



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

Biyomedikal Sinyal İşleme 5

14 Ekim 2017 - 10.45-12.15 - Salon A

Epileptik EEG Verilerinin Grup Görgül Kip Ayırışımı Kullanılarak İncelenmesi

Investigation of Epileptic EEG Data Using Ensemble Empirical Mode Decomposition

Özlem Karabiber Cura, Aydın Akan

Biyomedikal Mühendisliği Bölümü, İzmir Kâtip Çelebi Üniversitesi, İzmir, Türkiye

{ozlem.karabiber, aydin.akan}@ikc.edu.tr

Özetçe—Yapılan çalışmada Grup Görgül Kip Ayırışımı (GGKA) yöntemi kullanılarak epileptik ve normal EEG verilerinin sınıflandırılması amaçlanmıştır. Bu amaç doğrultusunda 3 veri grubu ile çalışılmış ve her gruptan 30'ar EEG verisi incelenmiştir. Öncelikle GGKA yöntemi kullanılarak sinyaller öz kip fonksiyonlarına (ÖKF) ayrıştırılmıştır. Epileptik ve sağlıklı bireylerden alınan EEG sinyallerine ait GGKA açılımındaki 1. ÖKF'lerden ayrıştırıcı öz nitelikler hesaplanmıştır. Güç yoğunluk izgesi Welch ve periyodogram yöntemleri ile kestirilerek yüksek dereceli frekans momentleri hesaplanmıştır. Her iki yöntem ile elde edilen moment değerleri incelendiğinde, epileptik EEG verilerinin normal EEG verilerinden yüksek başarı ile ayrılabilirdiği gözlenmiştir.

Anahtar Kelimeler — epilepsi; grup görgül kip ayırışımı; periyodogram; Welch.

Abstract— In this study, it was aimed to classify the epileptic and normal EEG data by using the Ensemble Empirical Mode Decomposition (EEMD) method. For this purpose, we studied with 3 data groups and 30 data from each group were examined. Firstly, data were decomposed into intrinsic mode functions (IMFs) using EEMD. Decomposer features were calculated from the 1st IMF of the EEMD expansion of EEG signals from epileptic and healthy subjects. Power density is estimated by Welch and Periodogram methods and high frequency moments are calculated. When the moment value obtained by both methods were examined, it was observed that the epileptic EEG data could be separated with high success from the normal EEG data.

Keywords — epilepsy; Ensemble Empirical Mode Decomposition; periodogram; Welch.

I. GİRİŞ

Epilepsi beynin normal aktivitesinin anormal elektriksel aktiviteler sonucu bozulması ile ortaya çıkan nörolojik bir hastalıktır. Anormal elektriksel aktiviteler beynin sadece belirli bir bölümünde meydana gelebileceği gibi farklı beyin bölgelerinde de gözlenebilmektedir. [1, 2, 3]. Beyinde meydana gelen bu ani ve istenmeyen elektriksel aktivitelerin belirlenebilmesi için sıklıkla beynin elektriksel aktivitesinin

incelenmesinde kullanılan EEG kayıt yöntemi kullanılmaktadır. Epilepsi nöbet anının ve kaynağının doğru tespit edilebilmesi için uzun süreli EEG kayıtlarına ihtiyaç duyulmaktadır. Kayıtların süresi incelemeyi ve teşhisi zorlaştıracağından çeşitli sinyal işleme yöntemlerine başvurulması zorunlu hale gelmiştir. Yapılan çalışmalar incelendiğinde epilepsi teşhisini kolaylaştırmak ve önceden epilepsi ataklarını tespit edebilmek için birçok sinyal işleme çalışmasının yapılmış olduğu gözlenmiştir [2].

Qi ve arkadaşlarının gerçekleştirdiği çalışmada [1] dalgacık paketi dönüşümü kullanılarak zaman ve frekans ekseninde öz nitelikler elde edilmiş daha sonra bu öz nitelikler kullanılarak epileptik EEG verileri ağırlıklandırılmış aşırı öğrenme makinası yöntemi (ELM) ile sınıflandırılmıştır. Yine bir çalışmada [3] filtreleme ve Bayes teoremi kullanılarak öz nitelikler çıkartılmış ve epilepsi nöbetleri için yüksek başarı ile otomatik alarm sistemi tasarlanmıştır. [4, 5] Farklı çalışmalarda ise EEG, EKG ve EMG verileri ile düzenli örüntülerin tespiti algoritması kullanılarak epilepsi atak tespiti ve yine kernel aşırı öğrenme makinası kullanılarak epilepsi atak tespiti gerçekleştirilmiştir. Son olarak incelenen çalışmada [6] zebra balıklarının tek kanallı bölgesel alan potansiyel kayıtları incelenerek epileptik elektriksel boşalmaların otomatik tespiti için SVM yöntemi kullanılmıştır.

