

DALGACIK DÖNÜŞÜMÜ İLE EEG İŞARETLERİNDEN ÇIKARILAN ÖZİNTELİK VEKTÖRLERİ ÜZERİNDE İSTATİSTİKSEL İŞLEMLERİN GERÇEKLEŞTİRİLMESİ

Elif Derya ÜBEYLİ¹

İnan GÜLER²

¹TOBB Ekonomi ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği, Söğütözü, Ankara

²Gazi Üniversitesi, Teknik Eğitim Fakültesi, Elektronik-Bilgisayar Bölümü, 06500 Teknikokullar, Ankara

¹e-posta: ubeyli@gazi.edu.tr

²e-posta: iguler@gazi.edu.tr

ÖZET

Teşhis sistemleri için dalgacık dönüşümünün kullanımı ile işaretlerden öznelik çıkarılmakta ve işaretlerin zaman-frekans dağılımı istatistiksel özellikler ile gösterilmektedir. Bu çalışmada, farklı kişilerden kayıt edilen elektroensefalogram (EEG) işaretlerinin spektral analizi dalgacık dönüşümü ile gerçekleştirilmiş ve işaret hakkında önemli bilgi içeren dalgacık katsayıları işareti temsil eden öznelik vektörleri olarak ele alınmıştır. Öznelik vektörlerinin boyutlarının azaltılabilmesi için dalgacık katsayıları üzerinde istatistiksel işlemler yapılmış ve sınıflama işleminde kullanılan çok katmanlı perseptron sinir ağının giriş öznelik vektörleri seçilmiştir. Toplam sınıflama doğruluğu dalgacık katsayılarının giriş olarak kullanıldığı çok katmanlı perseptron sinir ağının, EEG işaretlerinin (sağlıklı kişilerden, epilepsi nöbetinin olmadığı durumda epilepsi hastalarından ve epilepsi nöbeti sırasında epilepsi hastalarından kayıt edilen EEG işaretleri) sınıflandırılmasında kullanılabileceğini göstermiştir.

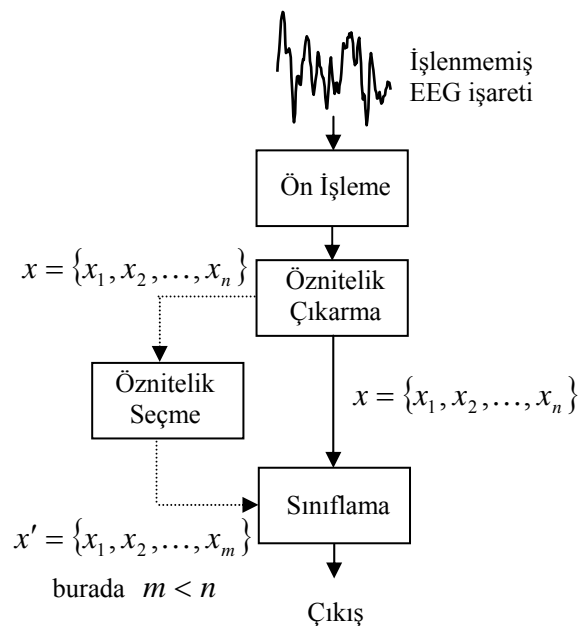
Anahtar kelimeler: Dalgacık dönüşümü, Öznelik çıkarma, Sınıflama doğruluğu, EEG işaretleri

1. GİRİŞ

Elektroensefalogram (EEG) işaretleri, beyin fonksiyonlarının elektriksel olarak değişimini ifade eder. Beynin işlevsel durumuna göre örneğin; uykuda, anesteziye, oksijen eksikliği (hipoksia) durumunda ve epilepsi gibi belirli sinir hastalıklarında, bu aktivite değişmektedir. EEG ilk kayıt edilmeye başlandığından beri klinik uygulamalarda en önemli teşhis araçlarından biri olmuştur [1-4].

