



Fare EEG İşaretlerinin *Daubech 5* Dalgacık Tabanlı Adaline ile Sınıflandırılması

Classification of Rat EEG Signals with Adaline Based on *Daubech 5* Wavelet

Faruk Kürker¹, Mehmet Sıraç Özerdem²

¹ Mühendislik Fakültesi
Adıyaman Üniversitesi
fkurker@adiyaman.edu.tr

² Mühendislik Fakültesi
Dicle Üniversitesi
sozerdem@dicle.edu.tr

Özetçe

Tıbbi teşhis ve araştırmalarda kullanılan Elektroensefalogram (EEG) işaretleri beynin sinirsel faaliyeti sonucu elde edilen biyoelektriksel işaretler olup, frekans bileşenleri son derece önemlidir. Bu işaretlerde beynin fonksiyonları ile ilgili çok miktarda bilgi saklıdır. Literatürde EEG işaretleri kullanılarak yapılmış çok çeşitli çalışmalar bulunmaktadır. Bu çalışmada, fare EEG kayıtlarının niteliğine göre sınıflandırılması amaçlanmıştır. EEG kayıtları sağlıklı (veri seti A) ve hastalıklı (veri seti B,C,D,E) olmak üzere iki gruba ayrılmaktadır. Ön işlem olarak, kayıtlardaki her deneğin, *Daubech 5* dalgacığı ile farklı seviyelerdeki dalgacık katsayıları elde edilmiştir. Katsayıların ortalama, standart sapma, maksimum ve minimum değerleri, her deneğin öznelik vektörü olarak değerlendirilmiştir. Öznelik vektörleri, yapay sinir ağlarının (YSA) en basit yapısı olan *Adaptive Linear Nöron (Adaline)* için eğitim kümesi olarak kullanılmıştır. EEG işaretleri, *Adaline* ile sağlıklı ve hastalıklı olmak üzere iki ayrı sınıfa ayrıştırılmıştır. Farklı seviyelerde ve farklı katsayılarla yapılan analizde, %100 başarı elde edilmiştir.

Anahtar Kelimeler: EEG, Epilepsi, Dalgacık Analizi, Yapay Siniri Ağları, *Adaline*.

Abstract

EEG signals, which are used in medical researches and diagnosis, are bioelectrical signals acquired by neural activities as a result of encephalic activities and their frequency constituents are highly significant. These signals contain vast data about cerebral functions. In literature, there are many researches conducted using these EEG signals. This research aims at categorizing the EEG signals of rats according to their qualities. The EEG records are classified into two categories as healthy (data set A) and unhealthy (data set B, C, D, E) as well. As pre-treatment, *Daubech 5* wavelets and their different wavelet coefficients of each subject in records were recorded. Means, standard deviations, maximum and minimum values of coefficients were evaluated

for each subject as its feature vector. Feature vectors were used as instruction cluster for *Adaptive Linear Neuron (Adaline)* which are the simplest structure of artificial neural sets. EEG signals were classified into two categories as healthy and unhealthy with *Adaline*. 100% success was achieved in analyses which were carried out at various levels and coefficients.

1. Giriş

EEG, beyindeki sinir hücreleri tarafından hem uyanıklık, hem de uyku halindeyken üretilen elektriksel faaliyetin kâğıt üzerine beyin dalgaları halinde yazdırılmasıdır. Beynin normal elektriksel faaliyeti başta epilepsi (sara hastalığı) olmak üzere pek çok durumda bozulur. EEG'yi oluşturan beyin dalgalarının değerlendirilmesi ile bu bozukluğun yeri ve şekli hakkında bilgi edinilir. Özellikle epilepsi hastalığının teşhisinde ve tiplerinin belirlenmesinde tedaviye karar verecek olan inceleme yöntemi EEG'dir. Ancak kısa süren epileptik dalga şekillerinin gözle tanınması zor ve zaman alıcı bir işlemdir [1]. EEG okuyucusu, kaydı değerlendirirken, epileptik dalga şekillerinin genel tanımlarından yararlandığı gibi, tüm kanalların etkileşimleri, önceki ve sonraki dalga şekilleri gibi subjektif bilgilerden de yararlanır [2]. Bu yüzden EEG kayıtlarının yorumlanması bu alanda eğitilmiş, deneyimli bir uzman gerektirir. Böyle bir kişinin EEG kaydı yapılan her yerde bulunması pratik olmadığı gibi ekonomikte değildir [3].