Gürültü temizleme yöntemi olarak sinyal işleme alanında sıkça kullanılmaya başlanan Grup Görgül Kip Ayırışımı (GGKA) yöntemi verilerin sınıflandırılması için kullanılabilecek yeni bir yöntemdir. Yapılan çalışma ile GGKA yöntemini kullanarak epileptik EEG verilerinin sağlıklı EEG verilerinden ayrılması amaçlanmıştır.

II. MALZEME VE YÖNTEM

A. Veriler

Çalışmada internet üzerinde açık erişime sahip referans [7]'da belirtilen beş farklı veri grubunu içeren (A'dan E'ye) veri seti kullanılmıştır. A ve B grubu veriler sağlıklı bireylerden yüzey elektrotları kullanılarak kaydedilmiş EEG verileridir. C ve D grubu veriler beyin içi elektrotları kullanılarak epilepsi hastası bireylerden kaydedilmiş ancak



Biyomedikal Sinyal İşleme 5

14 Ekim 2017 - 10.45-12.15 - Salon A

atak gözlenmeyen EEG verilerini içermektedir. E grubu veriler ise yine beyin içi elektrotlar kullanılarak epilepsi hastası bireylerden kaydedilmiş atak gözlenen EEG verilerinden oluşmaktadır. Her bir veri setinde 100 adet EEG kaydı olup verilerin örnekleme frekansı 173,61 hertzdir ve 40 Hz alçak geçiren filtre kullanılarak filtrelenmiştir [8].

Yapılan çalışmada epilepsi atağı gözlenen EEG verileri ve herhangi bir atak gözlenmeyen EEG verileri arasında anlamlı bir fark tespit etmek için yöntem geliştirilmesi amaçlandığından A, D ve E veri grubu ile çalışılmasına karar verilmiştir.

B. Grup Görgül Kip Ayırışımı (GGKA)Yöntemi

Lineer ve durağan olmayan sinyallerin analizinde kullanılabilir alternatif bir yöntem olan Görgül Kip Ayırışımı (GKA) yöntemi ile sinyaller kendini oluşturan sıfır ortalamalı öz kip fonksiyonları şeklinde birden fazla birleşene açılmaktadır. Böylece yapılan çalışmanın amacına yönelik olarak hangi kip fonksiyonu anlam ifade ediyorsa o kullanılabilir ve analiz kolaylaşmaktadır [2, 11]. Ancak GKA yönteminde bir kipte çok farklı genlikte salınımların olması veya çok benzer salınımların farklı kiplerde gerçekleşmesi gibi kip karışımı problemi olarak isimlendirilen problemlerle karşılaşmaktadır. Bu problemlerin üstesinden gelebilmek için GGKA yöntemi geliştirilmiştir [2, 9].

GGKA yönteminde analiz edilecek sinyale Gauss beyaz gürültü eklenmekte ve yine sinyal GKA yöntemi kullanılarak öz kip fonksiyonlarına ayrılmaktadır. Gürültü eklendikten sonra Gauss beyaz gürültünün istatistiksel özellikleri nedeniyle sinyalin sürekliliği farklı frekans bölgelerinde elde edilmekte böylece kip karışımı problemi azaltılmış olmaktadır. GGKA yönteminin aşamaları Algoritma 1 de gösterilmektedir.

Algoritma: GGKA yöntemi algoritması.

Aşama 1: Analiz edilen sinyale farklı ortalama ve varyansa sahip Gauss beyaz gürültüler eklenmektedir.

$x^i[n] = x[n] + g^i[n]$, $i = 1, \dots, k$, burada k sinyale farklı Gauss beyaz gürültüler eklenerek kaç kez görgül kip ayırışımı yönteminin uygulandığını göstermektedir.

Aşama 2. Elde edilen beyaz gürültü eklenmiş her bir $x^i[n]$ sinyalinden GKA yöntemi ile öz kip fonksiyonları elde edilmektedir.

$\overline{\text{ÖKF}}_j^i[n]$, $j = 1, \dots, J$, burada J elde edilen öz kip fonksiyonu sayısını göstermektedir.

