

# EEG İşareti Üzerinde Sara Ataklarının ve Sara Belirtisi İşaretlerin Bulunması

## Detection of Epilepsy Seizures and Epileptic Indicators in EEG Signals

Zeynep Yücel, A. Bülent Özgüler

Elektrik Elektronik Mühendisliği Bölümü  
Bilkent Üniversitesi, Ankara

zeynep@ee.bilkent.edu.tr, ozguler@ee.bilkent.edu.tr

### Özetçe

*Beyinde normal olmayan elektriksel aktivitelerin gerçekleşmesi ile tanımlanabilecek sara hastalığının belirtileri, elektroensefalografi (EEG) işareti üzerinde gözlemlenmektedir. Bu çalışma, EEG'nin kaotik ölçülerinin modellenmesinden yararlanarak, sara ataklarının tesbit edilmesine ve ataklardan yoksun işaretlerde hastalığın teşhis edilmesine yardımcı olmayı amaçlamaktadır.*

### Abstract

*Symptoms of epilepsy, which is characterized by abnormal brain electrical activity, can be observed on electroencephalography (EEG) signal. This paper employs models of chaotic measures of EEG and aims to help detection of epilepsy seizures and diagnosis of epileptic indicators in seizure-free signals.*

### 1. Giriş

Lehnertz [12], EEG işaret işleme tekniklerini doğrusal ve doğrusal olmayan olarak iki sınıfa ayırmıştır. Doğrusal yöntemler arasında [7], [11], [9] sayılabilir. Güler et. al. [7], EEG çözümlemesinde hızlı Fourier dönüşümü ve özbağlanım tabanlı yöntemleri karşılaştırmıştır. Juling et. al. [11], ve Jahankhani et. al. [9], EEG'nin zaman-sıklık özelliklerini türetmek için dalgacık dönüşümü kullanmıştır. Doğrusal olmayan metodların içinde sinir ağları sıkça kullanılmaktadır. Yazarlar [13]'te sinir ağlarını atakları öngörmek ve atak işaretçilerini saptamak için kullanmıştır. Doğrusal olmayan diğer bir takım yöntemler de entropi ile ilgili özellikleri ele alır. Bunlar atakların tahmin edilmesinde [14], kişilere özel atak işaretçilerinin tesbitinde [3] ve atak ve atak öncesi dönemlerin ayırt edilmesinde kullanılır, [4]. Bunların yanısıra, bağımsız bileşen analizi [10], evre kenetleme döngüsü [8] ve yukarıda bahsedilen metodları karışımlarından oluşan yöntemler de EEG çözümlemesinde kullanılmaktadır.

Biz bu çalışmada, EEG'nin kaotik ölçülerini modelleyerek sara hastalığı bakımından gösterdiği farklı belirtileri ayırt etmeyi amaçlıyoruz. Bu makalenin akışı şu şekildedir: Bölüm 2, ele alınan veri tabanının özelliklerini açıklamaktadır. Bölüm 3'te yöntem bilgisinin ayrıntıları sunulmaktadır. Bölüm 4 ve 5'te ise tanımlanan yöntemin başarımlarını grafikleri ve sonuçlar sergilenmektedir.

### 2. EEG Veri Tabanı

Bu çalışmada Bonn üniversitesi epileptoloji kliniğinde hazırlanan EEG veri tabanı kullanılmıştır. Andrzejak et. al. [2], değişik özelliklerdeki EEG işaretlerini barındıran üç kümeden oluşan bir veri tabanı oluşturmuştur.  $S$  ve  $E$  kümeleri sara hastası kişilerin EEG kayıtlarını bulundururken,  $H$  kümesi sağlıklı kişilerden alınmış 200 EEG kaydından oluşmaktadır.  $E$ 'deki 200 EEG işareti ataklar arası dönemde,  $S$ 'deki 100 işaret ise atak döneminde kaydedilmiştir. Bütün kümeler 173.61 Hz örnekleme hızıyla 23.6 s. boyunca kaydedilmiş tek kanallı EEG işaretlerinden oluşmaktadır.

