

Epiliktik EEG iřaretlerin ařırı öğrenme makineleri ile sınıflandırılması

Necmettin SEZGİN^{*,1}

¹ Batman Üniversitesi, Elektrik ve Elektronik Mühendislięi Bölümü, Batman

Makale Gönderme Tarihi: 24.03.2016

Makale Kabul Tarihi: 16.05.2016

Öz

Bu çalışmada Epilepsi tanısı konulmuş hastalardan alınan EEG iřaretleri, nöbet öncesi, nöbet anı ve nöbet sonrası olarak sınıflandırılmıştır. EEG iřaretleri lineer ve duraęan olmayan iřaretler olup beynin elektriksel aktivitelerini gösterirler. Nörolojik anormallerde EEG iřaretlerin alt bantlarında normal durumdan farklı olarak belirgin deęişimler gözlemlenmekte ve bu deęişimler nörolojik hastalıkların belirtisi olmaktadır. Epilepsi gibi nörolojik hastalıklarda EEG iřaretleri içerisindeki bantlarda normal durumdan farklı olarak bir faz senkronizasyonu ortaya çıkmaktadır. Bu faz eřleşmelerini yüksek dereceden spektral analizi tekniklerinden olan ikiz spektrum analizi ile ortaya çıkararak EEG iřareti içerisinde özellikler elde edilebilmektedir. Elde edilen bu özelliklerin bir sınıflandırıcının girişine verilmesi ile epileptik EEG iřaretleri sınıflandırılmaktadır. Çalışmada hızlı ve yüksek doğruluk sağlanması açısından sınıflandırıcı olarak ařırı öğrenme makineleri kullanılmıştır. Kullanılan bu yöntem ile %98,60 gibi yüksek bir doğrulukla sınıflandırma gerçekleştirilmiştir. Bu çalışmanın nörologlara epilepsi tanısında yardımcı olacağı düşünülmektedir.

Anahtar Kelimeler: EEG; ikiz spektrum analizi; ikiz uyumluluk; ařırı öğrenme makinesi; epilepsi

*Yazışmaların yapılacağı yazar: Necmettin SEZGİN. necmettinsezgin@gmail.com; Tel: (488) 217 41 41

Giriş

Epilepsi veya diğer adıyla sara, bir bölgedeki beyin sinir hücrelerinin anormal bir şekilde deşarj olmalarıyla kendini gösteren nörolojik bir hastalıktır. Epilepsi hastalarında nöbet geçirme sıklığı ve şiddeti hastadan hastaya farklılık göstermektedir. Nörologlar tarafından hastalık şiddetinin belirlenmesi ve ona göre tedavi yönteminin uygulanması son derece önemlidir. EEG gibi biyomedikal işaretler durağan, lineer ve Gauss formlarında olmayan işaretler olarak kabul görülmüştür (Chua vd., 2010). Bu tür işaretlerin analizinde yüksek dereceli spektral analizinin uygulanması işaret içerisindeki spektral bilginin yanı sıra fazsal bir takım önemli bilgileri ortaya çıkarma açısından güç spektrum analizine göre daha avantajlı olduğu ortaya konmuştur (Chua vd., 2010). Yüksek dereceli analiz metodlarından biri olan ikiz spektrum analizi işaretin bileşenleri arasındaki karesel faz eşleşmeleri (QPC – Quadratic phase coupling) yani fazsal ilintileri ortaya çıkarmak için başarılı bir metottur. İkiz spektrum analizi deniz bilimi problemlerin çözümünde (Hasselmann vd., 1963), örtüntü tanımda (Chandran ve Elgar 1991; Chandran ve Elgar, 1993; Chandran vd., 1997), kaotik işaret karakteristiğini ortaya çıkarmada (Chandran vd., 1993), EKG (Khadra vd., 2005) ve EEG (Muthuswamy vd., 1999) gibi biyolojik işaretlerin gizemini açığa çıkarmada ve bunlara benzer alanlarda başarılı bir şekilde uygulanmıştır.