EEG kayıtlarını otomatik olarak değerlendirebilecek sistemlere gereksinim vardır. Günümüze kadar bu amaçla bir çok yöntem geliştirilmiş ve uygulanmıştır. Son yıllarda ise EEG kayıtlarının otomatik olarak değerlendirilmesi için YSA kullanılmaktadır. YSA kendisine tanımlanan bir şekli, daha önce öğrendikleri ile karşılaştırarak, aradaki benzerlikleri ortaya koyma ve eksik şekilleri tamamlama, benzer şekilleri oluşturma veya şekilleri belirli sınıflara ayırma özelliklerine sahiptir [4]. Tıbbi alandaki uygulamalar da, şekil (veri) sınıflama ile YSA'ların hastalık teşhisinde kullanılabildiği görülmektedir [5].

YSA'da giriş kümelerinin seçimi ve boyutu çok önemlidir. Minimum boyutta giriş kümesi ile maksimum karakteristik

Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uygulamaları

2. Gün 26 Eylül 2014 Cuma (14.45-16.15)

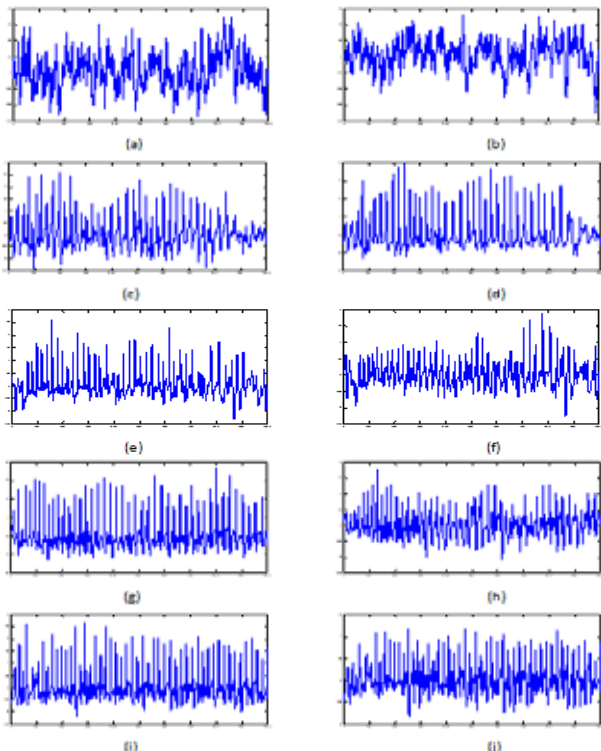
özelliğın ifade edilmesi istenir. Bu amaç için Dalgacık Dönüşümü (DD), en güçlü metottur. Durağan olmayan işaretlerin spektral analizi için uygun olması, DD yöntemini diğer spektral analiz metotlarından üstün kılmaktadır. DD' nin en önemli avantajı, yüksek frekanslar için dar, düşük frekanslar için geniş olacak şekilde değişen pencere boyutlarının olmasıdır. Böylece, bütün frekans aralıklarında optimum zaman-frekans çözünürlüğü sağlanabilmektedir [6].

Literatürde, EEG kayıtları için YSA ve dalgacık dönüşümü uygulanmış birçok çalışma bulunmaktadır [7,8]. Bu çalışma, yapılan çalışmalara benzer niteliktedir. Bu çalışmada amaç, fare EEG kayıtlarının normal-hasta olmak üzere iki sınıfa ayrıştırılması amaçlanmıştır.