### 3. Yöntem Bilgisi

Bu çalışma EEG işaretinin çeşitli sıklık bantlarındaki kaotik özelliklerinin hastanın işlevbilimsel durumu ile ilgili ek faydalı bilgiler sağlayacağı varsayımından hareketle sara hastalığına ait farklı belirtileri ayırt etmeyi amaçlamaktadır. Kullandığımız yöntem çoklu çözümlülük çözümlemesinin ardından gömülü gecikmeli zaman vektörlerinin oluşturulmasını ve özyineleme oranının modellenmesini içermektedir.


#### 3.1. Çoklu Çözümlülük Çözümlemesi

Dalgacık dönüşümü, işaretin çeşitli sıklık bantlarında ve farklı çözümlülük seviyelerinde incelenmesine imkan tanıdığından tercih edilmiştir.

Zaman serisi  $x_0$ ,  $H$ ,  $E$  ya da  $S$  kümelerinden birine ait olsun. Bu zaman serisinin dalgacık dönüşümü, alçak ve yüksek geçiren süzgeçler,  $h_0(n) = \{0.25, 0.5, 0.25\}$  ve  $h_1(n) = \{-0.25, 0.5, -0.25\}$ , ile 2 aşama boyunca hesaplanmaktadır. Bu işlem sonucunda hesaplanan 1. ve 2. aşama yaklaşıkla işaretleri  $x_1$  and  $x_2$  ile gösterilmektedir

#### 3.2. Gömülü Gecikmeli Zaman Vektörlerinin İnşa Edilmesi

Doğrusal olmayan bir sistem, zaman içinde evrimleşirken, belli bir durum kümesine yeterince yakınlaştıktan sonra, hafifçe sarsılabilir, bu durumların yakın komşuluğu içinde kalmaya devam edebilir. Bu tip durumlara kaotik çekiciler adı verilir. EEG işareti doğrusal olmayan bir dinamik sistem olarak ele alındığında, kaotik çekici özelliklerinin normal ve epileptik beyin etkinlikleri arasında fark gösterdiği gözlenmiştir. Bu makalede, sağlıklı, ataklar arası ve atak



Şekil 1:  $S$  kümesinin 15. elemanı için karşılıklı bilgi fonksiyonunun evrimi

dönemleri arasındaki farkları ayırt etmek için kaotik özelliklere odaklanmaktayız. Kaos ölçüsü olarak da özyineleme oranı kullanılacaktır. Özyineleme oranının hesaplanması gömülü gecikmeli (GG) zaman vektörlerinin oluşturulmasını gerektirmektedir. En küçük gömme boyutu  $d_0$ , en iyi gecikme miktarı  $m_0$  ve her hangi bir  $\alpha$  zaman serisinin uzunluğu  $N_\alpha$  ile gösterildiğinde, GG zaman vektörleri

$$\beta_\alpha^i(d_0) = \{\alpha(i), \alpha(i + m_0), \dots, \alpha(i + (d_0 - 1)m_0)\},$$

$$1 \leq i \leq n_\alpha, n_\alpha = N_\alpha - (d_0 - 1)m_0, \quad (1)$$

şeklinde. GG zaman vektörlerinin oluşturulması için öncelikle en iyi gecikme miktarı  $m_0$  ve minimum gömme boyutu  $d_0$  tesbit edilmelidir.

