

EŞİT GENİŞLİKLİ AYRIKLAŞTIRMA YÖNTEMİNE DAYALI YENİ BİR ÖZELLİK ÇIKARTMA YAKLAŞIMI VE YAPAY SİNİR AĞI KULLANARAK EPİLEPTİK ATAK TESPİTİ

Umut ORHAN*, **Mahmut HEKİM*** ve **Mahmut ÖZER****

*Elektronik-Bilgisayar, Tokat MYO, Gaziosmanpaşa Üniversitesi, 60250 Tokat

**Elektrik-Elektronik Mühendisliği, Zonguldak Karaelmas Üniversitesi, 67100 Zonguldak

umutorhan@hotmail.com, mhekim@gop.edu.tr, mahmutozer2002@yahoo.com

(Geliş/Received: 06.10.2010; Kabul/Accepted: 25.03.2011)

ÖZET

Bu çalışmada, eşit genişlikli ayırıklaştırma (EGA) yöntemine dayalı yeni bir özellik çıkartma yaklaşımı önerilmiş ve Elektroensefalogram (EEG) işaretlerinden epileptik atak tespitinde bu yaklaşım ile elde edilen istatistiksel özellikler çok katmanlı algılayıcı sinir ağı (ÇKASA) modeline giriş olarak kullanılmıştır. Bu amaç için, EEG işaretleri EGA yöntemi ile ayırıklaştırılmış, her ayırık bölgenin yoğunluğuna dayalı histogramları elde edilmiş ve hem gizli katmansız hem de 5 nörona sahip tek gizli katmanlı iki ÇKASA modeline giriş vektörü olarak uygulanmıştır. Her iki ÇKASA modeli de epileptik atak tespitinde yüksek başarı sağlamıştır. Bu sonuç, önerilen özellik çıkartma yöntemi sayesinde, doğrusal sınıflayıcıların da epileptik atak tespiti problemini çözebileceğini göstermektedir. Sonuç olarak, EGA histogramı yaklaşımı biyomedikal işaret işlemede yeni bir özellik çıkartma yöntemi olarak kullanılabilir.

Anahtar kelimeler: Eşit genişlikli ayırıklaştırma, biyomedikal işaret işleme, EEG işaretleri, epileptik atak tespiti, çok katmanlı algılayıcı sinir ağı, histogram.

EPILEPTIC SEIZURE DETECTION USING ARTIFICIAL NEURAL NETWORK AND A NEW FEATURE EXTRACTION APPROACH BASED ON EQUAL WIDTH DISCRETIZATION

ABSTRACT

In this study, we proposed a new feature extraction approach based on equal width discretization (EWD) method and used the statistical features obtained by means of this approach as the inputs of multilayer perceptron neural network (MLPNN) model in the detection of epileptic seizure from Electroencefalogram (EEG) signals. For this aim, EEG signals were discretized by EWD method, histograms of the signals were obtained according to the density of each discrete interval, and finally these histograms were used as the inputs of MLPNN models both without any hidden layer and with a hidden layer which has 5 neurons. Both of them detected epileptic seizures from EEG signals with high classification success ratios. This result showed that a linear classifier can also solve the problem of epileptic seizure detection by means of the offered feature extraction approach. Consequently, EWD approach may be used as a new feature extraction method in the biomedical signal processing.

Keywords: EEG signals, equal width discretization, biomedical signal processing, epileptic seizure detection, multilayer perceptron neural network, histogram.

1. GİRİŞ (INTRODUCTION)

Epilepsi, beyinde meydana gelen ve atak adı verilen geçici elektrik boşalmaları yüzünden vücutta kontrol edilemeyen istem dışı hareketlere yol açan bir sinir

hastalığıdır. Epilepsi teşhisinde kullanılan yöntemler, beyindeki elektriksel aktivitelerin Elektroensefalogram (EEG) kayıtlarına dayanmaktadır. EEG işaretlerinden epileptik atak tespitinde genellikle iki adım vardır: özellik çıkartma ve sınıflandırma.

