

İçsel Mod Fonksiyonlarının Tekrarlılık Grafiği Kullanılarak EEG Sinyallerinde Epileptik Nöbetin Algılanması

Epileptic Seizure Detection in EEG Signals Using Recurrence Plot of Intrinsic Mode Functions

Funda KUTLU ONAY¹, Cemal KÖSE²

^{1,2}Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü

Karadeniz Teknik Üniversitesi

¹fkutlu@ceng.ktu.edu.tr, ²ckose@ktu.edu.tr

Özet

Bilgisayarlı sistemler yardımıyla hastalıkların ön tanısı günümüzde yaygın ve popüler olan araştırma konularından birisidir. Böylece tanı için geçen zaman ve yanlış tanı oranı azalmaktadır. Bu amaçla, epilepsi hastalığının ön tanısının gerçekleştirilmesi ve sağlıklı ve epileptik bireylerin algılanması için EEG işaretleri kullanılmıştır. Çalışmada, öznelik çıkarmada Hilbert-Huang dönüşümü ile elde edilen içsel mod fonksiyonlarının tekrarlılık grafiğinden faydalanılmıştır. Sınıflandırma aşamasında ise destek vektör makineleri (DVM), çok katmanlı yapay sinir ağları (ÇKYSA) ve k-en yakın komşuluk (k-EYK) sınıflandırıcılarına başvurulmuştur. Buna bağlı olarak, DVM kullanıldığı durumda %96.67 sınıflandırma başarısı elde edilmiştir.

Abstract

The pre-diagnosis of diseases with computerized system is the one of the most common and popular research topic in recent days. So, the time taken for diagnosis and misdiagnosis rate is decreasing. EEG signals were used in the realization of a pre-diagnosis of epilepsy and detection of epileptic and healthy individuals for this reason. In this study, feature extraction was carried out with recurrence plot of intrinsic mode functions acquired with Hilbert-Huang transformation. in classification stage, support vector machines (SVM), multilayer perceptron neural networks (MLPNN) and k-nearest neighbor (k-NN) classifiers have been utilized. Accordingly, in the case of using SVM, 96,6% classification performance was obtained.

1. Giriş

Bilgisayarlı sistemlerle hastalık teşhisi, son zamanların en popüler konularından birisi haline gelmiştir. Geliştirilen yazılımlar sayesinde yanlış tanı ve tanı için geçen sürenin azaltılması sağlanmaktadır. Bu teknolojinin kullanıldığı alanlardan birisi de epilepsi hastalığının teşhisidir.

Epilepsi hastalığı tekrarlayan nöbetler şeklinde seyreden ve yaygın olarak görülen bir beyin fonksiyon bozukluğu hastalığıdır. Dünya nüfusunun %1'ini etkisi altına alan bu

hastalığın her yaşta görülebilme olasılığı vardır. İnsan yaşamını olumsuz halde etkilemesi, biyomedikal araştırmalarda epilepsi teşhisini önemli ve popüler bir hale getirmektedir [1].

Literatürde epilepsi işaretinin analizi ile epilepsi hastalığının teşhisine yönelik çok sayıda çalışma mevcuttur. Bu çalışmalarda zaman, frekans ya da zaman-frekans uzayında öznelik çıkarma yöntemleri uygulanıp, uygun sınıflandırıcı yöntemi ile sınıflandırma işleminin gerçekleştirilmesine yönelik bir akış izlenmektedir.