### 3.2.1. En İyi Gecikme Miktarının Bulunması

En iyi gecikme miktarı, bir zaman serisinin iki parçası arasında örtüşen bilgiyi en az yapan kayma miktarıdır. Bunun bulunmasında, iki değişken arasındaki karşılıklı bağımlılığı gösteren karşılıklı bilgi fonksiyonu,  $I$ , kullanılmaktadır. Zaman serisi  $x_0$ 'ın boyutu  $N_{x_0}$  olsun ve

$$x_0^i = \{x_0(i), x_0(i + 1), \dots, x_0(N_{x_0} - m)\},$$

$$x_0^{i+m} = \{x_0(i + m), x_0(i + m + 1), \dots, x_0(N_{x_0})\}$$

olsun. Bunlar arasındaki karşılıklı bağımlılığı  $I(m)$  ile gösterelim. Çeşitli  $m$  değerleri için  $I(m)$ 'nin aldığı değerler incelendiğinde iki zaman serisi arasındaki karşılıklı bağımlılığın evrimi gözlemlenebilir. Kuşkusuz daha büyük bir gecikme daha az örtüşmeye sebep olur. Öte yandan, daha küçük bir gecikme, mantıklı çıkarımlar yapılabilmesi için, elimizde yeterince fazla zaman serisi olmasına imkan sağlar. Bu sebeple,  $I(m)$  fonksiyonunun ilk yerel minimum noktası en iyi gecikme miktarı olarak kabul edilir, [1]. Şekil 1,  $S$  kümesinin rastgele bir elemanı için karşılıklı bilgi fonksiyonunun  $m$ 'nin artan değerlerine karşı gösterdiği evrimi ele almaktadır. Şekilde görüldüğü gibi, bu zaman serisi için en iyi gecikme miktarı  $m_0 = 9$ 'dur.

### 3.2.2. En Küçük Gömme Boyutunun Bulunması

Rastgele bir gömme boyutu  $d$  kullanılarak Denklem 1'deki şekilde oluşturulan  $\beta_{x_0}^i(d)$  GG zaman vektörünü ele alalım. Cao [5],  $d$  gömme boyutunun gerçek gömme boyutu olarak kabul edilmesi için bir gereksinim ve hesaplama yöntemi tanımlamıştır. Cao'ya göre,  $d_0$  gerçek gömme boyutu olduğunda,  $d_0$  boyutlu uzayda birbirlerine yakın yer alan,

$\beta_{x_0}^i(d_0)$  ve  $\beta_{x_0}^j(d_0)$  GG zaman serileri,  $d_0 + 1$  boyutlu uzayda da yakındırlar. Belli bir gömme boyutunun bu gereksinimi sağlayıp sağlamadığını anlamak için,  $d$  boyutlu uzayda birbirlerine en yakın komşu olan iki zaman serisinin  $d + 1$  boyutlu uzaydaki uzaklıklarına bakılır. Bu uzaklıkların ortalamalarının oranının, gömme boyutu  $d_0 - 1$  gibi bir değeri aştıktan sonra belli bir değere oturması beklenmekte ve  $d_0$ 'a minimum gömme boyutu adı verilmektedir. Bu veri tabanı için minimum gömme boyutunu [1], 7 olarak vermiştir.

Aşağıda  $d_0$  sabit tutulmakta fakat her  $x_0$  zaman serisi için ayrı bir  $m_0$  hesaplanmaktadır. Bu sebeple, gösterimde bir sadeleştirme yapılmakta ve bu noktadan sonra GG zaman vektörleri  $\beta_\alpha^i(d_0)$  yerine  $\beta_\alpha^i$  ile gösterilmektedir.

### 3.3. Özyineleme Oranının Modellenmesi

Her  $x_0$  ve ona karşı gelen  $x_1$  ve  $x_2$  altbantları için GG zaman vektörleri tesbit edilen  $m_0$  ve  $d_0$  ile, Denklem 1'deki şekilde oluşturulmaktadır. Bu işlem sonucunda oluşturulan  $\beta_{x_0}^i$ ,  $\beta_{x_1}^i$ ,  $\beta_{x_2}^i$ , üç adet gecikmeli evre uzayı meydana getirirler. Her hangi bir EEG kaydının ayırt edici özellikleri bu üç evre uzayının özyineleme özelliklerine bakılarak türetilmiştir.