Özellik çıkarma işlemi zaman, frekans veya zaman-frekans boyutunda yapılmaktadır. Zaman veya frekans boyutuna dayalı yöntemler EEG işaretlerindeki karakteristik farklılıkları kullanmaktadır. EEG gibi durağan olmayan işaretler için zaman-frekans boyutunda çalışan modeller genellikle daha yüksek başarıya sahip olmaktadır [1–11]. EEG işaretlerinin sınıflandırılmasında özbağlanımlı model [9, 12, 13], yaklaşıklık entropisi [5] ve doğrusal tahmin hata enerjisi [14] gibi farklı modeller kullanılmıştır. Biyomedikal işaretlerin sınıflandırılmasında en sık tercih edilen model tipi yapay sinir ağı (YSA) modelleridir [2, 10, 15, 16]. EEG işaretlerinin sınıflandırılmasında YSA modeline dayalı çok katmanlı algılayıcı sinir ağı [6, 7, 10, 12, 13, 16], uyarlamalı sinirsel bulanık çıkarım sistemi [2], çapsal tabanlı fonksiyon sinir ağı [17], yinelemeli sinir ağı [18, 19], öğrenen vektör parçalama [20], destek vektör makinesi [21], uzman sistem modeli [9] ve özbağlanımlı izgesel analize dayalı sinir ağı modeli [22] gibi birçok farklı yaklaşım önerilmiştir. Bu yaklaşımlar genellikle EEG işaretlerini ‘epileptik’ veya ‘normal’ olarak sınıflandırmayı amaçlamaktadır. YSA modelleri, bir eğitim kümesinden elde edilen özellikleri kullanarak EEG işaretleri arasındaki farklılıkları saptamakta ve işaretleri sınıflandırmaktadır. Bu yüzden kullanılan özellik çıkartma yöntemi YSA modellerinin sınıflandırma performansı üzerinde çok önemli bir rol oynamaktadır.

Sınıflandırma performansında etkili bir diğer konu ise hesaplama karmaşıklığıdır. EEG işaretlerinden epileptik atak tespitinde kullanılan zaman-frekans boyutuna dayalı YSA modelleri her ne kadar daha yüksek başarı sağlasalar da gerçek zamanlı bir uygulamada hesaplama karmaşıklığının yüksek oluşu yüzünden sınıflandırma süresinin uzun olabileceği düşünülerek genellikle ya zaman ya da frekans boyutunda çalışan modeller tercih edilmektedir [23].

Bu çalışmada, epileptik atak tespitinde daha önce uygulanmamış olan eşit genişlikli ayırıklaştırma (EGA) yöntemiyle zaman boyutunda ayırıklaştırılan EEG işaretlerinin histogramları, çok katmanlı algılayıcı sinir ağı (ÇKASA) modeline giriş olarak uygulanarak epileptik atak tespiti yapılmıştır.

2. MATERYAL VE YÖNTEM (MATERIAL AND METHOD)

2.1. EEG verisi (EEG dataset)

Bu çalışmada kullanılan EEG verisi, her biri tekkanallı 100 EEG kaydı içeren beş veri kümesinden (A, B, C, D ve E) oluşmaktadır [24]. Her bir kayıt 173,60 Hz örnekleme frekansıyla 23,6 saniyelik sürede kaydedilmiştir. Veri, göz ve kas hareketleri yüzünden meydana gelen aykırı durumlar içermeyen EEG kayıtlarından seçilmiştir. A ve B veri kümeleri yüzeysel olarak; C, D ve E veri kümeleri ise içsel

olarak kaydedilmiştir. A ve B veri kümeleri gözler açık ve gözler kapalı olarak beş sağlıklı bireyden; C ve D veri kümeleri beş epilepsi hastasının epileptik olmayan ve olan beyin yarıkürelerinden atak geçirmediği zamanlarda alınmıştır. E veri kümesi ise bu beş epilepsi hastasının atak geçirdikleri zamanlarda kaydedilmiştir [24]. Bu çalışmada, EEG işaretlerinden epileptik atak tespiti için tüm veri (A, B, C, D ve E) kullanılmıştır.

2.2. Eşit genişlikli ayırıklaştırma (EGA) histogramı (Equal width discretization histogram)

YSA modelleri kullanılarak yapılan sınıflandırma çalışmalarında EEG işaretleri, genellikle istatistiksel işlemlerle elde edilen maksimum, minimum, standart sapma, ortalama, entropi, ortalama güç gibi özellik vektörleriyle temsil edilmektedir [5, 9, 10]. Bu çalışmada, bu tip istatistiksel parametreler yerine işaretlerin ayırıklaştırılmasına dayalı olarak hesaplanan histogramlar ÇKASA modeline giriş vektörü olarak kullanılmıştır.