Çalışmada Almanya Bonn Üniversitesi Epileptoloji Bölümü'nden temin edilen, epilepsi teşhisi ve epileptik nöbet algılama araştırmalarında kullanılmak üzere kaydedilen EEG veri seti kullanılmıştır. Literatürde çok sayıda çalışma bu veri seti üzerinden yöntemler önermiş ve başarılı sonuçlar elde etmişlerdir. Belli başlı çalışmalardan bahsedilecek olursa; Gautama vd., doğrusal olmayan analiz yöntemleri ile, normal ve epileptik EEG işaretlerini temsil etmiş ve %86.2 sınıflandırma başarısı sağlamışlardır [2]. Kannathal vd., entropi ve adaptif bulanık mantık çıkarım sisteminden (ABMÇS, ANFIS) yararlanarak normal ve epileptik EEG işaretlerini sınıflandırmışlar ve %90 başarı elde etmişlerdir [3]. Sadati vd., normal ve epileptik dönemlerin algılanması amacıyla uyarlanabilir nöral bulanık ağlar yöntemini öne sürmüşler ve ANFIS ile %85.9 sınıflandırma doğruluğu elde etmişlerdir [4]. Srinivasan vd., yaklaşık entropi yöntemini kullanan YSA tabanlı otomatik epileptik EEG belirleme sistemini öne sürmüşlerdir ve Elman ve olasılıksal YSA yöntemlerini kullanarak %100 sınıflandırma performansı elde etmişlerdir [5]. Tzallas vd., zaman-frekans analizi metotlarından faydalanarak, k-en yakın komşuluk (k-EYK) sınıflandırıcı sayesinde %97.71 ile %100 arasında başarı elde etmişlerdir [6]. Son olarak Polat ve Güneş, karar ağacı ve hızlı Fourier dönüşümü tabanlı melez bir sistem öne sürerek, epileptik nöbetin tespitini %98 doğrulukla gerçekleştirmişlerdir [7].


Bir sonraki bölümde sırasıyla; kullanılan veri seti ve özelliklerinden, elde edilen özneliklerden ve uygulanan sınıflandırma yaklaşımlarından bahsedilecektir. Daha sonra

elde edilen sınıflandırma doğrulukları, literatürde benzer olan çalışmalarla karşılaştırılacaktır.

2. Kullanılan Veri Seti ve Özellikleri

Çalışmada, Almanya Bonn Üniversitesi, Epileptoloji Bölümü'nde Andrzejak vd. tarafından epilepsi teşhisi ve epileptik nöbet belirleme araştırmalarında kullanılmak üzere kaydedilen EEG veri setinden faydalanılmıştır [8]. Herkese açık olan bu veri seti 128-kanallı 12 bit EEG kayıt sistemi ile, 173.61 örnekleme frekansı ile örneklenecek kaydedilmiş ve bu 128 kanalın ortalama değeri alınarak tek bir kanala indirgenmiştir. Toplam 500 denemeden oluşan bu sistem, 5 grup bireyden elde edilmiştir (A, B, C, D ve E). Her bir deneme 23.6 sn uzunluğundadır. Dolayısıyla her bir deneme 173,61*23,6=4097 örnekle temsil edilir. Kayıt işlemi, uluslararası 10-20 elektrot sistemine göre gerçekleştirilmiş olup, tüm denemeler göz ve kas hareketlerinden dolayı oluşan artefaktlardan arındırılmıştır.

A ve B alt grupları, 5 gönüllü sağlıklı bireyden, sırasıyla göz açık ve kapalı durumda kaydedilmiştir. C ve D alt grupları 5 epilepsi hastası bireyden nöbet olmayan dönemde ölçülen ve kafatası içinden alınan kayıtlardır. Son olarak E alt grubu, aynı 5 hasta bireyden nöbet döneminde alınan kayıtlardır. Bu 5 alt gruba ait birer örnek deneme; A, B, C, D ve E sırasıyla Şekil 1'de verilmiştir.



Şekil 1: Sırasıyla A, B, C, D ve E gruplarına karşılık gelen EEG örnek sinyalleri

Buna göre "sağlıklı" bireyler A ve B gruplarına, "hastalıklı" bireyler ise C, D ve E gruplarına karşılık gelmektedir. Çalışmada ise bu iki sınıfın sınıflandırılması ele alınmıştır.

3. Öznitelik Çıkarma

Öznitelik çıkarma aşamasında, Hilbert-Huang dönüşümü ile elde edilen içsel mod fonksiyonlarının tekrarlılık grafiği kullanılmıştır. Bunun için öncelikle hastalıklı ve sağlıklı olmak üzere oluşturulan iki grup, çapraz doğrulamanın 10-kat doğrulama yöntemi ile %60 eğitim ve %40 test verisi olacak şekilde rastgele olarak ayrılıp, daha sonra sınıflandırma işlemine tabi tutulmuştur.

Bir sonraki bölümde ilk olarak Hilbert-Huang dönüşümü ile elde edilen içsel mod fonksiyonlarından, daha sonra ise tekrarlılık grafiğinden bahsedilecektir.