Bölüm 3.3.2 özyineleme özelliklerinin türetilmesinin ayrıntılarını ele almakta, Bölüm 3.3.3 özyineleme oranının modellenmesini açıklamakta ve kestirim hatasını sunarak modelin tutarlılığını kanıtlamaktadır. Özellik vektörlerinin 3 boyuttaki dağılımı ise Bölüm 3.3.4'de gösterilmektedir.

#### 3.3.1. Özyineleme Oranı

Birbirlerine  $\epsilon$ 'dan daha yakın bulunan her hangi iki durum özyineleme durumları olarak isimlendirilir. Elemanları  $\sigma_i$ ,  $1 \leq i \leq N$  olan  $\sigma$  evre uzayının özyineleme grafiğini  $\mathbf{R}$  ile gösterelim. Bu özyineleme grafiği üzerindeki  $(i, j)$  noktasının değeri

$$\mathbf{R}(i, j) = \Theta(\epsilon - \|\sigma_i - \sigma_j\|)$$

gibi hesaplanır. Burada  $\Theta$  Heaviside basamak fonksiyonunu,  $\|\cdot\|$  maksimum normu ve  $\epsilon$  ise uzaklık eşiğini ifade etmektedir. Bu denklemde açıkça görülür ki, evre uzayında  $\sigma_i$  ve  $\sigma_j$  gibi birbirlerine  $\epsilon$ 'dan daha yakın her hangi iki durum mevcutsa,  $\mathbf{R}(i, j) = 1$  ve aksi durumda  $\mathbf{R}(i, j) = 0$ 'dır. Özyineleme oranı  $\Psi$  ise


$$\Psi = \frac{1}{N^2} \sum_{i,j=1}^N \mathbf{R}(i, j)$$

ile hesaplanmaktadır ve grafikteki özyineleme noktalarının yoğunluğu olarak nitelendirilebilir.

#### 3.3.2. Özellik Vektörlerinin Türetilmesi

Özellik vektörleri,  $\Psi$ 'nın, uzaklık eşiğinin değişik değerlerine karşı gösterdiği evrimin incelenmesiyle türetilmektedir. Zaman serisi  $\alpha$ 'nın gecikmeli evre uzayının özyineleme oranı, belli bir  $\epsilon_k$  uzaklık eşiği için

$$\Psi_\alpha^k = \frac{1}{N_\alpha^2} \sum_{\substack{i,j=1 \\ i \neq j}}^{N_\alpha} \Theta(\epsilon_k - \|\beta_\alpha^i - \beta_\alpha^j\|)$$



Şekil 2: (a)  $H$  kümesinin 15. elemanının özyineleme oranının kestirimi ve (b)  $H$  kümesinin tümü için kestirim hatası.

olsun. Uzaklık eşliğinin değişik değerleri,  $\epsilon_1, \epsilon_2, \dots, \epsilon_K$  için  $\Psi_\alpha^k$  değeri hesaplanarak ve bir özyineleme oranı serisi  $\Psi_\alpha = \{\Psi_\alpha^1, \Psi_\alpha^2, \dots, \Psi_\alpha^K\}$  oluşturularak [6], özyineleme oranının uzaklık eşliğine karşı evrimi, gözlemlenmektedir.

Özyineleme oranı serisi  $\Psi_\alpha$ 'nın,  $H$ ,  $E$  ve  $S$  kümeleri için farklı özellikler sergilemesi beklenir. Ancak,  $\Psi_\alpha$  vektörünün boyutu  $K$ 'ya bağlı olarak büyük olabileceği için, sadece özyineleme oranı serisini kullanmak elverişli değildir. Boyut indirgemesi sağlamak bakımından,  $\Psi_\alpha$  için daha basit bir model benimsenmiştir. Böylece  $\alpha$ 'nın özellik vektörü sadece  $\Psi_\alpha$  için geliştirilen modelin parametrelerini içerecektir.