Bu çalışmada da epileptik EEG işaretlerinin bileşenleri arasındaki fazsal ilintileri ortaya çıkararak epilepsi hastalığını teşhis etmek, nöbet öncesi ile sonrasında beyinde meydana gelen fazsal dinamiklik hakkında bilgi edinmek için ikiz spektrum analizi kullanılmıştır. İkiz spektrum analizi sonucu elde edilen spektrum normalize edilerek ikiz uyumluluğu hesaplanmıştır. Analiz sonucu EEG işaretinin bileşenleri arasında ortaya çıkan faz ilintilerinin bir ölçüsü olarak EEG alt bantlarındaki QPC değerleri hesaplanmış ve nöbet öncesi, nöbet anı ve nöbet sonrası QPC miktarları belirlenmiştir. 8 hastaya ait her alt bantta elde edilen QPC

değerleri ile aşırı öğrenme makinesi (ELM) eğitilerek test edildi. Test sonucunda EEG işaretlerinin %98.60 doğrulukta nöbet öncesi, nöbet anı ve nöbet sonrası şeklinde birbirinden ayırt edilebildiği görülmüştür. Karşılaştırma amacıyla yapay sinir ağı (ANN) ve destek vektör makineleri (SVM) ile de aynı veriler test edilmiştir. Yapılan test sonuçlarında; ANN ve SVM için sırasıyla %95.33 ve %91.25 doğrulukta sonuçlar elde edilmiştir.

Materyal ve Yöntem

Verilerin Toplanması

Çalışmada kullanılan veriler İnönü Üniversitesi Tıp Fakültesi Nöroloji Ana Bilim Dalının arşivinden alınmıştır. Veriler 2001-2009 yılları arasında yaşları 25 ile 45 arasında olan ve ortalama 35 yaşa sahip 5 erkek ve 3 kadın olmak üzere toplam 8 yetişkin hastadan kayıt edilmiştir. Ölçümler standart 10/20 sayısal EEG kayıt sistemiyle 16 kanaldan yüzey elektrotlar ile yapılmıştır. Veriler 200 Hz örnekleme frekansıyla kayıt edilmiştir.

İkiz Spektrum Analizi

İki farklı frekanstaki işaretin ya da bir işaretin farklı frekanslara sahip bileşenleri arasında ister doğrusal olsun ister olmasın herhangi bir fazsal ilinti varsa, ikiz spektrum bu ilintiyi ortaya çıkarıp sergilemek için geliştirilen istatistiksel bir işaret işleme yöntemidir (Sigl ve Chamoun, 1994; Hinich ve Clay, 1968; Nikias ve Petropulu, 1993). Beyin gibi durağan ve de doğrusal olmayan, karmaşık sistemlerin dinamiği ya da ürettiği işaretlerin bileşenleri arasında olası ikinci dereceden faz eşleşmelerini (QPC – quadratic phase coupling) ortaya çıkarmak için ikiz spektrum kullanılmıştır (Sezgin vd., 2010). Bu çalışmada da deneklerden alınan epileptik EEG işaretlerinin bileşenleri arasındaki fazsal ilişkileri ortaya çıkarmak için ikiz-spektrum kullanıldı.

İkiz spektrum, türevlenebilir bir sistem dinamiğinin üçüncü derece kümülanın Fourier dönüşümü olarak tanımlanmıştır (Ning ve Bronzino, 1989). Herhangi bir durağan reel değerli ayrık rastsal $x(k)$ sürecinin r . derece momenti,

$$m_r^x(n_1, n_2, \dots, n_{r-1}) = E\{x(k)x(k + n_1) \dots x(k + n_{r-1})\} \quad (1)$$

şeklinde ifade edilebilir (Raghuveer ve Nikias, 1985). Burada E beklenti değeri anlamına gelmektedir. Genel anlamda $x(k)$ nın 1., 2. ve 3. kümülanlı momentler serisi cinsinden sırasıyla:

$$C_1^x = m_1^x = E\{x(k)\} \quad (2)$$

$$C_2^x(n_1) = m_2^x(n_1) - (m_1^x)^2 \quad (3)$$

$$C_3^x(n_1, n_2) = m_3^x(n_1, n_2) - m_1^x[m_2^x(n_1) + m_2^x(n_2) + (n_2 - n_1)](m_1^x)^3 \quad (4)$$