Hastalık teşhisleri, şekil sınıflama işlemi olarak incelenebilmektedir. Girişlerin belirsiz olması ve değişkenlik göstermesi durumunda geleneksel şekil sınıflama sistemleri sınıflamada başarılı olamayabilir. Yapay sinir ağları (YSA) ise girişlerin değişkenlik göstermesi durumunda şekil sınıflamada başarılı olmaktadır. Tıbbi alandaki uygulamalar, YSA'ların hastalık teşhisini içeren şekil sınıflama için uygun

olduklarını göstermektedir [1-7]. Teşhis sistemlerinde çeşitli metodlar kullanılmakla birlikte teşhis sistemleri genellikle şu işlemlerden oluşmaktadır: ön işleme, öznelik çıkarma/seçme ve sınıflama (Şekil 1). İşaret/görüntü elde etme, bozucu etkenlerin yok edilmesi, ortalama alma, eşik değeri belirleme, işaret/görüntü iyileştirme gibi işlemler ön işlemeyi oluşturmaktadır. Öznelik çıkarma, şekil tanımlama ve şeklin önemli özneliklerinin çıkarılıp öznelik vektörünün elde edilmesi işlemidir. Öznelik seçme isteğe bağlı olarak yapılan bir işlem olup sınıflama işlemi açısından en belirleyici özneliklerin seçilmesi ile öznelik vektörünün boyutunun azaltılmasıdır. Teşhis sistemlerinin son aşaması olan sınıflamada, kullanılan algoritmaya bağlı olarak giriş öznelik vektörleri incelenir ve sınıflama sonucu belirlenir. Sınıflama sonucunu belirlemesi açısından ele alındığında öznelik çıkarma ve gerekli durumlarda öznelik seçme, YSA gibi sınıflama sistemlerinin başarısını oldukça etkilemektedir [1-7].



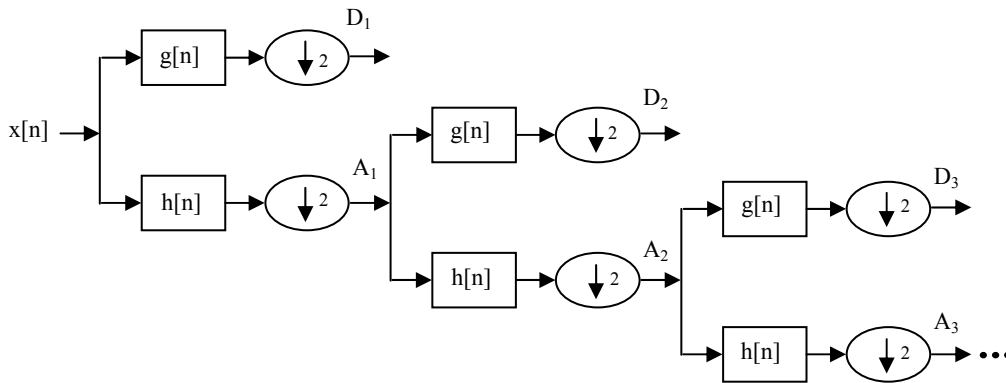
Şekil 1. Teşhis sistemlerinde gerçekleştirilen işlemler

EEG işaretleri, hastalık teşhisinin doğruluğunu sağlamak için çoğunlukla 8-10 saatlik kayıtlar şeklinde alınmaktadır. EEG kayıtlarının bu şekilde uzun olmasından dolayı, EEG işaretlerinin analizinin bilgisayar ortamında yapılması gerekli olmuştur. Bu konuda farklı yöntem ve algoritmalar geliştirilmiştir [1-4]. Bu çalışmada, kaynak [8]'de tanımlanan farklı kişilerden kayıt edilmiş EEG işaretlerinin (sağlıklı kişilerden, epilepsi nöbetinin olmadığı durumda epilepsi hastalarından ve epilepsi nöbeti sırasında epilepsi hastalarından kayıt edilen EEG işaretleri) spektral analizi dalgacık dönüşümü ile gerçekleştirilmiş ve sınıflama işlemi için kullanılan çok katmanlı perseptron sinir ağının giriş öznitelik vektörleri elde edilmiştir.