$\Psi_\alpha^k$ 'nin  $\epsilon_k$ 'ya karşı grafiğini incelendiğimizde,  $f(t) = Ae^{kt}$  üssel fonksiyonuna benzer bir davranış sergilediğini gözlemledik. Bu sebeple,  $\Psi_\alpha$ 'ya bir üssel fonksiyonla yaklaşıldığında,  $\alpha$  zaman serisinin özellik vektörü sadece  $A$  ve  $k$  parametreleriyle oluşturulabilir.

### 3.3.3. Geliştirilen Modelin Uygunluğu


Şekil 2-(a)'daki kesiksiz çizgi  $H$  kümesinin rastgele bir elemanının özyineleme oranı serisinin  $1 \leq \epsilon \leq 20$  için evrimini gösterirken, kesikli çizgi ise  $Ae^{k\epsilon}$  modelinin kestirimini ifade etmektedir. Model, özyineleme oranı serisine tam bir uygunluk göstermese de kestirim hatası yüksek değildir. Küme  $H$ 'nin tümü için kestirim hatasını gösteren Şekil 2-(b) de bu gerçeği doğrulamaktadır.

### 3.3.4. Özellik Vektörlerinin Dağılımı

Özyineleme oranının evrimi için bir model belirlendikten ve model parametreleri çözüldükten sonra, bunların, temelde yatan beyin elektriksel etkinliğinin ayırımına imkan verip vermediğini kontrol etmeliyiz. Şekil 3,  $H$ ,  $E$  ve  $S$  kümeleri için  $A$  ve  $k$  parametrelerinin dağılımını göstermektedir. Bu şekillerde de açıkça görülür ki, her iki parametre de  $x_0$ - $x_1$ - $x_2$  uzayında çoğunlukla farklı alanlara dağılmıştır ve bu kümelerin ayırımına imkan vermektedir.

## 3.4. Sınıflandırma

$H$ ,  $E$  ve  $S$  kümelerinin ayırt edilmesinde "K en yakın komşu" yöntemi kullanılmıştır. Eğitim ve deneme başarımları bir dizi sınıflandırma deneyi yoluyla hesaplanmıştır. Eğitim başarımları, sınıflandırıcının sınıfların özelliklerini ne kadar iyi öğrendiği ile tanımlanır. Eğitim başarımlarının bulunmasında sınıflandırıcı belli



Şekil 3:  $A$  ve  $k$ 'nin dağılımı.

bir sayıda eğitim örneklemleri ile eğitilir ve ardından aynı eğitim örneklemleri ile denenir. Eğitim kümesinin boyutu kademeli olarak artırılır ve sınıflandırmaya başarımının eğitim kümesi boyutuna göre evrimi incelenir. Böylece, sınıflandırıcının sınıf özelliklerini kavrayıp kavrayamadığı araştırılmaktadır.

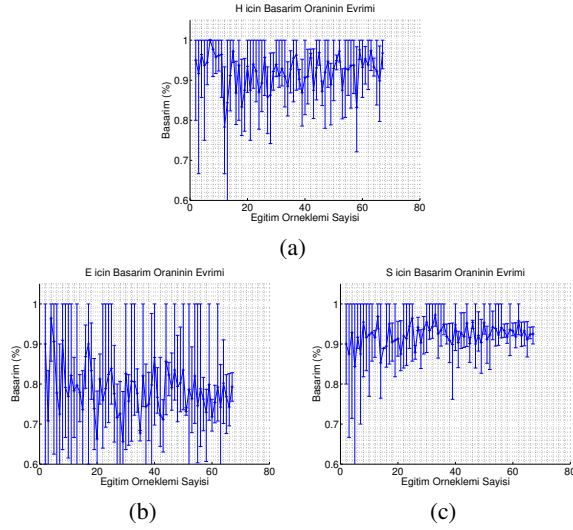
Deneme başarımları ise sınıflandırıcının yeni örneklemlerle karşılaştığında gösterdiği başarımları ifade eder. Deneme başarımlarını incelerken, sınıflandırıcı belli sayıda eğitim örneklemleri ile eğitilir ve ardından, kümelere bunlar dışında kalan örneklemlerle denenir. Burada, eğitim örneklemleri sayısı belli bir değeri aştıktan sonra, başarımların bir değer etrafına oturması beklenmektedir. Sınıflandırıcının tüm sınıfların özelliklerini kavraması için hangi büyüklükte bir eğitim kümesinin yeterli olduğunu bu şekilde görebiliriz.