şeklinde ifade edilirler. Gauss olmayan reel değerli durağan ve sıfır ortalamaya sahip bir ayrık $x(k)$ sürecinin 3. derece kümülanı,

$$C_3^x(n_1, n_2) = Cum\{x(k), x(k + n_1), x(k + n_2)\} \quad (5)$$

veya

$$C_3^x(n_1, n_2) = E\{x(k)x(k + n_1)x(k + n_2)\} \quad (6)$$

şeklinde ifade edilir (Nikias ve Petropulu, 1993). Buna göre 3. derece kümülan fonksiyonun spektrumu veya ikiz spektrumu,

$$B(\omega_1, \omega_2) = \sum_{n_1=-\infty}^{\infty} \sum_{n_2=-\infty}^{\infty} C_{3x}(n_1, n_2)W(n_1, n_2)e^{-j(\omega_1 n_1 + \omega_2 n_2)}, \quad (7)$$

$$|\omega_1|, |\omega_2| \leq \pi$$

şeklinde ifade edilir (Ning ve Bronzino, 1989). Burada $W(n_1, n_2)$, ikiz spektrumun değişkenliğini azaltmak için iki boyutlu pencere fonksiyonudur. Çalışmada ikiz-spektrum hesabı için 0.2 saniye aralığında Hanning penceresi kullanıldı. Denklem 7, $x(k)$ 'nin ω_1 ve ω_2 frekansları bazında elde edilen spektrumları cinsinden aşağıdaki gibi de ifade edilebilir;

$$B(\omega_1, \omega_2) = E\{X(\omega_1)X(\omega_2)X^*(\omega_1 + \omega_2)\} \quad (8)$$

Denklemdaki * işareti kompleks eşleniği belirtmektedir. İkiz-spektrumun simetri özelliğinden dolayı üzerinde çalışılan EEG işaretine ait bütün ikiz-spektrum bilgisi

$0 \leq \omega_2 \leq \omega_1$ ve $\omega_1, \omega_2 \leq \pi$ tanımlı üçgensel bölgede yoğunlaşmaktadır. Fazları ikinci dereceden eşleşen bileşenler sürecin üçüncü derece kümülanına söz konusu bölgede QPC şeklinde katkı sağlar ve böylece işaret hakkında ekstra bilgi sunar (Raghuveer ve Nikias, 1985). İkiz-spektrum, $B(\omega_1, \omega_2)$ düzlemindeki diğer bölgeler tanımlı üçgenin simetrisi olarak ortaya çıkmaktadır.

İkiz uyumluluk ikiz spektrumun normalizasyonu olarak ifade edilir. İkiz uyumluluk tek bir zaman işaretinden hesaplanan ağırlıklandırma değildir. Tek boyutlu uyumluluk fonksiyonu, bir sitemin giriş ile çıkışı arasındaki sapma miktarını hesaplar, ikiz uyumluluk fonksiyonu buna karşın eşleşmiş ikili fazların sahip olduğu işaret enerji oranlarını hesaplamaktadır. İkiz uyumluluk Huber ve diğerleri (1971) tarafından şu şekilde tanımlanmıştır,

$$b(\omega_1, \omega_2) = \frac{B(\omega_1, \omega_2)}{\sqrt{P(\omega_1)P(\omega_2)P(\omega_1 + \omega_2)}} \quad (9)$$

burada $B(\omega_1, \omega_2)$ ve $P(\omega)$ sırasıyla işaretin ikiz spektrum ve güç spektrumunu ifade etmektedir. Faz eşleşmelerine bağlı ortaya çıkan QPC miktarını hesaplamak için Ning ve Bronzino (1989) tarafından önerilen ve ikiz uyumluluk hesabında kullanılan ifade şu şekilde tanımlanmıştır,

$$D = \sum_{(\omega_1, \omega_2)} |b(\omega_1, \omega_2)|; \quad \omega_1 \neq \omega_2 \quad (10)$$

EEG işaretinin sahip olduğu farklı frekanslardaki bantlar şu şekildedir.

Delta(δ) 0.5-4 Hz,	$0.5 \text{ Hz} < (f_1, f_2) < 4 \text{ Hz}$
Teta(θ) 4-8 Hz,	$4 \text{ Hz} < (f_1, f_2) < 8 \text{ Hz}$
Alfa(α) 8-13 Hz,	$8 \text{ Hz} < (f_1, f_2) < 13 \text{ Hz}$
Beta(β) 13-32 Hz,	$13 \text{ Hz} < (f_1, f_2) < 32 \text{ Hz}$
Gama(γ) 32-64 Hz,	$32 \text{ Hz} < (f_1, f_2) < 64 \text{ Hz}$

Her bir EEG alt bant için $\omega_1 \neq \omega_2$ frekanslardaki faz eşleşmelerine bağlı ikiz uyumlulukların toplam değeri Denklem 10'a göre hesaplanmakta ve ELM'nin girişine verilerek EEG işaretleri epilepsi öncesi, epilepsi anı ve epilepsi sonrası şeklinde sınıflandırılmaktadır.