Ayrıklaştırma, veri madenciliği ve makine öğrenmesi yöntemlerinde sıklıkla kullanılan bir ön işleme yaklaşımıdır [25–32]. Ayrıklaştırma yöntemleri herhangi bir ön bilgi olmaksızın sürekli işaretleri zaman eksenine karşın genlik ekseninde birçok bölgeye gruplamaktadır. Bu yöntemlerde, her bir bölge farklı isimlerle etiketlenmekte ve veri noktaları bu etiketlere atanmaktadır. EEG gibi ayırık değerlere sahip işaretlerin ayırıklaştırılması işlemi ise amaç işaretlerin kümeler halinde temsil edilmesidir. Bu sayede verinin içerisinde gizlenen büyük gruplar keşfedilerek daha iyi bir işaret analizi yapılır. Ayrıklaştırmanın başarısı algoritmasına, verinin dağılımına ve kullanılan sonuç çıkarma modeline bağlıdır. İşaretlerin ayırıklaştırılmasında kullanılan birçok yöntem vardır: eşit genişlikli ayırıklaştırma [25], eşit frekanslı ayırıklaştırma [26], istatistiksel temelli ayırıklaştırma [27, 28], enformasyon entropisine dayalı ayırıklaştırma [29–31] ve kümeleme temelli ayırıklaştırma [32]. Bu çalışmada, daha önce epileptik atak tespitinde uygulanmamış olmasından dolayı eşit genişlikli ayırıklaştırma (EGA) yöntemi kullanılmıştır.

EGA yöntemi kullanılarak EEG işaretlerinin genlik eksenine K adet eşit aralığa bölünmüştür. Bu aralıklar,

$$W = (v_{\max} - v_{\min}) / K \quad (1)$$

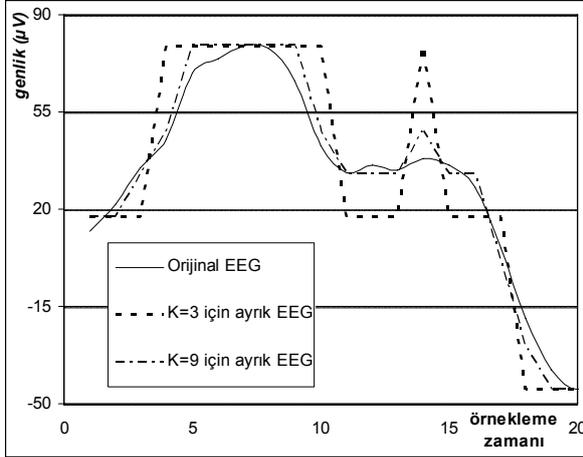
genişliğine sahiptir. Burada, v_{\min} minimum genlik değerini ve v_{\max} maksimum genlik değerini göstermektedir. Ayırıklaştırılacak işaret için kesme noktaları aşağıdaki gibidir:

$$v_{\min} + W, v_{\min} + 2W, \dots, v_{\min} + (K - 1)W \quad (2)$$

Belirlenen kesme noktalarına göre verideki tüm EEG kayıtları ayırıklaştırılmaktadır. Şekil 1, $K=3$ ve $K=9$

değerleri için EGA yöntemi kullanılarak ayrıklaştırılan bir EEG kaydını göstermektedir.

Şekil 1'de görüldüğü gibi K 'nın büyük değerlerinde (örneğin $K=9$) ayrıklaştırılarak elde edilen işaret, küçük değerlerinde (örneğin $K=3$) ayrıklaştırılarak elde edilen işarete göre orijinal işarete daha çok benzerdir.



Şekil 1. Bir EEG kaydının $K=3$ ve $K=9$ için ayrıklaştırılması (The discretization of an EEG segment for $K=3$ and $K=9$).