2. DALGACIK DÖNÜŞÜMÜ

Durağan olmayan işaretlerin spektral analizi için uygun olmasından dolayı dalgacık dönüşümünün diğer spektral analiz metodlarına göre üstünlükleri vardır. Dalgacık dönüşümünün en önemli avantajı, düşük frekanslar için geniş, yüksek frekanslar için dar olacak şekilde değişen pencere boyutlarının olmasıdır. Böylece, bütün frekans aralıklarında optimum zaman-frekans çözünürlüğü sağlanabilmektedir [2,3,9,10].

Dalgacık dönüşümü sürekli ve ayrık olmak üzere iki farklı şekilde incelenir. Sürekli dalgacık dönüşümünde ölçeklendirme ve dönüşüm parametrelerinin sürekli olarak değişiminden dolayı her bir ölçek için dalgacık katsayılarının hesaplanması zor ve zaman alıcı olmaktadır. Bu nedenle ayrık dalgacık dönüşümü daha sık kullanılmaktadır. Dalgacık dönüşümü ile işaret belli sayıda ölçeklere ayrılır. Çoklu çözünürlük ayrışımı olarak isimlendirilen bu işlem, $x(n)$ işareti için Şekil 2'de gösterilmektedir. Şekil 2'de, ilk yüksek geçiren filtreye ($g[\cdot]$) ve alçak geçiren filtreye ($h[\cdot]$) ait olan örneklenmiş çıkışlar sırası ile ayrıntılı D_1 ve yaklaşık A_1 alt bantlarını oluşturur. A_1 yaklaşım bantı tekrar ayrışır ve bu işlem Şekil 2'de görüldüğü gibi devam eder.



Şekil 2. Ayrık dalgacık dönüşümünün gerçekleştirilmesinde alt bandlara ayrışım; $g[n]$ yüksek geçiren filtre, $h[n]$ alçak geçiren filtre

Dalgacık dönüşümü aşağıda verilen şartı sağlayan alçak geçiren filtre (h) ile belirtilebilir:

$$H(z)H(z^{-1}) + H(-z)H(-z^{-1}) = 1 \quad (1)$$

burada $H(z)$, h filtresinin z -dönüşümüdür. Bu filtrenin tamamlayıcı yüksek geçiren filtresi (g) şu şekilde tanımlanabilir:

$$G(z) = zH(-z^{-1}) \quad (2)$$

Artan uzunluklar ile filtre dizisi (i indeksi ile) şu şekilde elde edilir:

$$H_{i+1}(z) = H(z^{2^i})H_i(z) \quad (3)$$

$$G_{i+1}(z) = G(z^{2^i})H_i(z), \quad i = 0, \dots, I-1$$

burada başlangıç şartı $H_0(z) = 1$ 'dir. Bu, zaman domeninde şu şekilde ifade edilir:

$$h_{i+1}(k) = [h]_{\uparrow 2^i} * h_i(k) \quad (4)$$

$$g_{i+1}(k) = [g]_{\uparrow 2^i} * h_i(k)$$

burada, $[\cdot]_{\uparrow m}$ indeksi m faktörü ile yukarı örnekleme yapıldığını gösterir ve k eşit olarak örneklenmiş ayrık zamanı belirtir.

Normalize edilmiş dalgacık ve ölçek temelli fonksiyonlar $\varphi_{i,l}(k)$, $\psi_{i,l}(k)$ şu şekilde tanımlanır:

$$\varphi_{i,l}(k) = 2^{i/2} h_i(k - 2^i l) \quad (5)$$

$$\psi_{i,l}(k) = 2^{i/2} g_i(k - 2^i l)$$

burada, $2^{i/2}$ faktörü iç çarpım normalizasyonudur, i ölçeklendirme parametresi, l dönüşüm parametresidir. Ayrık dalgacık dönüşüm ayrışımı şu şekilde belirtilir:

$$a_{(i)}(l) = x(k) * \varphi_{i,l}(k) \quad (6)$$

$$d_{(i)}(l) = x(k) * \psi_{i,l}(k)$$

burada, $a_{(i)}(l)$ ve $d_{(i)}(l)$ sırası ile i çözünürlüğündeki yaklaşık katsayılar ve ayrıntılı katsayılardır [2,3,9,10].