Aşırı Öğrenme Makinesi

Aşırı Öğrenme Makinesi (ELM) tek bir gizli katmana sahip ileri yönlü beslemeli sinir ağıdır. Gizli katmanın giriş ağırlıkları rastgele seçilmekte ve çıkış ağırlıkları analitiksel olarak hesaplanmaktadır. Gizli katmanda Sigmoid, sinus ve Gauss gibi aktivasyon fonksiyonları kullanılırken, çıkış katmanında doğrusal aktivasyon fonksiyonları kullanılmaktadır. İleri yönlü beslemeli sinir ağının giriş katmanındaki ağırlıklar tek gizli katmana sahip ağıın performansını etkilememektedir (Huang vd., 2006; Ertuğrul ve Kaya 2014; Kaya vd., 2014). Bir ELM ağında diyelim ki \mathbf{x}_k giriş ve \mathbf{o}_k da ağıın çıkışı olsun. Tek bir gizli katmana sahip ve gizli katmandaki düğüm sayısı M olan ağıın çıkışının matematiksel ifadesi şu şekilde tanımlanmıştır (Suresh vd., 2010),


$$\sum_{j=1}^M \beta_j g(\mathbf{w}_j \mathbf{x}_k + b_j) = \mathbf{o}_k, \quad k=1,2,3,\dots,N \quad (11)$$

Burada \mathbf{w}_i giriş ile gizli katman arasındaki ağırlıklar, b_i girişe etki eden bias değerleridir. β_i değerleri gizli katman ile çıkış arasındaki ağırlıklar ve $g(.)$ aktivasyon fonksiyonudur (Huang vd., 2006). ELM hakkında daha detaylı bilgi Huang ve diğerleri (2006) çalışmasında bulunabilir.

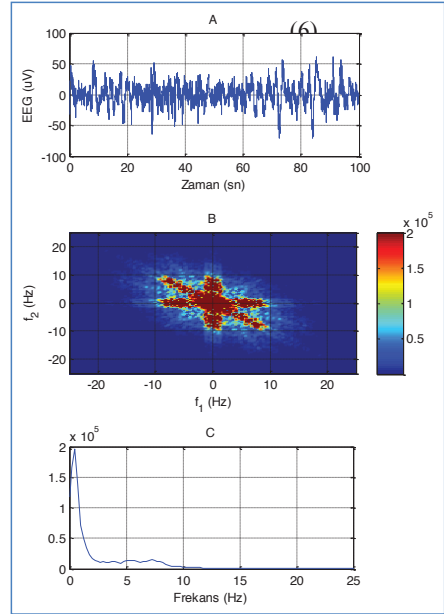
Uygulama ve başarımlar

Çalışmada sekiz yetişkin insan EEG işareti incelemek için ele alınmıştır. Epileptik EEG verilerinin ikiz spektrumu yukarıda açıklandığı gibi hesaplanarak bileşenler arasındaki faz ilintileri ortaya çıkarılmıştır. Çalışmada kullanılan bir hastaya ait epileptik EEG işareti Şekil 1'de gösterilmiştir. Hasta 3850. saniyeden sonra bir nöbet geçirmekte ve nöbet sonrası bir süre geçene kadar EEG işaretinde belirgin değişimler gözlemlenmektedir. Aynı hastanın EEG verisinden epilepsi öncesi, epilepsi anı ve epilepsi sonrası EEG işaretinin kendisi, ikiz-spektrumu ve ikiz spektrumunun iki boyutlu olarak gösterimi sırasıyla Şekil 2, Şekil 3 ve Şekil 4'te gösterilmiştir. EEG işareti ve her banttaki QPC zaman serisini hesaplamak için işaretin 10 saniyelik veri parçaları, diğer bir ifade ile kısa süreli 2000'er veri noktası ardışık