Aşama 3. Farklı istatistiksel özelliklere sahip Gauss beyaz gürültü eklenmiş k adet $x[n]$ sinyali öz kip fonksiyonlarına ayrılmış ve her $x^i[n]$ sinyali için öz kip fonksiyonları $\overline{\text{ÖKF}}_j^i[n]$ elde edilmiştir. Elde edilen bu öz kip

fonksiyonlarından ortalama öz kip fonksiyonları $\overline{\text{ÖKF}}_j[n]$ elde edilmektedir [10, 11].

$$\overline{\text{ÖKF}}_j[n] = \frac{1}{k} \sum_{i=1}^k \overline{\text{ÖKF}}_j^i[n] \quad (1)$$

C. Önerilen Yöntem

Grup Görgül Kip Ayırışımı yöntemi kullanılarak Epileptik ve normal EEG verilerinin incelenmesi amaçlanmıştır. Bu amaç doğrultusunda A, D ve E veri grubu içerisinde 30'ar veri kullanılarak çalışma gerçekleştirilmiştir. GGKA yönteminde sinyaller kendini oluşturan öz kip fonksiyonlarına (ÖKF) ayrıştırılmaktadır ancak hangi ÖKF'nin sinyali en iyi şekilde temsil ettiği sinyalin yapısına göre farklılık göstermektedir [2, 9, 12]. Bu nedenle öncelikle hangi ÖKF ya da ÖKF'ler kullanılarak çalışmanın gerçekleştirileceğine doğru şekilde karar verilmeli daha sonra gruplar arasındaki fark ayırt edilmeye çalışılmaktadır. Yapılan çalışmanın işlem basamakları aşağıda anlatılmaktadır.

1) $x_A[n]$, $x_D[n]$ ve $x_E[n]$ veri gruplarından sinyaller GGKA yöntemi ile ÖKF'lere ayrıştırılmıştır.

$$\begin{aligned} \overline{\text{ÖKF}}_i^A[n], & \quad i = 1, \dots, I \\ \overline{\text{ÖKF}}_j^D[n], & \quad j = 1, \dots, J \\ \overline{\text{ÖKF}}_k^E[n], & \quad k = 1, \dots, K \end{aligned}$$

Burada I, J, K sırasıyla A, D ve E veri gruplarından seçilen her bir sinyal için toplam ÖKF sayısını göstermektedir.

2) Her bir grup için seçilen ilk 7 ÖKF'nin enerjileri hesaplanarak ÖKF'ler frekans bölgesinde incelenmiş ve 1.ÖKF'nin epileptik ve normal veri grupları arasında farklılık gösterdiği tespit edilmiştir. Dolayısı ile çalışmada 1.ÖKF'nin kullanılmasına karar verilmiştir.

$X^A[k]$, $X^D[k]$, $X^E[k]$ sırası ile A, D ve E veri grubundan seçilen sinyallerin 1.ÖKF sinin Fourier dönüşümünü temsil etmektedir.

3) Her bir veri grubu için 1. ÖKF'lerin toplam gücü, ve yüksek dereceli frekans momentleri $\langle \omega_k^i \rangle$, $i = 1, 2, 3$, hem Periyodogram hem de Welch yöntemleri ile hesaplanmış ve gruplar arasındaki fark incelenmiştir.

$$P[k] = \frac{1}{N} |X[k]|^2 \quad k = 1, \dots, N \quad (2)$$

$$P_{TOP} = \sum_{k=1}^N P[k] \quad (3)$$

$$M_1 = \sum_{m=1}^N \frac{2\pi m}{N} \times P[m] \quad (4)$$

Biyomedikal Sinyal İşleme 5

14 Ekim 2017 - 10.45-12.15 - Salon A

$$M_2 = \sum_{m=1}^N \left(\frac{2\pi m}{N} \right)^2 \times P[m] \quad (5)$$

$$M_3 = \sum_{m=1}^N \left(\frac{2\pi m}{N} \right)^3 \times P[m] \quad (6)$$

Burada denklem 2 ve 3 periyodogram yönteminde 1. ÖKF'lerin gücünü ($P[k]$) ve toplam gücünü (P_{TOP}) hesaplamak için kullanılan matematiksel eşitlikleri göstermektedir.