## 4. Başarım

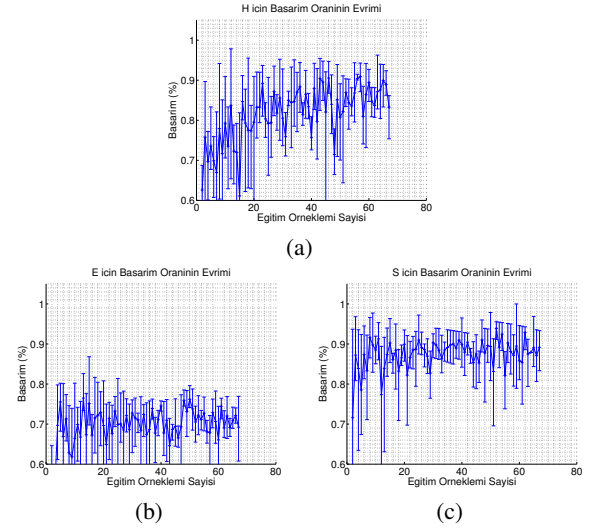
Eğitim ve deneme başarımları yukarıda tanımlanan karşılıklı ilinti metoduna göre hesaplanmış ve Şekil 4 ve 5'de sunulmuştur. Bu şekillerde yer alan kesiksiz çizgi yatay eksende gösterilen örneklem sayısı kullanılarak dört kez eğitim yapılmışla bulunan başarımların ortalamasını göstermektedir. Ayrıca her örneklem sayısı için bu dört deney içinde en iyi ve en kötü sonuçları veren deneylerin başarımları da dikey çizgilerle ifade edilmiştir. Şekil 4'de de görüldüğü gibi, eğitim örneklemleri sayısı 10'u geçtikten sonra, sınıflandırma başarımları  $H$  kümesi için 90% civarında,  $E$  için 80% civarında ve  $S$  kümesi için de 94%'in üzerindedir. Şekil 5'de görüldüğü gibi, eğitim örneklemleri sayısı 10'u geçtikten sonra, deneme başarımları  $H$  kümesi için 84%'ün üzerinde,  $E$  kümesi için 72% ve  $S$  kümesi içinse 90%'nın civarındadır.

## 5. Sonuç

Bu çalışmada EEG işaretinin değişik çözünürlük derecelerindeki kaotik özelliklerinin sara hastalığı bakımından farklı özellikler sergilediği gösterilmiştir. Bu özelliklerin sara krizinin tesbit edilmesinde ve hasta ve sağlıklı kişilerin EEG kayıtlarının ayırımında kullanılabileceği kanıtlanmıştır. Önerdiğimiz özellik vektörleri ile sınıfların 5%-10% arası bir kısmının eğitim için kullanılmasının, sara krizinin tesbit edilmesinde 90%, hasta ve sağlıklı kişilerin ayırımında ise 70%'in üzerinde deneme başarımları elde edilmesine yettiği gösterilmiştir. Bildiğimiz kadarıyla bu çalışma ile ilk defa, bu veri tabanının tümü kullanılarak bu türden bir sınıflandırma problemi kapsamlı olarak ele alınmıştır.