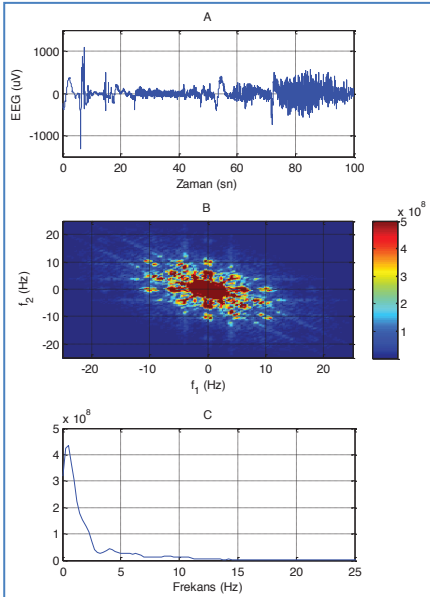
olarak ele alınmış ve hesaplamalar buna göre yapılmıştır.



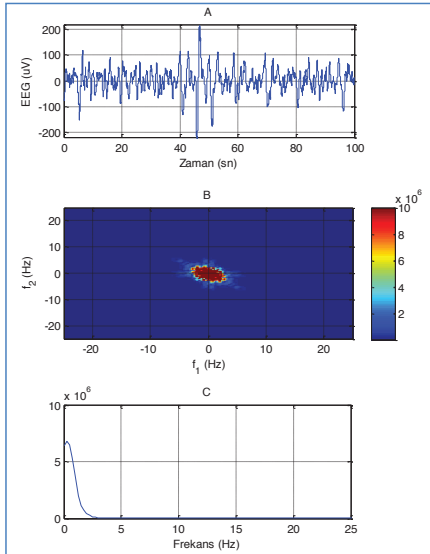
Şekil 1. Yetişkin bir hastaya ait epileptik EEG işaretinin gösterimi



Şekil 2. Epilepsi öncesi; a) EEG işareti, b) ikiz spektrumu, c) iki boyutlu ikiz spektrumu



Şekil 3. Epilepsi anı; a) EEG işareti, b) ikiz spektrumu, c) iki boyutlu ikiz spektrumu



Şekil 4. Epilepsi sonrası; a) EEG işareti, b) ikiz spektrumu, c) iki boyutlu ikiz spektrumu

Şekillerden de anlaşıldığı üzere epilepsi anında (Şekil 3) düşük frekanslı alt bantlarda QPC miktarı yani faz eşleşme durumları daha fazla olduğu görülmektedir ki bu durum düşük frekanslarda Gauss dağılımına sahip olmayan bileşenlerin işarete hakim olduğu anlamına gelmektedir. QPC miktarının yüksekliği EEG işaretinin ilgili bölgesinde lineer ve Gauss olmayan bileşenlerin oranının büyüklüğünü ifade etmektedir. Bütün şekiller birlikte değerlendirildiğinde epilepsi öncesi (Şekil 2) EEG işareti içerisinde epilepsi anı (Şekil 3) ve sonrasına (Şekil 4) göre daha az sayıda lineer olmayan faz eşleşmeleri kendini gösterirken epilepsi anında çok daha fazla fazsal ilinti ortaya çıkmıştır. Ayrıca epilepsi sonrası QPC değerleri epilepsi öncesine göre daha yüksek çıkarak, bu da epilepsi sonrası beyin içerisindeki dinamiklerin bir süre devam ettiğini göstermektedir.

Çalışmadaki bütün hastalar için epileptik EEG işaretlerin alt bantların sahip olduğu QPC miktarları hesaplanarak Tablo 1’de verilmiştir. Görüldüğü gibi tüm hastalar için durum aynıdır; epilepsi anında iken epilepsi öncesi ve sonrasına göre EEG işareti bileşenleri arasında daha fazla faz ilişkisi oluşmaktadır. Bu QPC yoğunluğu özellikle delta alt bandında kendini göstermektedir. Yapılan deneysel çalışmalarla bu QPC yoğunluğunun epilepsi nöbetinin ağırlık derecesi ile orantılı olduğu görülmüştür. Epilepsi nöbeti anında yüksek QPC miktarının ortaya çıkması beyin içindeki bilgi işleme sürecinin azaldığı ve buna karşın hücre deşarjları arasında ve dolayısıyla işaret bileşenleri arasında senkronizasyonun arttığı anlamına gelmektedir.