2. Materyal ve Metot

2.1. Veri Seti

Bu çalışmada kullanılan EEG verileri, WAG/Rij türü erkek farelerden sağ ve sol frontal korteks'ten kayıt alınan (iki kanallı) 5 saniyelik EEG kayıtlarıdır. Alınan kayıtlar A-B-C-D-E veri setlerinden oluşmaktadır. A seti sağlıklı EEG kaydı olup, diğer setler ise farklı nitelikte epileptik rahatsızlığa sahip EEG kayıtlarıdır. Hastalıklı işarete diken dalga (Spike discharge) aktivitesi/deşarjı epileptik bir belirti olarak değerlendirilir. Doğru ölçüm yapıldığı zaman sara hastalığının belirtisi olabilmektedir. Veri setleri 1-100 Hz filtrelenmiş ve 200 Hz'de sayısallaştırılmıştır. A-B-C-D ve E veri setlerinden her biri 1000x2 sinyalden oluşmakta olup toplam 1000x10 EEG verisi mevcuttur. Kayıtlar $[A_1, A_2]$, $[B_1, B_2]$, $[C_1, C_2]$, $[D_1, D_2]$ ve $[E_1, E_2]$ olarak etiketlenmiş olup, her bir etiket 1000x1 niteliğinde bir vektörü ifade etmektedir. Şekil 1'de söz konusu vektörlerin örnek değişimleri gösterilmiştir [9].




Şekil 1: Örnek fare EEG değişimleri (a) A_1 Normal (b) A_2 Normal (c) B_1 Epileptik (d) B_2 Epileptik (e) C_1 Epileptik (f)

C_2 Epileptik (g) D_1 Epileptik (h) D_2 Epileptik (i) E_1 Epileptik (j) E_2 Epileptik (x eksenı ms, y eksenı μV)

2.2. Önerilen Sınıflandırma Düzenegi

Bu çalışmada işlem akışı iki aşamadan oluşmaktadır. Ön işlem olan birinci aşamada EEG kaydının karakteristik bilgilerini içeren öznitelik vektörlerinin elde edilmesi aşamasıdır. Özniteliklerin elde edilmesinde dalgacık dönüşümü ile elde edilen katsayıların istatistiksel değerleri kullanılmıştır. Elde edilen öznitelikler, önerilen düzenegin ikinci aşamasında yer alan sınıflandırma işlemine tabii tutulur. Sınıflandırma da YSA'nın en basit yapısı olan Adaline kullanılmış olup, öznitelik vektörleri Adaline'nin giriş vektörleri olarak kullanılmıştır. Oluşturulan düzenek Şekil 2'de gösterilmiştir. Sistem çıkışında, EEG kaydının sağlıklı veya epileptik olduğuna karar verilmektedir.



Şekil 2: Önerilen sınıflandırma düzenegi

2.3. Önişlem Olarak Öznitelik Vektörlerinin Hesaplanması

Öznitelik vektörlerinin hesaplanmasında, dalgacık dönüşümü ile elde edilen katsayıların istatistiksel parametreleri kullanılmıştır. Sınıflandırma işlemine ise sağlıklı (A) ve hastalıklı (B-C-D-E) olan veriler iki ayrı kümeye sınıflandırılmıştır.

Bu bölümde öncelikle dalgacık dönüşüm yöntemi ve ardından öznitelik vektörlerinin hesaplanması açıklanmıştır.

a) Dalgacık Dönüşümü (DD)

EEG işaretleri durağan olmayan işaret türündendir. Bu tür işaretlerin spektral analizinde Fourier dönüşümünün iyi sonuç vermediği bilinmektedir. Bazı çalışmalarda kısa süreli Fourier dönüşümü (KSFD) kullanılsa da özellikle seçilen pencere boyutunun sabit olmasından dolayı bu yöntem hem zaman hem de frekans boyutlarında belirsizlik ilkesi (Uncertainty principle) gereği eşit bir çözünürlük ve dolayısıyla çok iyi bir sonuç vermeyebilir.