Aynı büyüklükler MATLAB de bulunan Welch yöntemi kullanılarak da hesaplanmıştır. Ayrıca N 1.ÖKF'lerin boyutunu, M_1 , M_2 , ve M_3 sırasıyla 1. ÖKF'lerin 1.momentini, 2. momentini ve 3.momentini göstermektedir.

Welch Yöntemi; Güç spektrumu kestiriminde yaygın olarak kullanılan yöntemlerden biridir. Öncelikle veri dizisi K adet aralarında örtüşmelerin de olabileceği parçaya ayrılmaktadır. Ardından her bir parçanın pencerelemiş Fourier dönüşümü hesaplanmaktadır. Son olarak hesaplanan Fourier dönüşümleri kullanılarak her bir parça için periyodogram değeri hesaplanmaktadır [13].

D. Performans Değerlendirmesi

Performans değerlendirme için kullanılan performans ölçütleri aşağıda verilmiştir.

$$ACC = \frac{TP + TN}{TP + FN + FP + TN} \quad (7)$$

$$SEN = \frac{TP}{TP + FN} \quad (8)$$


$$SPE = \frac{TN}{TN + FP} \quad (9)$$

Yukarıdaki formüller sırasıyla doğruluk (ACC), duyarlılık (SEN) ve seçicilik (SPE) olarak ifade edilmektedir [14]. Burada TP gerçekte bir sınıfa ait olup sınıflandırıcı tarafından da aynı sınıfa atanan verilerin sayısını, FN yanlışlıkta farklı bir sınıfa atanan verilerin sayısını göstermektedir. TN gerçekte farklı bir sınıfa ait olup sınıflandırıcı tarafından da farklı bir sınıfa atanan verilerin sayısını, FP yanlışlıkla aynı sınıfa atanan verilerin sayısını göstermektedir [15].


III. SONUÇLAR

GGKA yöntemi kullanılarak 3 farklı veri grubu ile çalışılmış her veri grubundan 30'ar veri incelenmiştir. Önerilen yöntem bu verilere uygulanmış, toplam güç ve yüksek dereceli frekans momentlerinin değerleri analiz edilerek epileptik veri grubunun diğerlerinden ayrılabilmesi amaçlanmıştır.

Şekil 1.a da periyodogram yöntemi kullanılarak elde edilmiş sonuçların grafiği 1.b de ise Welch yöntemi kullanılarak elde edilen sonuçların grafiği gösterilmektedir. Ayrıca her grup için bir eşik değeri belirlenerek atak gözlenen ve gözlenmeyen EEG verileri sınıflandırılmış ve sınıflandırma sonucunun performans değerlendirme tablo 1'e kaydedilmiştir. Her iki yöntemde de atak gözlenen ve gözlenmeyen EEG verilerinin maksimum %92,2 ACC, %93,3 SEN ve %91,6 SPE başarı ile sınıflandırılmış olduğu gözlenmiştir.



(a)



(b)

Şekil 1. Periyodogram ve Welch sonuç değerlendirilmesi

Burada (a) periyodogram , (b) Welch yöntemi ile elde edilen sonuçları, grafiklerdeki yeşil renk epilepsi hastası olup atak gözlenen grubun sonuçlarını, kırmızı renk sağlıklı grubun sonuçlarını mavi renk epilepsi hastası olup atak gözlenmeyen grubun sonuçlarını göstermektedir. Grafiklerde 1. Satır toplam güç, 2. Satır 1.moment, 3.satır 3.moment ve 4 satır da 4.moment grafiğini göstermektedir

Tablo 1. Periyodogram ve Welch yöntemleri ile elde edilen sonuçların performans değerlendirilmesi

	Periyodogram				Welch				Performans Değerlendirmesi (%)		
	TP	TN	FP	FN	TP	TN	FP	FN	ACC	SEN	SPE
Moment1	28	55	5	2	28	55	5	2	92.2	93.3	91.6
Moment2	28	55	5	2	28	55	5	2	92.2	93.3	91.6
Moment3	28	53	7	2	28	53	7	2	90	93.3	88.3
Toplam Güç	28	55	5	2	28	55	5	2	92.2	93.3	91.6

I. TARTIŞMA

Grup Görgül Kip Ayrışımı (GGKA) yönteminin farklı veri grupları arasında anlamlı bir ilişki ortaya koymakta kullanılabilecek yeni bir yöntem olması çalışmada kullanılması temeli sebebi olmuştur. Bu çalışmada GGKA yöntemi ile elde edilen öz kip fonksiyonlarının periyodogram ve Welch yöntemleri ile incelenmesi önerilen yöntemdir.

