çıkarılan öznitelikler kullanılarak sınıflandırılmaya tabi tutulmuştur, Sınıflandırma olarak K en yakın komşuluk (K-NN) yöntemi ve çok katmanlı sinir ağı kullanılarak, hastalığın tespitinde elde edilen performansın sırasıyla %95.75 ve %99 olduğu gözlemlenmiştir.

Anahtar Kelimeler — EEG; Epileptik nöbet; K-NN Sınıflandırma; Hilbert Dönüşümü; Teager Enerji.

Abstract—With regard to electrical interactions in the brain, Electroencephalographic (EEG) records are strongly considered to be one of the most applicable methods in diagnosis of neurologic diseases. One of the neurologic diseases is called Epilepsy which has impacted upon nearly 1% of the population worldwide. Today, employing computerized systems, to use in quick diagnosis of

illnesses that has been a paramount interest of study among researchers, has productively led to a great accuracy and immediate response. In this study, on account of Electroencephalographic signals epileptic seizures, a classification of the healthy and the epileptic is applied.

In this paper, descriptive database has been acquired from Physionet which includes two groups of data; first data belongs to healthy individuals which consists of 400 samples, and subsequently the second one belongs to the epileptic that is composed of 100 samples whose resolution and velocity are 16 bits and 256 samples per second respectively. The mentioned signals fall into 3 to 23 age range that has been sampled by the 10-20 standard.

From extracted features, Hilbert transform and teager energy value have been used for the act of classification. After applying the proposed method on the mentioned data, maximum correctness using KNN, Multilayer Neural Networks, classifiers, Are 95.75% and 99% respectively. Finally, our proposed method could successfully classify and distinguish between EEG of healthy individuals and epileptic ones with an accuracy of higher than 95%.

Keywords — Hilbert transform; Teager Energy; EEG Signal; Epileptic; K Nearest Neighbors Classification.

1. GİRİŞ

Elektroensefalogram (EEG) işaretleri beynin 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 [1]. Beynin elektriksel aktivitesi ile ilgili elektroensefalografi kayıtları kullanılarak yapılan çalışmalar nörolojik hastalıkların tanısında kullanılan en önemli araçlardan biridir [2-3]. Bu

İnteraktif Sunumlar 2

Poster Alanı

hastalıkların en bilinenlerinden biri olan epilepsi dünya nüfusunun yaklaşık olarak %1'inin sahip olduğu bir nörolojik bozukluktur [4]. Epilepsi hastalarında EEG sinyallerinde anormal kalıplar görülebilir. Bu durum zihnin bir pozisyonun da gerçekleşmesi olabilir, bu ataklara yerel atak denir ve eğer ataklarının etkileri tüm EEG kanallarında görülse, ona yaygın atak denir [5].

Frekans değişiklikleri EEG sinyallerinde zamanda ve öngörülemez doğası nedeniyle olmayan bir statik koşullar sahip olsun. Bu nedenle lineer olmayan analizler: hilbert dönüşümü, teager enerji ve yapay sinir ağı gibi analizler uygun öneriler den biridir [6].

Kerim karadağ ve Mehmet siraç özerdem tarafından dalgacık dönüşümü kullanılarak EEG işaretlerinde epileptik nöbet tespiti ve Sınıflandırma olarak K en yakın komşuluk (K-NN) yöntemi kullanılmıştır [7]. Duygu gür, turgay kaya, mustafa türk normal ve epileptik EEG sinyallerinin filtreleme yöntemleri ile hastalık teşhisinin kolaylaştırılması amaçlanmıştır [8]. Funda kutlu ve cemal köse tekrarlılık ölçme analizi ve destek vektör makineleri (DVM), çok katmanlı yapay sinir ağları (ÇKYSA) ve naive bayes sınıflandırıcılarından faydalanarak normal ve epileptik sinyallerin sınıflandırılmasında %96 başarı elde etmişlerdir[9]. Muhittin bayram ve hüseyin acar dalgacık dönüşümü ve Shannon entropi kullanarak sağlıklı ve epileptik EEG sinyallerini sınıflandırmıştır[10]. Bu çalışmalarda sadece 60-90 doğruluk oranı ve korteks ve frontal alanlarda nöbetlerin ortaya çıkmasını tespit kapasitesine sahiptirler.

Bu çalışmada, EEG işaretlerinin zaman ve frekans ortamında işlenmesi sonucu elde edilen bir takım özellikler kullanılarak, sağlıklı ve epileptik deneklerin sınıflandırılması K-NN ve çok katmanlı sinir ağı ile gerçekleştirilmiştir. Yapılan uygulamada, özneliklerin elde edilmesi aşamasında hilbert dönüşümü ve teager enerji yöntemleri kullanılmıştır. Sınıflandırma performansına göre seçilen özneliklerin etkinliği gözlenmiştir.