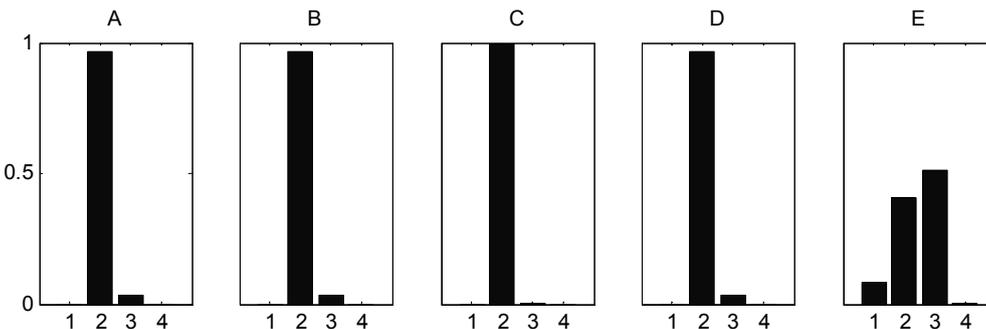
Bu çalışmada, EGA yöntemi ile EEG işaretleri ayrıklaştırıldıktan sonra i nci ayrık bölgenin yoğunluğu aşağıdaki eşitlik ile hesaplanmıştır:

$$D_i = \frac{\sum_{j=1}^n S_{ij}}{\sum_{j=1}^n S_j}, \quad i=1, \dots, K \quad (3)$$

Burada, S_{ij} değeri j nci EEG kaydının i nci bölgesinde bulunan işaretlerin sayısı, S_j değeri j nci EEG kaydının işaret uzunluğu ve n değeri de toplam EEG kayıt sayısıdır. Şekil 2, $K=4$ için veriden örnek olarak seçilen EEG işaretlerinin histogramlarını göstermektedir.

2.3. Geçerlik ölçütleri (Validity Measurements)

Çalışmada kullanılan ÇKASA modelinin genel bir başarıya sahip olduğunu anlamak için rasgele örnekler



Şekil 2. A, B, C, D ve E kümelerinden seçilen beş EEG kaydının normalizasyonlu histogramları (The normalized histograms of five EEG segments chosen from A, B, C, D, and E sets)

seçimine dayalı çapraz geçerlik yöntemi kullanılmıştır. Bu yöntemde, verideki EEG kayıtları üç kümeye (eğitim, geçerlik ve test) rasgele olarak dağıtılmaktadır. Modelin eğitimi için eğitim kümesi kullanılmaktadır. Modelin geçerlik kümesindeki başarısı en yüksek seviyeye ulaştığı zaman eğitime son verilmektedir. Son olarak, modelin nihai tahmin başarısı test kümesi üzerinde aşağıdaki istatistiksel ölçütlerle hesaplanmaktadır:

Doğru Pozitif (DP): Doğru sınıflandırılan epileptik atak geçiren bireylerin sayısı

Doğru Negatif (DN): Doğru sınıflandırılan epileptik atak geçirmeyen bireylerin sayısı

DP Oranı: Doğru pozitif karar sayısının (DP) toplam pozitif durum sayısına oranı.

DN Oranı: Doğru negatif karar sayısının (DN) toplam negatif durum sayısına oranı

Sınıflandırma yöntemlerinde modelin başarısı için genelde kullanılan geçerlik ölçütü toplam sınıflandırma doğruluğudur ve doğru sınıflandırılan örnek sayısının tüm örnek sayısına oranıyla hesaplanmaktadır. Ancak, örnek sayılarının sınıflara dağılımları çok farklı olan bir veride genel başarının yüksek olması durumunda, bu ölçüt az örneğe sahip sınıfın da yüksek başarıya sahip olduğu şeklinde yanlış bir kaniya yol açabilmektedir. Bu yüzden, bir başarı değerlendirmesi yapılırken ROC analizi kullanılmaktadır.

3. ANALİZ VE TARTIŞMA (ANALYSIS AND DISCUSSION)

Bu çalışmada, EEG işaretleri farklı K değerleri için EGA yöntemi ile ayrıklaştırılmıştır. Her ayrık bölgenin yoğunluğuna göre histogramlar elde edilmiş ve epileptik atak tespiti için bir ÇKASA modeline giriş olarak kullanılmıştır. ÇKASA modelinin aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonu ve eğitim algoritması olarak Levenberg-Marquardt geri-yayılım algoritması seçilmiştir. K 'nın her bir değeri için model 5000 kez çalıştırılmıştır. Verinin %20'si eğitim kümesine, %20'si geçerlik kümesine ve %60'ı test kümesine rasgele olarak dağıtılmıştır.