Tablo 1. Sekiz epilepsi hatasının nöbet öncesi, anı ve sonrasındaki her alt bantta ortaya çıkan QPC miktarlarının ortalama ve standart sapması (SS)

EEG alt bant	Epilepsi öncesi (ortalama±SS) x10 ⁵	Epilepsi anında (ortalama ±SS) x10 ⁸	Epilepsi sonrası (ortalama ±SS) x10 ⁶
Delta (δ)	260.44 ± 61.20	450.89 ± 25.12	346.00 ± 28.15
Teta (θ)	3.65 ± 0.50	15.50 ± 4.12	8.55 ± 2.25
Alfa (α)	0.56 ± 0.12	3.75 ± 0.54	2.20 ± 0.32
Beta (β)	0.15 ± 0.06	0.45 ± 0.38	1.62 ± 0.70
Gama (γ)	0.014 ± 0.02	0.082 ± 0.08	0.06 ± 0.01

Toplam sekiz hastaya ait 10 ar saniyelik bölütler 400 bölüt epilepsi öncesi, 400 bölüt epilepsi sonrası ve 400 bölüt epilepsi anı için sınıflandırıcıların eğitim ve test aşamalarında kullanılmıştır. Eğitim/test oranı %50-%50 şeklinde kullanılarak ANN, SVM ve ELM eğitilerek test edildi. Her bir EEG bölütü içerisindeki alt bantın sahip olduğu QPC enerjisi ile epilepsi öncesi, epilepsi sonrası ve epilepsi anı için ayrı ayrı 5X400 boyutunda bir özellik matrisi oluşturulmuştur. ELM' de 5 giriş hücrelerine sahip bir giriş katmanı, 25 hücreye sahip bir gizli katman ve 3 hücreye sahip bir çıkış katmanı ile mimari oluşturulmuştur. Hücrelerde Sigmoid aktivasyon fonksiyonu kullanılmıştır. ANN ile en iyi sonuç 5-10-12-3 mimarisine sahip ağ ile elde edilmiştir. Burada giriş katmanı 5 hücreden, her katmanda 10 ve 12 hücre ile iki tane gizli katman ve 3 hücreden

oluşan bir çıkış katmanından oluşmaktadır. Bu sınıflandırıcıda geri yayımlı algoritma kullanılmıştır. Gizli katmanlarda ve çıkış katmanında Sigmoid dönüşüm fonksiyonu kullanılmıştır. Gerek ELM ve ANN mimarilerindeki gizli katman hücre sayısı, gerekse de bu mimarilerde kullanılan aktivasyon fonksiyonları deneme yanılma yoluyla tespit edilmişlerdir. SVM sınıflandırıcısı için doğrusal çekirdek fonksiyonu kullanılmıştır. Çalışmada kullanılan öğrenme makineleri Matlab programı ile gerçekleştirilmiştir. Sınıflandırıcıların test işaretlerine verdikleri başarımları Tablo 2'de gösterilmektedir. Tablo 2'den de görüldüğü gibi ELM sınıflandırıcısı ANN ve SVM sınıflandırıcılara göre hem daha hızlı hem de daha yüksek doğrulukta kestirim yapabilmektedir.

Tablo 2. ANN, SVM ve ELM sınıflandırıcıların performansları

Sınıflandırıcı	Eğitim işlem süresi (sn)	Test işlem süresi (sn)	Test verileri için doğruluk (%)
ANN	58.44	2.87	95.33
SVM	3.50	0.33	91.25
ELM	0.12	0.02	98.60

Sonuçlar ve Tartışma

Bu çalışmada epileptik EEG işaretlerinin ikiz spektrum analizi yapılarak işaretin bileşenleri arasında olası faz eşleşme veya ikiz uyumluluğun bir ölçüsü olarak QPC bulunma durumu araştırılmıştır. Elde edilen sonuçlardan epileptik EEG işaretinin epilepsi öncesi, epilepsi anında ve epilepsi sonrası lineer ve Gauss