2. Materyal ve Metot

2.1. Çalışmada Kullanılan Veri Seti

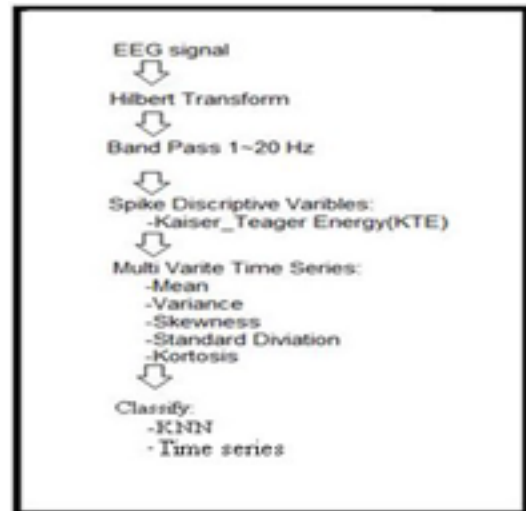
Bu çalışmada kullanılan EEG verileri, physionet bilimsel sitesi veri tabanından alınmıştır. Temel olarak veri seti iki işaret grubundan (A, B) oluşmaktadır. Her bir EEG sinyalleri 23 kanaldan alınmıştır. A işaret grubu sağlıklı deneklerden alınan dört yüzer adet yüzey EEG işaretini kapsamaktadır. B işaret grubu ise hasta deneklerden epileptik nöbet esnasında alınan yüz adet bölütleme oluşmaktadır. EEG işaretleri 16 bit analog sayısal dönüştürücü kullanılarak 256 örnekleme frekansı ile bilgisayar ortamına aktarılmıştır. Bu sinyaller saniyede, 3 ila 23 yaş

aralığında, 10-20 standardına numunelenmiştir. Şekil 1'de A ve B işaret gruplarına bir örnek gösterilmiştir.



Şekil 1. a) A işaret grubundan bir örnek
b) B işaret grubundan bir örnek

Bu çalışma kapsamında önerilen tespit akış şeması şekil 2'de verilmiştir.



Şekil 2. Epileptik nöbet tespitinde izlenen işlem akışı

Öncelikle kayıtların öznelik vektörleri elde edilir. Öznelik olarak hilbert dönüşümü ve teager enerji kullanılır. Elde edilen hilbert ve teager katsayıların istatistiksel değerleri (ortalama, standart sapma, varyans, skewness, kortosis) kullanılarak, k-NN ve Time series ile sınıflandırılması sağlanır.

İnteraktif Sunumlar 2

Poster Alanı

2.2. Metot

Bu çalışmada uygulanan yöntem temel olarak iki aşamadan oluşmaktadır. Birinci aşamada Hilbert dönüşümü ve Teager enerji kullanılarak öznelik çıkarma işlemi uygulanmaktadır. İkinci aşamada ise k-NN ve Time series kullanılarak sınıflandırma işlemi uygulanmaktadır.

2.2.1. Öznelik Çıkarma

Hilbert dönüşümü, bir matematiksel fonksiyondurki sinyalin fazın 90° dönüştürülken sinyal dalga aralığı hiçbir değişiklik yapmaz. Hilbert dönüşümü için sadece Fourier fonksiyonu elde edilebilir ve sonra $j\text{sgn}(f)$ fonksiyonuna çarpılır. Sonra ters Fourier dönüşümü alınır, sonuç olarak Hilbert dönüşümü alınır.

$$H(j\omega) = -j\text{sgn}(\omega) \quad [11] \quad (1-2)$$

$$\text{Sgn}(\omega) = \begin{cases} 1 & \omega > 0 \\ 0 & \omega = 0 \\ -1 & \omega < 0 \end{cases} \quad (2-2)$$

Başlangıç olarak sinyal Hilbert dönüşümüyle işlenir ve sonra bilgi içeren frekans bandı belirlenir. Orjinal sinyali elde edebilmek için iyi bir filtreleme yapılmalıdır. Çalışmada hem normal hem de epileptik EEG sinyallerindeki yüksek frekanslı ve şebekeden kaynaklanan ek bileşenleri elimine etmek için filtreleme yapılmıştır. Yüksek frekanslı gürültüleri yok etmek için hareketli ortalama filtre kullanılmıştır. Hareketli ortalama filtre keskin darbeleri yok etmezken, gürültüyü azaltmaktadır. Bu da sinyal için önemli bilgilerin kaybolmaması adına önem teşkil etmektedir. Hareketli ortalama filtreler sinyalin 1-20 Hertz frekansları kalmaktadır. Bu aşamada filtre edilen sinyal den özellik çıkartma için Teager entropisi kullanılmıştır. Bantlar genişliği arasında alfa bandı enerji açısından belirgin bir farkı var. Bu nedenle, özellik çıkartma için alfa bandı kullanılmıştır. Teager enerjisini hesaplamak için (3-2) formül kullanılmıştır.

$$TE(t) = (dx/dt)^2 + x(t)(d^2x/dt^2) \quad [12] \quad (3-2)$$

Enerjinin hesaplanmasın sonra aşağıdaki özellikler EEG sinyalin den elde edilmiştir: ortalama, standart sapma, varyans, skewness, kurtosis.