3.1. Hilbert-Huang Dönüşümü

Hilbert-Huang Dönüşümü (HHD), doğrusal olmayan ve durağan olmayan işaretlerin analizinde kullanılan deneysel bir yöntemdir. Matematiksel ifadesinin net ve keskin olmayışı, yöntemin ampirik bir yöntem olduğu fikrini ortaya koymaktadır [9].

HHD yöntemi iki aşamalı bir yöntemdir. İlk olarak İçsel Mod Fonksiyonları (İMF) elde edilir, ikinci olarak ise Hilbert Dönüşümü (HD) ile anlık frekans ve genlik değerleri zaman-frekans uzayında elde edilir. HHD, doğrusal olmayan ve durağan olmayan işaretlerin zaman-frekans uzayında temsillerinde, geleneksel yöntemlere göre daha net sonuçlar verdiği için tercih edilmektedir.

3.1.1. İçsel Mod Fonksiyonlarının Elde Edilmesi

Bu yöntem ile çalışmada EEG işareti olarak kullanılan girdi sinyali, farklı karakteristik salınım özellikleri barındıran İMF'ler cinsinden ifade edilmektedir.

$$y(t) = \sum_{i=1}^N s_i(t) + r_N(t) \quad (1)$$

Burada $s_i(t)$, işaretin ayrıştırıldığı İMF'leri, $r_N(t)$ ise bu N tane İMF'nin toplamından arda kalan artık işareti temsil eder. Bulunan İMF'lerin iki özelliği barındırması gerekir: Birincisi, yerel maksimum ve minimumlarının sayısı ve sıfır geçiş sayıları eşit ya da 1 farklı olmalıdır. İkincisi ise, İMF sinyaline ait üst ve alt zarf ortalaması, herhangi bir an için sıfıra yakın (seçilen eşiğin altında) olmalıdır [10]. İMF'lerin bulunması aşağıdaki algoritmaya göre gerçekleştirilmektedir:

i) Girdi sinyalindeki yerel ekstremum değerler kullanılarak ara değerlendirme ile üst ve alt zarflar elde edilir. Bunların ortalaması ile ortalama zarf sinyali bulunur. ii) girdi sinyalinden ortalama zarf sinyali çıkarılarak detay işareti bulunur. iii) Elde edilen detay işareti, yukarıda belirtilen İMF özelliklerini taşııyorsa, üstteki adımlar detay işareti için tekrar uygulanır. iv) İMF özelliklerinin sağlanması ile detay işaretinin elde edilmesi durumunda, İMF sinyali hesaplanmış olur ve bu seviyedeki artık sinyal elde edilir. İstenen İMF sayısına ulaşına dek, adımlar artık sinyal üzerinden tekrarlanır.

3.1.2. Hilbert Dönüşümü

Bir sinyali ifade etmenin en iyi yolu anlık frekanslardır. Hilbert dönüşümü de, anlık frekansların kolaylıkla hesaplanıp ifade edildiği bir yöntemdir.

Gerçek değerli $x(t)$ fonksiyonunun HD'si, karmaşık uzayda bir fonksiyona karşılık gelir [11]. Bu da (2)'deki gibi ifade edilir:

$$z(t) = x(t) + j y(t) = a(t)e^{j\theta(t)} \quad (2)$$


Bu ifadenin anlık genlik ve faz fonksiyonu (3)'teki gibidir. Burdan da anlık frekans bilgisi (4)'teki gibi elde edilir.

$$a(t) = \sqrt{x^2(t) + y^2(t)}, \theta(t) = \arctan\left(\frac{y(t)}{x(t)}\right) \quad (3)$$

$$\omega(t) = \frac{d\theta(t)}{dt}, f(t) = \frac{1}{2\pi} \frac{d\theta(t)}{dt} \quad (4)$$

Her bir İMF için HD dönüşümü alınarak analitik bir ifade elde edilir. HD göstermektedir ki, her bir İMF aslında genlik veya frekans modülasyonuna uğratılmış işaretlerdir. İMF ayrıştırma işlemi, Fourier Dönüşümünün aksine sabit olmayan yani değişken genlik ve frekans ölçeklerine sahip olan bir dönüşüm olduğundan, EEG sinyali gibi durağan olmayan işaretler için oldukça faydalı bir ayrıştırma işlemidir [12].

Şekilde sağlıklı bireyden alınan EEG sinyali ve bu sinyalin ilk 5 İMF'si verilmiştir. İlk 5 İMF'nin sinyalin temsili ve sınıflandırılmasında yeterli olduğu deneysel olarak belirlenmiştir.