Şekil 4: (a)  $H$ , (b)  $E$ , (c)  $S$  için eğitim başarımının evrimi



Şekil 5: (a)  $H$ , (b)  $E$ , (c)  $S$  için deneme başarımının evrimi

## 6. Kaynakça

- [1] Adeli, H.; Ghosh-Dastidar, S.; Dadmehr, N., "A Wavelet-Chaos Methodology for Analysis of EEGs and EEG Subbands to Detect Seizure and Epilepsy", *IEEE Transactions on Biomedical Engineering*, Volume 54, Issue 2, Feb. 2007 Page(s) 205 - 211
- [2] Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., 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", *Physical Review E*, Volume 64, 2001
- [3] D'Alessandro, M., Esteller, R., Vachtsevanos, G., Hinson, A., Echauz, J., Litt, B., "Epileptic seizure prediction using hybrid feature selection over multiple intracranial EEG electrode contacts: a report of four patients", *IEEE Transactions on Biomedical Engineering*, Volume 50, Issue 8, Aug. 2003 Page(s) 1041 - 1041
- [4] Bianchi, A.M., Panzica, F., Tinello, F., Franceschetti, S., Cerutti, S., Baselli, G., "Analysis of multichannel EEG synchronization before and during generalized epileptic seizures", *Proceedings of First International IEEE EMBS Conference on Neural Engineering*, 20-22 March 2003, Page(s) 39 - 42
- [5] Cao, L., "Practical Methods for Determining The Minimum Embedding Dimension of a Scalar Time Series". *Physica D*, 1997, Page(s) 43-50.
- [6] Grassberger, P., Procaccia, I., "Characterization of Strange Attractors", *Physical Review Letters*, Volume 50, Number 5, 31 January 1983. Page(s) 346-349
- [7] Güler, I., Kiyimik, M.K., Akin, M., Alkan A., "AR Spectral Analysis of EEG Signals by Using Maximum Likelihood Estimation", *Computers in Biology and Medicine*, Volume 31; 2001, Page(s) 441-450.
- [8] Gysels, E., Le Van Quyen, M., Martinerie, J., Boon, P., Vonck, K., Lemahieu, I., Van De Walle, R., "Long-term evaluation of synchronization between scalp EEG signals in partial epilepsy", *Proceedings of the 9<sup>th</sup> International Conference on Neural Information Processing, 2002. ICONIP '02.*, Volume 3, 18-22 Nov. 2002 Page(s) 1495 - 1498
- [9] Jahankhani, P., Revett, K., Kodogiannis, V., "Data Mining an EEG Dataset with an Emphasis on Dimensionality Reduction", *IEEE Symposium on Computational Intelligence and Data Mining, 2007, CIDM 2007*, March 1 2007-April 5 2007 Page(s):405 - 412
- [10] James, C.J., Lowe, D., "Using independent component analysis & dynamical embedding to isolate seizure activity in the EEG", *Proceedings of the 22<sup>nd</sup> Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2000*, Volume 2, 23-28 July 2000, Page(s)1329 - 1332
- [11] Junling, Z., Dazong, J., "A linear epileptic seizure predictor based on slow waves of scalp EEGs", *27<sup>th</sup> Annual International Conference of the Engineering in Medicine and Biology Society, 2005, IEEE-EMBS 2005*, 01-04 Sept. 2005, Page(s) 7277 - 7280
- [12] Lehnertz, K., "Seizure prediction techniques: robustness and performance issues", *Proceedings of the Second Joint EMBS/BMES Conference, 2002*, Volume 3, 23-26 Oct. 2002, Page(s) 2037 - 2038
- [13] Niederhoefer, C., Tetzlaff, R., "Prediction Error Profiles allowing a Seizure Forecasting in Epilepsy? ", *10<sup>th</sup> International Workshop on Cellular Neural Networks and Their Applications, 2006. CNNA '06*, 28-30 Aug. 2006 Page(s) 1 - 6
- [14] Srinivasan, V., Eswaran, C., Sriraam, N., "Approximate Entropy-Based Epileptic EEG Detection Using Artificial Neural Networks", *IEEE Transactions on Information Technology in Biomedicine*, Volume 11, Issue 3, May 2007 Page(s) 288 - 295