olmama durumuna bağlı olarak QPC miktarları belirlenmiştir. Epileptik EEG işaretinin delta, teta, alfa, beta ve gama alt bantlarındaki olası ikiz uyumluluklarına bağlı olarak faz ilişkileri hesaplanarak Tablo 1'de gösterilmiştir. Tablo 1'den anlaşıldığı üzere epilepsi anında beyin içerisinde bilgi işleme sürecinin bir belirtisi olan karmaşıklık azalmış ve buna karşılık lineer ve Gauss olmayan bileşenlerin arasındaki QPC

oranı epilepsi öncesine göre oldukça arttığı gözlemlenmiştir. EEG alt bantları ayrı ayrı dikkate alındığında düşük frekanslarda QPC oranının yüksek frekanslara nazaran arttığı görülmektedir. Epilepsi sonrası QPC değeri, epilepsi anına göre düşük fakat epilepsi öncesine göre daha yüksek olduğu da Tablo 1'den anlaşılmaktadır. Bu da epilepsi nöbeti sonrası beyin dinamiğinin epilepsi öncesine göre daha senkronize olduğunu göstermektedir ki bu durum beyin normale dönüşüncüye kadar QPC oranı azalarak devam etmekte olduğu anlaşılmaktadır.

Çalışmada kullanılan sekiz hastaya ait epileptik EEG işaretlerinden epilepsi öncesi, epilepsi anı ve epilepsi sonrasında ait 400'er adet bölüt tasarlanan ANN, SVM ve ELM sınıflandırıcıların eğitim ve test aşamalarında kullanılarak EEG işareti sınıflandırılmıştır. ELM ile yapılan sınıflandırma işleminin ANN ve SVM'ye göre çok daha hızlı olduğu görülmüştür. Ayrıca ELM'nin %98.60 ile ANN ve SVM'ye göre daha yüksek doğrulukta sınıflandırma yaptığı ortaya konulmuştur.

Yapılan bu çalışma ile elde edilen sonuçların nöroloji biliminde faydalı olacağı ve nörolog hekimin epilepsi derecesini ölçmeye ve teşhis etmeye yönelik katkı yapacağı düşünülmektedir. Bu şekilde yapılan bir teşhisin neticesi hastaya özgü daha etkili tedavi yöntemlerinin geliştirilmesine olanak sağlayacağı düşünülmektedir.

Kaynaklar

- Chandran, V., Elgar, S.L., (1991). Mean and variance of estimates of the bispectrum of a harmonic random process—an analysis including leakage effects, IEEE Trans. on Signal Processing, 39, 2640– 51.
- Chandran, V., Elgar, S.L., (1993). “Pattern recognition using invariants defined from higher order spectra—1-D inputs”, IEEE Transactions on Signal Processing, 41, 205–11.
- Chandran, V., Carswell, B., Boashash, B., Elgar, S.L., (1997). “Pattern recognition using invariants defined from higher order spectra: 2-D image inputs”, IEEE Trans. Image Processing, 6, 5, 703–12.
- Chandran V, Elgar SL, Pezeshki C., (1993). “Bispectral and trispectral characterization of transition to chaos in the duffing oscillator”, Int. Journal of Bifurcation and Chaos, 3, 3, 551–7.
- Chua, K.C., Chandran, V., Acharya, U.R., Lim, V.M., (2010) “Application of higher order statistics / spectra in biomedical signals”, Medical Eng. & Physics, 32, 679–689.
- Ertuğrul, Ö.F., Kaya, Y., (2014). “A detailed analysis on extreme learning machine and novel approaches based on ELM”, American J. of Computer Science and Eng. 1, 5, 43-50.
- Hasselmann, K., Munk, W., MacDonald, G., (1963). “Bispectra of ocean waves”, In: Rosenblatt M, editor. Time series analysis. New York: Wiley, 125–39.
- Hinich, M.J. ve Clay, C.S., (1968). “The application of the discrete Fourier transform in the estimation of power spectra, coherence and bispectra of geophysical data”, Reviews of Geophysics, 6, 3, 347-363.
- Huang, G.B., Zhu, Q.Y. & Siew, C.K., (2006). “Extreme learning machine: theory and applications”, Neurocomputing, 70, 1-3, 489-501.
- Huber, P. J., Kleiner, B., Gasser, T. & Dumermuth, G., (1971). “Statistical methods for investigating phase relations in stationary stochastic processes”, IEEE Trans. on Audio Electroacoust, 78– 86.
- Kaya, Y., Ertuğrul, Ö.F. ve Tekin, R., (2014). “An Expert Spam Detection System Based on Extreme Learning Machine”, Computer Science and Applications, 1, 2, 133- 138.
- Khadra, L., Al-Fahoum, A.S., Binajjaj, S., (2005). “A quantitative analysis approach for cardiac arrhythmia classification using higher order spectral techniques”, IEEE Transactions on Biomedical Engineering, 52, 11, 1840–5.
- Muthuswamy J, Sherman D, Thakor NV., (1999). “Higher order spectral analysis of EEG burst patterns during asphyxia injury”, IEEE Trans. on Biomedical Engineering, 46, 1, 92–9.
- Nikias, C.L. ve Petropulu, A.P., (1993). “Higher order spectral analysis: A nonlinear signal processing framework”, Englewood Cliffs, NJ: Prentice-Hall.
- Ning, T. ve Bronzino, J.D., (1989). “Bispectral analysis of the rat EEG during various vigilance states”, IEEE Trans Biomed Eng, 36, 4, 497-499.