Şekil 2: Sağlıklı bireyden alınan EEG sinyali ve bu sinyalin ilk İMF örnekleri

Epileptik ve epileptik olmayan EEG işaretlerinden İMF'ler elde edilip, HD uygulandıktan sonra, geleneksel öznitelikler yerine, Tekrarlılık Grafiği (TG) yönteminden faydalanılarak öznitelik çıkarma işlemi gerçekleştirilmiştir.

3.2. Tekrarlılık Grafiği ve Tekrarlılık Ölçme Analizi

Tekrarlılık grafiği (TG), Eckmann [13] tarafından öne sürülen ve dinamik bir sistemde meydana gelen tekrarlı durumları gösteren bir matristir. Bir sinyalin durağan olmama durumunu ölçmede faydalıdır. TG yöntemi, doğrusal olmayan sınıflandırma problemlerinde kullanılan avantajlı bir

yöntemdir. Örnek iki sınıfa ait tekrarlılık grafiği şekilde verilmiştir.



Şekil 3: Örnek iki sınıfa ait tekrarlılık grafiği


Tekrarlılık olduğundan bahsedilebilmesi için, i ve j gibi iki nokta arasındaki uzaklık bir ε eşik değerinin altına düşmelidir. i. nokta j. noktaya yeteri ölçüde yakın ise, grafik üzerindeki (i,j) konumuna bir nokta konur. x_i 'nin x_j 'ye olan uzaklığı, x_j 'nin x_i 'ye olan uzaklığına eşit olacağından, tekrarlılık grafiği i=j eksenine göre simetriktr. Böylelikle, tekrarlılık grafiği NxN boyutta noktalardan oluşan bir matristir.

Acharya vd. [14], çalışmalarında normal, nöbet öncesi ve nöbet dönemlerinin tanımlanmasında bu yöntemle başvurmuşlardır. Tekrarlılık grafiğinin yorumlanmasında tekrarlılık ölçme analizi (TÖA) parametrelerinden faydalanılır. R, NxN boyutlu bir tekrarlılık grafiği olmak üzere, kullanılan TÖA parametreleri Çizelge 1'deki gibi hesaplanmaktadır:


Çizelge 1: TÖA parametreleri

Parametre	Denklem
Tekrarlılık Oranı	$RR = \frac{1}{N^2} \sum_{i,j=1}^N R_{i,j}$
Belirlilik	$DET = \frac{\sum_{l=l_{min}}^N IP(l)}{\sum_{i,j=1}^N R_{i,j}}$
Tabakalanma	$LAM = \frac{\sum_{l=l_{min}}^N \nu P(\nu)}{\sum_{l=l_{min}}^N \nu R(\nu)}$
Belirlilik ve tekrarlılık oranı ilişkisi	$RATIO = N^2 \frac{\sum_{l=l_{min}}^N IP(l)}{\left(\sum_{l=l_{min}}^N IP(l)\right)^2}$
Ortalama çapraz hat uzunluğu	$L = \frac{\sum_{l=l_{min}}^N IP(l)}{\sum_{l=l_{min}}^N P(l)}$
Yakalama zamanı	$TT = \frac{\sum_{l=l_{min}}^N \nu P(\nu)}{\sum_{l=l_{min}}^N P(\nu)}$
En uzun çapraz (Lmax) ve dikey (Vmax) hat uzunluğu	$L_{max} = \max\{l_i; i=1...N_l\}$ $V_{max} = \max\{l_v; v=1...N_v\}$
İraksaklık	$DIV = \frac{1}{L_{max}}$
Düzensizlik	$ENTR = - \sum_{l=l_{min}}^N p(l) \ln p(l)$

Şekil 4'te ve Şekil 5'te sırasıyla sağlıklı ve epilepsi hastası bireylerin bir denemesinin İMF'lerine ait tekrarlılık grafikleri verilmiştir. Buradan elde edilen öznitelikler, sınıflandırma aşamasında kullanılacaktır.



Şekil 4: Sağlıklı bireye ait bir denemenin IMF'lerinin tekrarlılık grafikleri



Şekil 5: Epileptik bireye ait bir denemenin IMF'lerinin tekrarlılık grafikleri

4. Sınıflandırma

Bu kısımda, TÖA sonucu elde edilen öznelitlikler ile k-EYK, DVM ve ÇKYSA sınıflandırıcılarına başvurularak sınıflandırma işlemi yapılmıştır.