Buna göre, 500 vektör içeren tüm veriden test kümesi için 300 vektör seçilmiştir. Bunun 240 vektörü ABCD (sağlıklı bireyler ve epileptik atak geçirmeyen epilepsi hastaları) sınıfından ve 60 vektörü E (epileptik atak geçiren epilepsi hastaları) sınıfından oluşmaktadır. Elde edilen özellik vektörleri hem gizli katmansız bir ÇKASA modeliyle hem de 5 nöron içeren tek gizli katmanlı ÇKASA modeliyle sınıflandırılmıştır. Modellerin sınıflandırma sonucunda elde edilen en yüksek başarıları için karışıklık matrisleri Tablo 1 ve 2'de gösterilmektedir.

Tablo 1. Gizli katman kullanılmadan yapılan deneyin karışıklık matrisi (Confusion matrix of the experiment without any hidden layer)

Sınıf	ABCD	E
ABCD	235	5
E	1	59

Tablo 2. 5 nörona sahip tek gizli katman kullanılarak yapılan deneyin karışıklık matrisi (Confusion matrix of the experiment by using a hidden layer with 5 neurons)

Sınıf	ABCD	E
ABCD	239	1
E	1	59

Tablo 1 ve Tablo 2'den görüldüğü gibi önerilen özellik çıkartma yöntemini kullanan gizli katmansız ÇKASA modeli toplam 6 durumu yanlış sınıflandırırken, 5 nörona sahip tek gizli katmanlı ÇKASA modeli aynı özellikleri kullanarak sadece 2 durumu yanlış sınıflandırmıştır. Çalışmada en yüksek başarıyı sağlayan K değerleri her iki model için de bağımsız ele alınmıştır. Verilen sonuçlar gizli katmansız model için $K=9$ ve gizli katmanlı model için $K=5$ değerlerinde ulaşılan en yüksek başarıları temsil etmektedir.

EGA yaklaşımına dayalı gizli katmansız ve gizli katmanlı ÇKASA modeli ve geleneksel parametrelere sahip gizli katmanlı ÇKASA modellerinin geçerlik sonuçları Tablo 3'te gösterilmektedir.

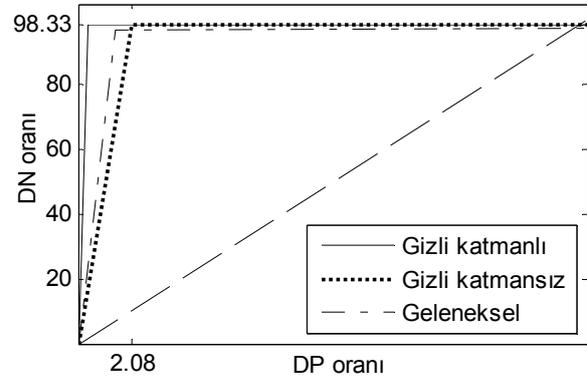
Tablo 3. Deneilerin geçerlik sonuçları (Validity results of the experiments)

Model	DP oranı	DN oranı
EGA yaklaşımına dayalı gizli katmansız model	%2,08	%98,33
EGA yaklaşımına dayalı gizli katmanlı model	%0,42	%98,33
Geleneksel parametrelere sahip model	%1,67	%97,08

Tablo 3'te görüldüğü gibi epileptik atak tespitinde önerilen modelin DP ve DN oranları gizli katmansız ÇKASA modeli için sırasıyla %2,08 ve %98,33 iken, 5 nörona sahip tek gizli katmanlı ÇKASA modeli için %0,42 ve %98,33 olmuştur. Aynı gizli katmanlı

ÇKASA modelinin girişleri olarak geleneksel parametrelere sahip bir model (maksimum, minimum, standart sapma, ortalama) kullanıldığı zaman [2, 10, 11, 21] DP oranı %1,67 ve DN oranı %97,08 olmuştur. Gizli katmansız ve gizli katmanlı ÇKASA modelleri önerilen özellik çıkartma yöntemi sayesinde epileptik atak tespitinde birbirine yakın başarı sonuçları sağlamıştır. Bu sonuç EGA temelli özellik çıkartma yaklaşımının EEG işaretlerinin karakteristik özelliklerini ortaya çıkartmakta etkin olduğunu göstermektedir.