- Raghuveer, M.R. ve Nikias, C.L., (1985). "Bispectrum estimation: A parametric approach", IEEE Trans. Acoust., Speech, Signal Processing, 33, 4, 1113-1230.
- Sezgin, N., Tagluk, M.E., Akin, M., (2010). "Using bispectral analysis in OSAS estimation". IEEE 18th Signal Processing and Communications Applications Conference, 89 – 92, 22-24 April, Diyarbakir.
- Sigl, J.C. ve Chamoun, N.G., (1994). "An introduction of bispectral analysis for the electroencephalogram", Journal of Clinical Monitoring, 10, 6, 392-404.
- Suresh, S., Saraswathi, S. & Sundararajan, N., (2010). "Performance enhancement of extreme learning machine for multi-category sparse data classification problems", Eng Applications of Artificial Intelligence, 23, 1149-1157, 2010.

Classification of Epileptic EEG Signals by Extreme Learning Machines

Extended Abstract

In this study, the EEG signals obtained from patients that diagnosed with epilepsy seizure, were classified as before, during and after seizures. EEG signals are the non-linear and non-stationary signals that indicate the electrical activity of the brain. Different from normal situation of the brain, in the abnormal neurological, changes are significantly different in the sub-band of EEG signals, and these changes are signs of neurological disease. Since epilepsy starts the dynamic in the brain changes while the nonlinearity and non-Gaussianity increases in the EEG signal. So, the phase synchronization arises during seizure. During this phase match the features of the EEG signals can be obtained by using bispectrum analysis which is one of the higher order spectral analysis techniques. Bicoherence, as the normalized version of the bispectrum, of EEG signals obtained from eight patients were determined, and quadratic phase coupling (QPC) identified. These features, which is obtained by epileptic EEG signals were fed to the input of the classifier. In terms of providing fast and high accuracy for classification of the EEG signal, the extreme learning machine (ELM) was used. The ELM is a single hidden layer feed-forward neural network. For comparison the artificial neural network (ANN) and support vector machine (SVM) classifiers were also used.

In the study, it was shown that the QPCs in the EEG signal increased during epilepsy compared with before epilepsy. This result shows that the complexity and non-Gaussianity increase during epilepsy seizure. By considering the sub-bands of EEG separately, during epilepsy, the ratio of QPC has increased in the low frequency compared to high frequency. In the study it was also shown that the QPC after epilepsy is higher than before epilepsy, however, the QPC after epilepsy is lower than during epilepsy. This suggests that the brain dynamic after epilepsy seizure is more synchronous than before epilepsy seizure. This situation is going on until brain activities became normal.

In the study 8 patient's EEG that were diagnosed with seizure were used. 400 episodes of each pre epilepsy, during epilepsy and after epilepsy were obtained from whole data. A train/test data rate of 50%-50% was used in the classifiers. The test results show that the ELM has higher accuracy than ANN and SVM as shown in the Table 2. By using ELM a high classification accuracy of 98.60% was obtained. For ANN and SVM the test results of %95.33 and %91.25 obtained respectively. Furthermore, it was also shown that the ELM is much faster than ANN and SVM classifiers. This study is thought to help neurologists in the diagnosis of epilepsy.

Keywords: EEG, bispectrum analysis, bicoherence, extreme learning machine, Epilepsy