Problemi kısmen gidermek için KSFD yerine DD kullanılmıştır [10]. DD yüksek frekanslar için küçük ve düşük frekanslar için büyük boyutlu pencere kullandığından, zaman ve frekans açısından en uygun çözünürlüğü sağlar [11]. Aşağıda Sürekli Dalgacık Dönüşüm (SDD) denklemi verilmiştir [12].

$$W(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (1)$$

Burada $x(t)$ işaretin kendisi, $W(a, b)$ dalgacık dönüşümü, ψ ana dalgacık fonksiyonu, a ölçek ve b zamanda kaydırma parametreleridir. ψ ana dalgacık a ve b ölçeklerine göre elde edilmektedir [13,14]:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi \left(\frac{t-b}{a} \right) \quad (2)$$

Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uygulamaları


2. Gün 26 Eylül 2014 Cuma (14.45-16.15)

Ana dalgacık hem frekans hem de zaman çözünürlüğünün uygun olmasını sağlar [15]. a ölçeği büyük bir değer seçildiğinde ana dalgacık genişler ve düşük frekanslı detaylar elde edilirken, a ölçeği küçük bir değer seçildiğinde ise ana dalgacık daralır ve yüksek frekanslı detaylar elde edilir.

Dalgacık dönüşümünün sürekli veya ayrık formları kullanılabilir. Ancak bu çalışma için SDD, sinyali tanımlamak için gerekenden fazla katsayı üretir ve sinyalin yeniden oluşturulmasında tüm bu parametreler gerekli olduğundan aşırı hesaplama zorluğuna neden olur. Bu yüzden dönüşüm ve ölçek değişimini kısıtlayan Ayrık Dalgacık Dönüşümünü (ADD) kullanmak uygulamada daha büyük kolaylık sağlamaktadır. SDD'de ölçek ve kaydırma parametreleri $a=2^j$ ve $b=k \cdot 2^j = k \cdot a$ ile ayrık hale getirilerek ADD temel ifadesi aşağıdaki gibi ifade edilebilir:

$$\psi(a, b) = \sum_j \sum_k x(n) 2^{-j} \psi(2^{-j}n - k) \quad (3)$$

Burada $x(n)$ işaretin kendisi ve ψ ana dalgacıktır. Logaritmik ve dengeli yapıya sahip çok frekanslı süzgeç banklarıyla AD analizi yapılabilir [14]. ADD ile işaret yüksek geçiren filtreye sokularak ayrıntı (detail) katsayıları ve alçak geçiren filtreye sokularak yaklaşık (Approximate) katsayıları elde edilir. Bu işlemler elde edilen ayrıntı veya yaklaşık frekans bantlarında istenilen çözünürlük elde edilinceye kadar Şekil 3 de gösterildiği gibi tekrar edilir. Şekilde de görüldüğü gibi ayrık $x[n]$ sinyali yüksek-geçiren filtreden (YGF) geçerek detay katsayıları ($D_i[n]$) ve alçak geçiren filtreden (AGF) geçerek yaklaşık katsayıları ($A_i[n]$) elde edilir.



Şekil 3: Ayrık $x[n]$ işaretinin alt bantlara ayrıştırılması

Bu ayrıştırma işleminin zaman alanındaki matematiksel ifadesi $g[n]$ ve $h[n]$ sırasıyla yüksek-geçiren ve alçak-geçiren filtreler olmak üzere aşağıdaki gibi ifade edilir:

$$h_{i+1}(k) = \sum_n h_i[n] h[2k - n] \quad (4)$$

$$g_{i+1}(k) = \sum_n h_i[n] g[2k - n]$$

Her ayrıştırma seviyesinde yarım-band filtreler frekans bandının yarısını içeren sinyaller oluşmasını sağlar.