Şekil 3'te bu çalışmada gerçekleştirilen deneylerin ROC analizi görülmektedir. Şekil 3'teki ROC eğrilerin altındaki alanlara göre EGA yaklaşımına dayalı gizli katmanlı ÇKASA modeli en başarılı model olmuştur. Bu sonuçlar, bir işaretin uygun özelliklerini çıkartmanın en uygun sınıflayıcıyı seçmekten bile daha önemli olabileceğini göstermektedir.



Şekil 3. Deneilerin ROC analizi (ROC analysis of the experiments)

4. SONUÇ (CONCLUSION)

Bu çalışmada, epileptik atak tespiti için ÇKASA modelinin girişleri olarak ortalama, standart sapma, maksimum, minimum, ortalama güç, entropi gibi istatistiksel parametreler kullanmak yerine EEG işaretlerinin tüm karakteristik özelliklerini içeren histogramlar kullanılmıştır. EGA yaklaşımına dayalı gizli katmansız ve gizli katmanlı ÇKASA modelleri epileptik atak tespitinde yüksek sınıflandırma başarıları göstermiştir. Her iki sınıflayıcının başarı oranının yüksek çıkması, epileptik atak tespiti probleminin önerilen özellik çıkartma yöntemi sayesinde doğrusal sınıflayıcılar tarafından da çözülebileceğini göstermiştir. Sonuç olarak, EGA yaklaşımı EEG işaretlerinden epileptik atak tespitinde yeni bir özellik çıkartma yöntemi olarak kullanılabilir.

KAYNAKLAR (REFERENCES)

- Adeli, H., Zhou, Z., ve Dadmehr, N., "Analysis of EEG Records in an Epileptic Patient using