Elde edilen sonuçların hem grafiksel olarak dağılımları incelenmiş hem de sınıflandırma sonuçlarının performans değerlendirilmesi gerçekleştirilmiştir. İki değerlendirmede de epileptik verilerin diğer iki gruptan iyi bir şekilde ayrılmış olduğu %92,2, %93,3, %91,6 sırasıyla ACC, SEN ve SPE sonuçları ile görülmektedir. Önerilen yöntemin epileptik veriler ile sağlıklı verilerin sınıflandırılmasında kullanılabileceği gözlenmiştir.

KAYNAKÇA

- [1] Yuan, Q., Zhou, W., Zhanga, L., Zhanga, F., Xud, F., Lenga, Y., Weia, D., Chena, M., "Epileptic seizure detection based on imbalanced classification and wavelet packet transform", Seizure 50 (2017) 99–108, 2017
- [2] Mert, A., Akan, A., "Detrended fluctuation thresholding for empirical mode decomposition based denoising", Digital Signal Processing 32 (2014) 48–56, 2014.
- [3] Grewal, S., Gotman, J., "An automatic warning system for epileptic seizures recorded on intracerebral EEGs", Clinical Neurophysiology 116 (2005) 2460–2472, 2005.
- [4] Fürbass, F., Kampusch, S., Kaniusas, E., Koren, J., Pirker, S., Hopfengärtner, R., Stefan, H., Kluge, V., Baumgartner, C., "Automatic multimodal detection for long-term seizure documentation in epilepsy", Clinical Neurophysiology 128 (2017) 1466–1472, 2017.
- [5] Liua, Q., Zhaoa, X., Houa, Z., Liub, H., "Epileptic seizure detection based on the kernel extreme learning machine", Technology and Health Care -1 (2017) 1–11, 2017.



TIP TEKNO'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

Biyomedikal Sinyal İşleme 5

14 Ekim 2017 - 10.45-12.15 - Salon A

- [6] Hunyadi, B., Siekierska, A., Sourbron, J., Copmans, D., A.M. de Witte, P., “Automated analysis of brain activity for seizure detection in zebrafish models of epilepsy”, *Journal of Neuroscience Methods* 287 (2017) 13–24, 2017.
- [7] http://epileptologie-bonn.de/cms/front_content.php?idcat=193&lang=3&changelang=3, [Erişim Tarihi: 15.04.2017].
- [8] Güler, İ., Übeyli, E., D., “Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients”, *Journal of Neuroscience Methods*, 2005.
- [9] Flandrin, P., Rilling, G., Gonçalvés, P., “Empirical Mode Decomposition as a Filter Bank”, *IEEE Signal Processing Letters*, 11(2), 2004.
- [10] Wu, Z., Huang, N., E., “Ensemble Empirical Mode Decomposition: A Noise-Assisted Data Analysis Method”, *Advances in Adaptive Data Analysis* Vol. 1, No. 1 (2009) 1–41.
- [11] Sharma, B., Kaur, S., “Distinction between EMD & EEMD Algorithm for Pitch Detection in Speech Processing”, *International Journal of Engineering Trends and Technology (IJETT)* –7 (3), 2014
- [12] Ren, H., Wang, Y., Huang, M., Chang, Y., Kao, H., “Ensemble Empirical Mode Decomposition Parameters Optimization for Spectral Distance Measurement in Hyperspectral Remote Sensing Data”, *Remote Sens.* 2014, 6, 2069–2083, 2014
- [13] Welch, P., D., “The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodogram”, *IEEE Transaction on Audio and Electroacoustic*, AU-15, 70-73, 1967.
- [14] Özmen, N. G., “Beyin Bilgisayar Arayüzü Tasarımı İçin Farklı Zihinsel Aktiviteler Esnasında Oluşan EEG İşaretlerinin Analiz Edilmesi ve Sınıflandırılması”, *Doktora Tezi, Fen Bilimleri Enstitüsü, Karadeniz Teknik Üniversitesi, Trabzon*, 2010.
- [15] Narin, A., İşler, Y., Özer, M., “Konjestif Kalp Yetmezliği Teşhisinde Kullanılan Çapraz Doğrulama Yöntemlerinin Sınıflandırıcı Performanslarının Belirlenmesine Olan Etkilerinin Karşılaştırılması”, *DEÜ Mühendislik Fakültesi Mühendislik Bilimleri Dergisi*, 16(48), 1-8, 2014.