3. KLİNİK SONUÇLAR

3.1. Ayrık Dalgacık Dönüşümü ile Öznitelik Çıkarma

Uygun dalgacık seçimi ve ayrışım seviyelerinin sayısının tesbiti, işaretlerin dalgacık dönüşümü ile analizinde oldukça önemlidir. İşaretin baskın frekans bileşenlerine göre ayrışım seviyelerinin sayısı tespit edilir. Bu çalışmada, EEG işaretlerinin ayrışım seviyelerinin sayısı 4 olarak belirlenmiştir. Bu durumda, EEG işaretleri $D_1 - D_4$ ayrıntılı alt bandlarına ve son olarak A_4 yaklaşık alt bandına ayrılmıştır. Sınıflamanın doğruluğu uygulama için seçilen dalgacık tipine bağlıdır. Bu çalışmada, dalgacık katsayılarının hesaplanmasında 2. dereceden Daubechies dalgacık kullanımının uygun olduğu belirlenmiştir.

Dalgacık katsayıları işaret hakkında önemli bilgi içerdiği için EEG işaretlerinin dalgacık katsayıları işareti temsil eden öznitelik vektörleri olarak ele alınmıştır. Çıkarılan öznitelik vektörlerinin boyutlarının azaltılabilmesi için dalgacık katsayıları üzerinde istatistiksel özellikler kullanılmıştır. EEG işaretlerinin zaman-frekans dağılımını göstermekte kullanılan istatistiksel özellikler aşağıda verilmektedir:

1. Her bir alt bandedeki katsayıların mutlak değerlerinin ortalaması.
2. Her bir alt bandedeki katsayıların mutlak değerlerinin maksimumu.
3. Her bir alt bandedeki katsayıların kuvvetlerinin ortalaması.
4. Her bir alt bandedeki katsayıların standard sapması.
5. Komşu alt bandlara ait mutlak ortalama değerlerinin oranı.
6. Her bir alt bandedeki katsayıların bozulmasının dağılımı.

Özellik 1-3 işaretin frekans dağılımını gösterirken özellik 4-6 frekans dağılımındaki değişim miktarını göstermektedir. Bu öznitelik vektörleri, EEG işaretlerinin sınıflandırılmasında çok katmanlı perseptron sinir ağının girişleri olarak kullanılmıştır. Bu çalışmada, iki gizli katmanı olan ve Levenberg-Marquardt algoritması ile eğitilen çok katmanlı perseptron sinir ağı ile sınıflama yapılmıştır. Dalgacık katsayılarının hesaplanmasında ve çok katmanlı perseptron sinir ağının gerçekleştirilmesinde MATLAB program paketi kullanılmıştır.

3.2. Çok Katmanlı Perseptron Sinir Ağının EEG İşaretlerine Uygulanması

EEG işaretleri, sağlıklı kişilerden (gözleri açık durumda), epilepsi nöbetinin olmadığı durumda epilepsi hastalarından (epileptojenik bölgeden) ve epilepsi nöbeti sırasında epilepsi hastalarından kayıt edilmiştir [8]. Her bir EEG işareti dikdörtgen pencere

ile pencerelenerek 256 örnekten oluşan bölütlere ayrılmıştır. Sağlıklı kişiden, epilepsi nöbetinin olmadığı durumda epilepsi hastasından ve epilepsi nöbeti sırasında epilepsi hastasından kayıt edilmiş olan örnek EEG bölütleri sırası ile Şekil 3(a)-(c)'de verilmektedir. Sağlıklı kişiden ve epilepsi nöbetinin olmadığı durumda epilepsi hastasından kayıt edilen EEG bölütlerinin genlikleri $100\mu V$ seviyesinde değişirken epilepsi nöbeti sırasında epilepsi hastasından kayıt edilen EEG bölütlerinin genlikleri $1000\mu V$ seviyesinde değişmektedir. Her sınıftan 400'er adet bölütün birinci, ikinci, üçüncü ve dördüncü ayrıntılı alt bandlarında (d^k , $k = 1,2,3,4$) ayrıntılı dalgacık katsayıları ($129 + 66 + 34 + 18$ dalgacık katsayıları) ve dördüncü yaklaşık alt bandında (a^4) yaklaşık dalgacık katsayıları (18 dalgacık katsayıları) hesaplanmıştır. Bu durumda, her bir EEG bölütü için 265 dalgacık katsayısı elde edilmektedir. Çıkarılan öznitelik vektörlerinin boyutunu azaltmak için 3.1 kısmında açıklanan istatistiksel özellikler kullanılmıştır. Böylece çok katmanlı perseptron sinir ağının giriş sayısı 29 (öznitelik vektörünün boyutu) olmuştur. Sağlıklı kişiden, epilepsi nöbetinin olmadığı durumda epilepsi hastasından ve epilepsi nöbeti sırasında epilepsi hastasından kayıt edilmiş olan örnek EEG bölütlerinin D_1 frekans bandındaki ayrıntılı dalgacık katsayıları sırası ile Şekil 4(a)-(c)'de verilmektedir. Aynı sınıflardaki EEG bölütlerinin dalgacık katsayılarının birbirlerinden farklı olduğu Şekil 4(a)-(c)'den görülmektedir.