4.1. k-EYK Sınıflandırıcı

k-en yakın komşuluk algoritması, örüntü tanıma ve otomatik öğrenmeye ilişkin uygulamalarda, verilerin sınıflandırılmasında kullanılan bir danışmanlı öğrenme metodudur [15]. Buna göre, tanıma yapılacak olan örüntü örneğine en yakın olan k komşusu tespit edilir. Daha sonra bu k tane komşunun en fazla hangi sınıfa ait olduğu bulunur ve o sınıfın etiket değeri, tanınacak örüntü örneğine atanır. Burada kullanılan k parametresinin seçilmesinde çapraz doğrulama yöntemi kullanılmıştır. İki nokta arasındaki uzaklık ise Öklit uzaklığı yöntemi ile hesaplanmıştır.

4.2. Çok Katmanlı Yapay Sinir Ağları

ÇKYSA sistemleri, insandaki biyolojik sinir sisteminin temelini oluşturan nöronların çalışma mekanizmasından esinlenilerek geliştirilen bir sınıflandırma tekniğidir [16].

Probleme dair çıkarılan öznelitlikler bir vektöre dönüştürüldükten sonra yapay sinir ağına girdi olarak verilerek, çıktı katmanında uygun karar değerinin elde edilmesi amaçlanır. Burada, ağı doğru eğitilmesi ağı kalitesini artırır [17].

Bir ÇKYSA; verilere ait öznelitliklerin sunulduğu bir girdi katmanı, ayrıştırmayı sağlayan bir veya daha fazla gizli (ara) katman ve girdilerin sınıf bilgisini ortaya koyan çıktı katmanından oluşur. Bu çalışmada kullanılan ÇKYSA mimarisinde girdi katmanı 10, ara katman 40 ve çıkış katmanı 1 nörona oluşmaktadır.

4.3. Destek Vektör Makineleri

Destek vektör makineleri, danışmanlı öğrenme yaklaşımıyla çalışan bir sınıflandırma tekniğidir. Hem doğrusal ayrılabilen hem de doğrusal ayrılamayan sınıflandırma problemlerinde kullanılır. Ancak DVM'nin çalışma prensibi temel olarak iki sınıfa ait verileri birbirinden en uygun şekilde ayıran karar sınırlarının yani hiper-düzlemlerin belirlenmesine dayalıdır [18].

Gerçek zamanlı uygulamaların çoğunda, doğrusal ayrıştırma mümkün olmadığından çekirdek fonksiyonu denilen fonksiyonlar yardımıyla girdi uzayında doğrusal olarak ayrılamayan veriler, girdi uzayından daha yüksek boyutlu olan bir başka uzayda tanımlanır. Böylece veriler doğrusal olarak ayrılabilir ve hiper-düzlem belirlenebilecek duruma getirilir. Çalışmada radyal tabanlı çekirdek fonksiyonu kullanılmıştır ve (5)'teki gibi ifade edilir. Burada γ , çekirdek boyutunu ifade eder.

$$K(x, y) = e^{-\gamma \|x - x_i\|^2} \quad (5)$$

5. Sonuçlar ve Tartışma

Bu bölümde epileptik ve epileptik olmayan EEG işaretlerinden çıkarılan özneliklere göre sınıflandırma performanslarından bahsedilecektir.

HHD ile elde edilen İMF'lerin tekrarlılık grafiklerinin ölçme kriterlerine göre sınıflandırma doğrulukları Çizelge 2'de verilmiştir.

Çizelge 2: Sınıflandırma doğrulukları

İMF	k-NN(%)	SVM(%)	YSA(%)
İMF1	98,80	99,6	98,80
İMF2	82,8	88,4	88
İMF3	80,4	80,8	78,4
İMF4	77,2	84,0	84,0
İMF5	75,6	75,2	75,20
İMF1 İMF2	81,95	91,26	94,8
İMF1 İMF4	70,4	83,8	84,6
İMF1 İMF2 İMF4	77,6	85,33	84,27

Tabloya bakıldığında, 1 numaralı içsel mod fonksiyonunun TÖA parametreleri üzerinden SVM ile sınıflandırma yapıldığında, %99,6 sınıflandırma doğruluğu elde edilmiştir.