2.2.2. Sınıflandırma


Bu çalışmada sınıflandırıcı olarak K en yakın komşu ve Time series kullanılmıştır. Eğitim ve deneme başarımları bir dizi sınıflandırma deneyi yoluyla hesaplanmıştır. Eğitim başarımı, sınıflandırıcının sınıfların özelliklerini ne kadar iyi öğrendiği ile tanımlanır. Eğitim başarımının bulunmasında sınıflandırıcı belli bir sayıda eğitim örneklemleri ile eğitilir ve ardından aynı eğitim

örneklemeleri ile denenir. Eğitim kümesinin boyutu kademeli olarak artırılır ve sınıflandıma başarımının eğitim kümesi boyutuna göre evrimi incelenir. Böylece, sınıflandırıcının sınıf özelliklerini kavrayıp kavrayamadığı araştırılmaktadır.

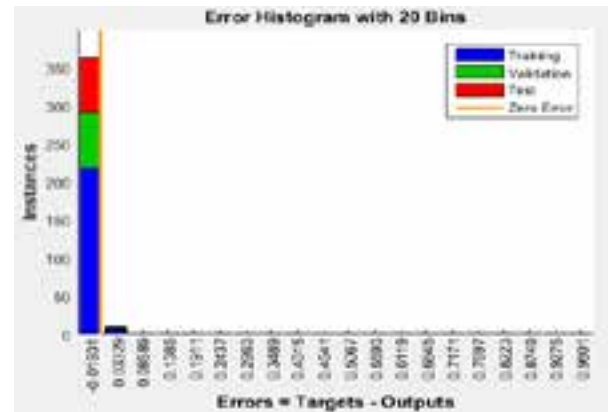
Deneme başarımı ise sınıflandırıcının yeni örneklemelerle karşılaştığında gösterdiği başarıyı ifade eder. Deneme başarımını incelerken, sınıflandırıcı belli sayıda eğitim örneklemleri ile eğitilir ve ardından, kümelerde bunlar dışında kalan örneklemelerle denenir. Burada, eğitim örneklemleri sayısı belli bir değeri aştıktan sonra, başarımın bir değer etrafına oturması beklenmektedir. Sınıflandırıcının tüm sınıfların özelliklerini kavraması için hangi büyüklükte bir eğitim kümesinin yeterli olduğunu bu şekilde görebiliriz. Eğitim ve deneme başarımları hesaplanmış ve şekil 3 ve 4'de ve Tablo 1'de sunulmuştur.

| K sayısı | K=3 | K=5 | K=7 | K=9 |
|-------------------|--------|--------|--------|--------|
| Sonuç | | | | |
| Hata oranı | %4.25 | %5.31 | %5.31 | %5.85 |
| Doğruluk | %95.75 | %94.69 | %94.69 | %94.15 |

Tablo 1.A ve B işaretlerinin sınıflandırma sonuç istatistikleri



Şekil 3. Time series sinir ağı performans grafiği



Şekil 4. Time series sinir ağı hatası grafiği



İnteraktif Sunumlar 2

Poster Alanı

3. Sonuçlar

Bu çalışmada physionet bilimsel sitesi very tabanından alınmış olan ve A ve B EEG işaret grupları sınıflandırılmaya çalışılmıştır. A işaret grubu sağlıklı deneklerden alınan dört yüzer adet yüzey EEG işaretini kapsamaktadır. B işaret grubu ise hasta deneklerden epileptik nöbet esnasında alınan yüz adet bölütten oluşmaktadır. Öznitelik çıkarma aşamasında hilbert dönüşümü ve teager enerji kullanılmıştır. Sınıflandırıcı olarak K-en yakın komşu ve Time series kullanılmıştır. A ve B işaret grupları sırasıyla K en yakın komşuluk (K-NN) yöntemi ve Time series kullanılarak, hastalığın tespitinde elde edilen performansın sırasıyla %95.75 ve %99 olduğu gözlemlenmiştir. Çalışmanın elde ettiği performans sonuçları hilbert dönüşümü ve teager enerji yardımıyla EEG işaretlerinde epileptik nöbet tespit etmesi açısından umut vericidir.