Ağın çıkış vektörleri şu şekilde tanımlanmıştır:

[0 0 1] = Sağlıklı kişiden kayıt edilen EEG bölütü

[0 1 0] = Epilepsi nöbetinin olmadığı durumda

epilepsi hastasından kayıt edilen EEG bölütü


[1 0 0] = Epilepsi nöbeti sırasında epilepsi hastasından kayıt edilen EEG bölütü

Ağın eğitimi için 600 bölüt (her sınıftan 200 bölüt) ve testi için 600 bölüt (her sınıftan 200 bölüt) kullanılmıştır. Ağın daha iyi genelleme yapmasını sağlamak için eğitimde kullanılan 600 bölütten 120 bölüt geçerlilik verisi olarak kullanılmıştır. Bu çalışmada, eğitim 3600 iterasyonda tamamlanmış ve iterasyon sayısı geçerliliğe göre belirlenmiştir. Ağın eğitiminden sonra ağın testi yapılmıştır. Ağın sınıflama performansı, doğru sınıflandırılmış bölüt sayısının toplam bölüt sayısına oranı olan toplam sınıflama doğruluğu ile tespit edilmiştir. Dalgacık katsayılarının giriş olarak kullanıldığı çok katmanlı perseptron sinir ağının, EEG işaretlerini %89,67 doğrulukla sınıflandırdığı gözlenmiştir.

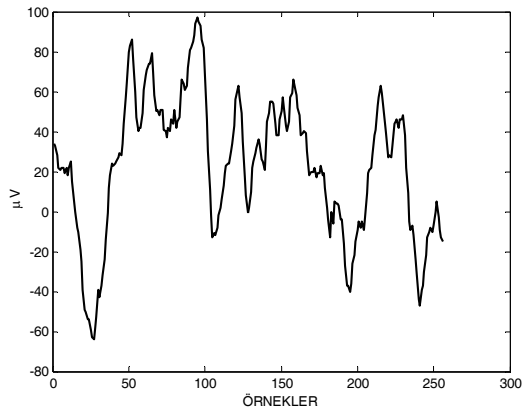
4. SONUÇ

Dalgacık katsayılarının giriş öznitelik vektörleri olarak kullanıldığı çok katmanlı perseptron sinir ağı ile EEG işaretlerinin %89,67 doğrulukla sınıflandırıldığı tespit


edilmiştir. Bu çalışmamızın sonraki aşamasında, farklı eğitim algoritmaları ve farklı ağ mimarisinin kullanımı ile daha yüksek sınıflama sonuçlarının elde edilmesi hedeflenmektedir. Ayrıca, sınıflama doğruluğunu arttırabilmek için giriş öznelik vektörlerinin boyutlarını azaltmada kullanılmış olan istatistiksel özelliklerin geliştirilmesi amaçlanmaktadır.