- Wavelet Transform”, **Journal of Neuroscience Methods**, No 123, 69–87, 2003.
2. Güler, İ., ve Übeyli, E. D., “Adaptive Neuro-Fuzzy Inference System for Classification of EEG Signals using Wavelet Coefficients”, **Journal of Neuroscience Methods**, No 148, 113–121, 2005.
 3. Khan, Y. U., ve Gotman, J., “Wavelet Based Automatic Seizure Detection in Intra-cerebral Electroencephalogram”, **Clinical Neurophysiology**, No 114, 898–908, 2003.
 4. Kıymık, M. K., Akın, M., ve Subaşı, A., “Automatic Recognition of Alertness Level by using Wavelet Transform and Artificial Neural Network”, **Journal of Neuroscience Methods**, No 139, 231–240, 2004.
 5. Ocak, H., “Automatic Detection of Epileptic Seizures in EEG using Discrete Wavelet Transform and Approximate Entropy”, **Expert Systems with Applications**, No 36, 2027–2036, 2009.
 6. Subaşı, A., “Automatic Recognition of Alertness Level from EEG by using Neural Network and Wavelet Coefficients”, **Expert Systems with Applications**, No 28, 701–711, 2005.
 7. Subaşı, A., “Epileptic Seizure Detection using Dynamic Wavelet Network”, **Expert Systems with Applications**, No 29, 343–355, 2005.
 8. Subaşı, A., “Automatic Detection of Epileptic Seizure using Dynamic Fuzzy Neural Networks”, **Expert Systems with Applications**, No 31, 320–328, 2006.
 9. Subaşı, A., “EEG Signal Classification using Wavelet Feature Extraction and a Mixture of Expert Model”, **Expert Systems with Applications**, No 32, 1084–1093, 2007.
 10. Übeyli, E. D., “Combined Neural Network Model Employing Wavelet Coefficients for EEG Signals Classification”, **Digital Signal Processing**, No 19, 297–308, 2009.
 11. Übeyli, E. D., “Decision Support Systems for Time-Varying Biomedical Signals: EEG Signals Classification”, **Expert Systems with Applications**, No 36, 2275–2284, 2009.
 12. Alkan, A., Köklükaya, E., ve Subaşı, A., “Automatic Seizure Detection in EEG using Logistic Regression and Artificial Neural Network”, **Journal of Neuroscience Methods**, No 148, 167–176, 2005.
 13. Subaşı, A., ve Ercelebi, E., “Classification of EEG Signals using Neural Network and Logistic Regression”, **Computer Methods and Programs in Biomedicine**, No 78, 87–99, 2005.
 14. Altunay, S., Telatar, Z., ve Eroğul, O., “Epileptic EEG Detection using the Linear Prediction Error Energy”, **Expert Systems with Applications**, Cilt 37, No 8, 5661–5665, 2010.
 15. Acir, N., “Automated System for Detection of Epileptiform Patterns in EEG by using a Modified RBFN Classifier”, **Expert Systems with Applications**, Cilt 29, No 2, 455–462, 2005.
 16. Subaşı, A., “Application of Adaptive Neuro-Fuzzy Inference System for Epileptic Seizure Detection using Wavelet Feature Extraction”, **Computers in Biology and Medicine**, Cilt 37, No 2, 227–244, 2007.
 17. Aslan, K., Bozdemir, H., Şahin, S., Oğulata, S. N., ve Erol, R., “A Radial Basis Function Neural Network Model for Classification of Epilepsy using EEG Signals”, **The Journal of Medical Systems**, No 32, 403–408, 2008.
 18. Petrosian, A., Prokhorov, D., Homan, R., Dashei, R., ve Wunsch, D., “Recurrent Neural Network Based Prediction of Epileptic Seizures in Intra and Extra-cranial EEG”, **Neurocomputing**, No 30, 201–218, 2000.
 19. Srinivasan, V., Eswaran, C., ve Sriraam, N., “Artificial Neural Network based Epileptic Detection using Time-Domain and Frequency-Domain Features”, **Journal of Medical Systems**, Cilt 29, No 6, 647–660, 2005.
 20. Pradhan, N., Sadasivan, P. K., ve Arunodaya, G. R., “Detection of Seizure Activity in EEG by an Artificial Neural Network: A Preliminary Study”, **Computers and Biomedical Research**, No 29, 303–313, 1996.
 21. Übeyli, E. D., “Analysis of EEG Signals by Combining Eigenvector Methods and Multi-class Support Vector Machines”, **Computers in Biology and Medicine**, Cilt 38, No 1, 14–22, 2008.
 22. Kıymık, M. K., Subaşı, A., ve Özçalık, H. R., “Neural Networks with Periodogram and Autoregressive Spectral Analysis Methods in Detection of Epileptic Seizure”, **Journal of Medical Systems**, Cilt 28, No 6, 511–522, 2004.
 23. Kıymık, M. K., Güler, İ., Dizibüyük, A., and Akın, M., “Comparison of STFT and Wavelet Transform Methods in Determining Epileptic Seizure Activity in EEG Signals for Real-time Application”, **Computers in Biology and Medicine**, Cilt 35, No 7, 603–616, 2005.
 24. Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., 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”, **Physical Review E**, Cilt 64, No 6, 061907, 2001.
 25. Hsu, C. N., Huang, H., J., Wong, T. T., “Implications of the Dirichlet Assumption for Discretization of Continuous Variables in Naive Bayesian Classifiers”, **Machine Learning**, Cilt 53, No 3, 235–263, 2003.
 26. Jiang, S., Li, X., Zheng, Q., ve Wang, L., “Approximate Equal Frequency Discretization Method”, **Global Congress on Intelligent Systems**, 514–518, 2009.

27. Tay, E. H., ve Shen, L., “A Modified Chi2 Algorithm for Discretization”, **IEEE Transactions on Knowledge and Data Engineering**, Cilt 14, No 3, 666–670, 2002.
28. Gang, L. ve Tong, F., “An Unsupervised Discretization Algorithm based on Mixture Probabilistic Model”, **Chinese Journal of Computers**, Cilt 25, No 2, 158–164, 2002.
29. Lee, C.H., “A Hellinger-based Discretization Method for Numeric Attributes in Classification Learning”, **Knowledge-Based Systems**, Cilt 20, No 4, 419–425, 2007.
30. Fayyad, U.M., ve Irani, K.B., “Multi-interval Discretization of Continuous Valued Attributes for Classification Learning”, **Proc. of the 13th International Joint Conference on Artificial Intelligence**, 1022–1029, 1993.
31. Clarke, E.J. ve Bratton, B.A., “Entropy and MDL Discretization of Continuous Variables for Bayesian Belief Networks”, **International Journal of Intelligence Systems**, No 15, 61–92, 2000.
32. Xi, J. Ouyang, W.M., “Clustering based Algorithm for Best Discretizing Continuous Valued Attributes”, **Mini-micro systems**, Cilt 21, No 10, 1025–1027, 2000.