Aynı veri setini kullanan benzer bir çalışmada ise, dalgacık dönüşümü ve içsel mod fonksiyonlarının karşılaştırılması yapılmış ve en yüksek %98 özgüllük değeri elde edilmiştir [19].

6. Kaynaklar

- [1] Reynolds, P. E. H., Epilepsy: The Disorder, Epilepsy Atlas, (2005) 15-27.
- [2] Gautama, T., Mandic, D. P. ve Hulle, M. M. V., "Indications of Nonlinear Structures in Brain Electrical Activity", *Phys. Rev. E*, 67,4 (2003) 046204-1,5.
- [3] Kannathal, N., Choo, M. L., Acharya, U. R. ve Sadasivan, P. K., "Entropies for Detection of Epilepsy in EEG", *Computer Methods and Programs in Biomedicine*, 80, 3 (2005) 187-194.
- [4] Sadati, N., Mohseni, H. R. ve Maghsoudi, A., "Epileptic Seizure Detection Using Neural Fuzzy Networks", *2006 IEEE International Conference on Fuzzy Systems*, July 2006, Canada, Bildiri Kitabı: 596-600.
- [5] Srinivasan, V., Eswaran, C. ve Sriraam, N., Approximate "Entropy-Based Epileptic EEG Detection Using Artificial Neural Networks", *IEEE Transactions on Information Technology in Biomedicine*, 11, 3 (2007) 288-295.
- [6] Tzallas, A. T., Tsipouras, M. G. ve Fotiadis, D. I., Automatic "Seizure Detection Based on Time-Frequency Analysis and Artificial Neural Networks", *Computational Intelligence and Neuroscience*, 2007 (2007) 80510-1,13.
- [7] Polat, K. ve Güneş, S., "Classification of Epileptiform EEG Using a Hybrid System Based on Decision Tree Classifier and Fast Fourier Transform", *Applied Mathematics and Computation*, 187, 2 (2007) 1017-1026.
- [8] Andrzejak, R. G., Lehnertz, F., Mormann, F., Rieke, David, P. ve Elger, C.E., "Indications of Nonlinear Deterministic and Finite Dimensional Structures in Time Series of Brain Electrical Activity: Dependence on Recording Region and Brain State", *Phys. Rev. E*, 64 (2001) 061907-1,8.
- [9] Roy, A. Wen, C.-H., Doherty, J. H. and Mathews, J. D., "Signal Feature Extraction From Microbarograph Observations Using the Hilbert-Huang Transform", *IEEE Transactions on Geoscience and Remote Sensing*, 46, 5 (2008) 1442-1447
- [10] Şayli, Ö., "Hilbert-Huang Dönüşümü İle Solunum Seslerindeki Üfürümün Saptanması"
- [11] Hekim Tanç, Y. ve Akan, A., "Hilbert-Huang Dönüşümü İle Sayısal Modülasyon Türü Sınıflandırması"
- [12] Huang, N. E. and Wu, Z., "A Review on Hilbert-Huang Transform: Method and Its Applications to Geophysical Studies", *Reviews of Geophysics*, 46, 2 (2008)
- [13] Eckmann, J. P., Kamphorst, S. O. ve Ruelle, D., "Recurrence Plots of Dynamical Systems", *Europhy. Lett.*, 4 (1987) 973-977.
- [14] Acharya, U. R., Sree, S. V., Chattopadhyay, S., Wenwei, Y. U. ve Alvin, A. P. C., "Application of Recurrence Quantification Analysis for the Automated Identification of Epileptic EEG Signals", *Int. J. Neural Syst.* 21,3 (2011) 199-211.
- [15] Larose, D. T., Discovering Knowledge in Data, A John Wiley & Sons Inc. Publication, Newyork, 2005.
- [16] Yegnanarayana, B., *Artificial Neural Networks*, Prentice Hall of India, New Delhi, 2006.
- [17] Öztemel, E., *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul, 2006.
- [18] Vapnik, V., *The Nature of Stastical Learning Theory*, Springer-Verlag, Newyork, 1995.
- [19] Li, S., QiYuan, W., Geng S., Cai, D., "Feature Extraction and Recognition of Ictal EEG Using EMD and SVM", *Computers in Biology and Medicine*, 43(2013) 807-816