KAYNAKÇA

- [1] 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*, 2011. 4(12): p. 788.
- [2] Übeyli, E.D., Statistics over features: EEG signals analysis. *Computers in Biology and Medicine*, 2009. 39(8): p. 733-741.
- [3] Agarwal, R., et al., Automatic EEG analysis during long-term monitoring in the ICU. *Electroencephalography and clinical Neurophysiology*, 1998. 107(1): p. 44-58.
- [4] Nergiz, M., M.S. Özerdem, and M. Akin, Dalgacık Dönüşümü Kullanılarak EEG İşaretlerinde Epileptik Nöbet Tespiti Detection Of Epileptic Seizures In EEG Signals VIA Applying Wavelet Transform, 2014, Tip Teknolojileri Ulusal Kongresi.
- [5] Suratgar, A. and A. Rezaei Ashtiani, EEG Signals Processing for Diagnosis Petitmal (absence) and Grandmal Epilepsies Using Artificial Neural Network. *Arak Medical University Journal*, 2008. 11(3): p. 89-97.
- [6] Mohseni, H.R., A. Maghsoudi, and M.B. Shamsollahi. Seizure detection in EEG signals: A comparison of different approaches. in *Conf Proc IEEE Eng Med Biol Soc*. 2006.
- [7] Karadağ, K. and M.S. Özerdem, Dalgacık Dönüşümü Kullanılarak Fare EEG İşaretlerinde Epileptik Nöbet Tespiti Detection Of Epileptic Seizures In Rat EEG Signals VIA Applying Wavelet Transform, 2014, Tip Teknolojileri Ulusal Kongresi.
- [8] Gur, D., T. Kaya, and M. Turk. Analysis of normal and epileptic eeg signals with filtering methods. in *Signal Processing and Communications Applications Conference (SIU)*, 2014 22nd. 2014. IEEE.
- [9] Kutlu, F. and C. Kose. Detection of epileptic seizure from EEG signals by using recurrence quantification analysis. in *Signal Processing and Communications Applications Conference (SIU)*, 2014 22nd. 2014. IEEE.
- [10] Bayram, M. and H. ACAR, EEG sınıflandırma amaçlı bir kompozit sistem. *Dicle Univ. J. Eng. Cilt*, 2013. 4: p. 5-2.
- [11] Nikbakhsh, M.R. and A.M. MESHINCHI, Determination of parameters of self-potential anomalies using Hilbert transform method. 2012.
- [12] Monte-Moreno, E., Non-invasive estimate of blood glucose and blood pressure from a photoplethysmograph by means of machine learning techniques. *Artificial Intelligence in Medicine*, 2011. 53(2): p. 127-138.
- [13] ONAY, F.K. and K. Cemal, İçsel Mod Fonksiyonlarının Tekrarlılık Grafiği Kullanılarak EEG Sinyallerinde Epileptik Nöbetin Algılanması Epileptic Seizure Detection in EEG Signals Using Recurrence Plot of Intrinsic Mode Functions.
- [14] Mert, A. and A. Akan. Epilepsy detection using Empirical Mode Decomposition and detrended Fluctuation Analysis. in *Signal Processing and Communications Applications Conference (SIU)*, 2015 23th. 2015. IEEE.
- [15] Acharya, U.R., et al., Linear and nonlinear analysis of normal and CAD-affected heart rate signals. *Computer methods and programs in biomedicine*, 2014. 113(1): p. 55-68.
- [16] Alberdi, A., A. Aztiria, and A. Basarab, Towards an automatic early stress recognition system for office environments based on multimodal measurements: A review. *Journal of biomedical informatics*, 2016. 59: p. 49-75.
- [17] Gaspard, N., et al., Automatic detection of prominent interictal spikes in intracranial EEG: Validation of an algorithm and relationship to the seizure onset zone. *Clinical Neurophysiology*, 2014. 125(6): p. 1095-1103.
- [18] Shams, N., C. Alain, and S. Strother, Comparison of BCG artifact removal methods for evoked responses in simultaneous EEG-fMRI. *Journal of neuroscience methods*, 2015. 245: p. 137-146.
- [19] Chavan, M.S., R. Agarwala, and M. Uplane. Application of the Chebyshev type II digital filter for noise reduction in ECG signal. in *Proceedings of the 5th WSEAS Int. Conf. on Signal Processing, Computational Geometry & Artificial Vision*, Malta. 2005.
- [20] Alberdi, A., A. Aztiria, and A. Basarab, Towards an automatic early stress recognition system for office environments based on multimodal measurements: A review. *Journal of biomedical informatics*, 2016. 59: p. 49-75.