Bu çalışmada, Daubech 5 dalgacığı kullanılmış olup, sınıflandırmada başarıya olan etkisi incelenmeye çalışılmıştır.

b) Öznitelik Vektörlerinin Hesabı

Fare EEG işaretlerinin dalgacık dönüşümü (Daubech 5) kullanılarak, her 5 denek için 2-3-4-5 seviyelerinde en yüksek yaklaşık ve detay dalgacık katsayıları hesaplanmıştır. Örneğin 5. seviye için kullanılan katsayılar; cA5 ve cD5 dir. Katsayıların farklı seviyelerde hesaplanmış olmasının sebebi, seviyenin performansa etkisini görebilmektir. Katsayıların ortalama, standart sapma, maksimum, minimum değeri hesaplanarak her denek için öznitelik vektörü hesaplanmıştır. Her denek için 1x4 lük bir öznitelik vektörü hesaplanmıştır. Böylelikle her küme ($A_1, A_2, B_1, B_2, C_1, C_2, D_1, D_2, E_1, E_2$)

için toplam 10 adet 1x4 lük öznitelik vektörü hesaplanmıştır. Bunlardan A_1 ve A_2 olanı sağlıklı, diğer kümeler ise hastalıklı sınıf olarak değerlendirilmiştir.

2.4. Öznitelik Vektörlerinin Sınıflandırılması


Elde edilen öznitelik vektörleri Adaline için eğitim kümesi olarak kullanılmıştır. Toplam 10 örüntü olduğu ve bunlardan 2 tanesi sağlıklı, 8 tanesi ise hastalıklı olan örüntülerdir. Her örüntü 4 adet data point içerdiğinden ötürü, Adaline 4 girişli bir YSA yapısına sahiptir. Adaline'nın 1 çıkışı olacak şekilde tasarlanmıştır. Çıkışın 1 olması durumunda, giriş örüntüsünün sağlıklı olduğu, 0 olması durumunda ise örüntünün hastalıklı olduğu anlamına gelmektedir. Aşağıda Adaline konusuna ilişkin temel bilgiler verilmiştir.

a) Adaptive Linear Nöron (Adaline)

YSA'nın oluşturulması temel manada biyolojik sinir sisteminin yapısı dikkate alınarak geliştirilmiştir. Bir yapay sinir ağı katmanlar şeklinde birbirleriyle bağlantılı hücreler ve bunları birbirine bağlayan ağırlıklardan oluşmaktadır. Bir YSA'daki en önemli unsurlardan biri de sinir hücrelerinin birbirlerine veri aktarımını orantısız olarak ayarlayan bağlantılar arasındaki katsayılardır.

1959'da, Stanford Üniversitesinden Bernard Widrow, basit nöron benzeri elemanlara dayanan ve Adaline olarak adlandırılan bir adaptif lineer elemanı geliştirmiştir. Adaline yapısı sinir ağlarının en basit yapısı olup, öğrenme için danişmanlı öğrenme kullanır. Adaline ve iki tabakalı biçimi olan Madaline (Multiple Adaline) çok farklı uygulamalarda kullanılabilir. Adaline bir çok uygulama için oldukça iyi çalışmasına rağmen lineer problem uzayıyla sınırlıdır. Aktivasyon fonksiyonu olarak lineer transfer fonksiyonu kullanılır. Giriş ve istenilen çıkış örüntülerinin tekrar tekrar ağı uygulanmasıyla eğitim süreci gerçekleştirilir. Örüntülerin doğru sınıflara ayrılmasıyla, hatalar minimize edilerek öğrenme gerçekleştirilir. Eğitimden sonra adaline, yeni girişleri kazandığı deneyime göre sınıflandırabilir [7].

Şekil 4'te örnek bir Adaline yapısı verilmiştir.



Şekil 4: Adaline için genel yapı

Sinir ağının çıkışı global olarak;

$$y(t+1) = F\left(\sum_{j=1}^n W_{ij} x_j(t) - \theta_i\right) \quad (5)$$

Şeklinde ifade edilir [16]. Burada x_j ağı giriş değişkenleri, W_{ij} hücreler üzerindeki etkisini belirten ağırlık değeridir. W_{ij} ve x_j çarpılması ile aktivasyon fonksiyonunun girişi için bir veri oluşturmaktadır. $F(x)$ aktivasyon fonksiyonunu ve θ_i eşik değerini belirtmektedir.