(a)

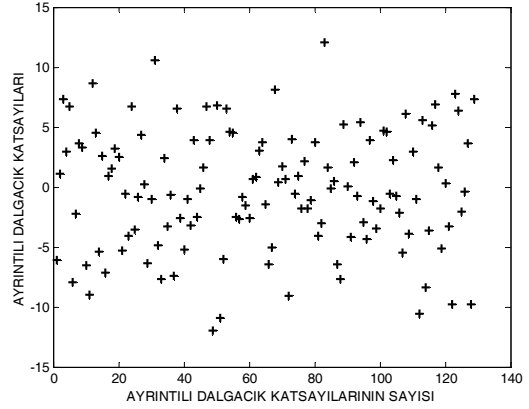


(b)

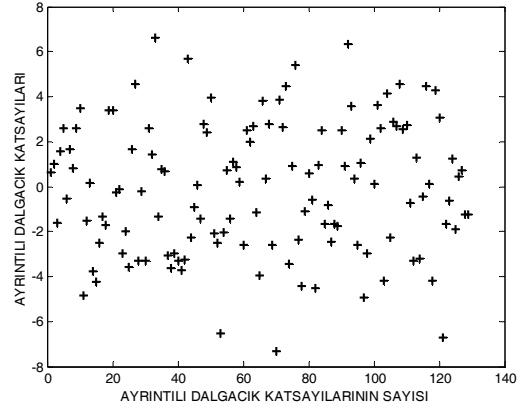


(c)


Şekil 3. EEG bölütlerinin dalga şekilleri: (a) Sağlıklı kişiden kayıt edilen EEG bölütü, (b) Epilepsi nöbetinin olmadığı durumda epilepsi hastasından kayıt edilen EEG bölütü, (c) Epilepsi nöbeti sırasında epilepsi hastasından kayıt edilen EEG bölütü



(a)



(b)



(c)

Şekil 4. EEG bölütlerinin D_1 frekans bandındaki ayrıntılı dalgacık katsayıları: (a) Sağlıklı kişiden kayıt edilen EEG bölütü, (b) Epilepsi nöbetinin olmadığı durumda epilepsi hastasından kayıt edilen EEG bölütü, (c) Epilepsi nöbeti sırasında epilepsi hastasından kayıt edilen EEG bölütü

KAYNAKLAR

- [1] Agarwal R., Gotman J., Flanagan D., Rosenblatt B., Automatic EEG analysis during long-term monitoring in the ICU, ELECTROENCEPHALOGRAPHY AND CLINICAL NEUROPHYSIOLOGY, Vol 107, Iss 1, pp. 44-58, 1998.
- [2] Adeli H., Zhou Z., Dadmehr N., Analysis of EEG records in an epileptic patient using wavelet transform, JOURNAL OF NEUROSCIENCE METHODS, Vol 123, Iss 1, pp. 69-87, 2003.
- [3] Hazarika N., Chen J.Z., Tsoi A.C., Sergejew A., Classification of EEG signals using the wavelet transform, SIGNAL PROCESSING, Vol 59, Iss 1, pp. 61-72, 1997.
- [4] Özdamar Ö., Kalaycı T., Detection of spikes with artificial neural networks using raw EEG, COMPUTERS AND BIOMEDICAL RESEARCH, Vol 31, Iss 2, pp. 122-142, 1998.
- [5] Güler İ., Übeyli E.D., Detection of ophthalmic artery stenosis by least-mean squares backpropagation neural network, COMPUTERS IN BIOLOGY AND MEDICINE, Vol 33, Iss 4, pp. 333-343, 2003.
- [6] Übeyli E.D., Güler İ., Neural network analysis of internal carotid arterial Doppler signals: predictions of stenosis and occlusion, EXPERT SYSTEMS WITH APPLICATIONS, Vol 25, Iss 1, pp. 1-13, 2003.
- [7] Kordylewski H., Graupe D., Liu K., A novel large-memory neural network as an aid in medical diagnosis applications, IEEE TRANSACTIONS ON INFORMATION TECHNOLOGY IN BIOMEDICINE, Vol 5, Iss 3, pp. 202-209, 2001.
- [8] 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, Vol 64, 061907, 2001.
- [9] Daubechies I., The wavelet transform, time-frequency localization and signal analysis, IEEE TRANSACTIONS ON INFORMATION THEORY, Vol 36, Iss 5, pp. 961-1005, 1990.
- [10] Güler N.F., Übeyli E.D., Wavelet-based neural network analysis of ophthalmic artery Doppler signals, COMPUTERS IN BIOLOGY AND MEDICINE, 2004 (baskıda).