Adaline eğitim sürecinde izlenen yol; örüntü ağı uygulanır ve ağı çıkışı elde edilir. Uygulanılan örüntünün ağı çıkışında beklenen değeri ile ağı çıkışının farkı alınır.



Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uygulamaları

2. Gün 26 Eylül 2014 Cuma (14.45-16.15)

Elde edilen hata, giriş örüntüsü ve öğrenme katsayısı ile çarpılarak, ağırlığın güncellenme değeri bulunur.

b) Sınıflandırma Uygulamasının Sonuçları

Bu çalışmada dalgacık ailelerinin sınıflandırma üzerindeki etkisini bulmak için db5 dalgacığı kullanılarak her denek seti için farklı seviyelerde katsayıların istatistiksel değerleri hesaplanmıştır. Kullanılan seviyeler 2, 3, 4 ve 5 dir. Her seviyenin katsayılarının istatistik değeri, Adaline girişine uygulanarak, sistemin performansı gözlemlenmiştir. Katsayı olarak her seviyenin en yüksek derecedeki katsayılar kullanılmıştır. Kullanılan katsayılar Tablo 1’de gösterilmiştir.

Tablo 1: Seviyeye göre kullanılan katsayılar

	2. seviye	3. seviye	4. seviye	5. seviye
Kullanılan katsayılar	cD2	cD3	cD4	cD5
	cA2	cA3	cA4	cA5

Kullanılan katsayıların istatistiksel değerleri Adaline yapısında eğitilmiştir. Adaline için rastgele belirlenen başlangıç ağırlık ve ϕ değerleri kayda alınmış olup, her eğitimde bu değerler sabit olarak kullanılmıştır. Bu değerler, $w=[1 \ 2 \ -1 \ -3]$, $\phi=-1$ ve öğrenme katsayısı $\lambda=0.5$ dir.

Eğitim işlemi sonunda tüm eğitim işleminin %100 başarımın elde edildiği görülmüştür. Eğitim aşamasında göze çarpan bilgiler Tablo 2’de gösterilmiştir.

Tablo 2: Adaline’nın eğitimde seviyenin etkisi

	2. seviye	3. seviye	4. seviye	5. seviye
İterasyon/katsayı	6/cD2	6/cD3	7/cD4	14/cD5
İterasyon/katsayı	16/cA2	19/cA3	664/cA4	204/cA5

Tablodan görüldüğü üzere, detay katsayılarının daha az iterasyonla sonuca yakınsadığı görülmektedir.

3. Sonuçlar

Bu çalışmada, WAG/Rij türü erkek farelerin sağ ve sol frontal korteks’ten alınan EEG kayıtları kullanılmıştır. Kayıtlar, sağlıklı (veri seti A) ve hastalıklı (veri seti B,C,D,E) olmak üzere iki gruptan oluşmaktadır. Bu çalışmada, iki farklı işaretlerin iki ayrı -sınıfa ayrıştırılması amaçlanmıştır. Ön işlem olarak, kayıtlardaki her deneğin, Daubech 5 dalgacığı ile farklı seviyelerde (2,3,4 ve 5) dalgacık katsayıları elde edilmiştir. Katsayı olarak seviyenin en üst derecesi olan katsayılar kullanılmıştır (Tablo 1). Katsayıların ortalama, standart sapma, maksimum ve minimum değerleri, her deneğin öznelik vektörü olarak değerlendirilmiştir. Bu öznelik vektörleri, yapay sinir ağlarının (YSA) en basit yapısı olan Adaptive Linear Nöron (Adaline) için eğitim kümesi olarak kullanılmıştır. EEG işaretleri, Adaline ile sağlıklı ve hastalıklı olmak üzere iki ayrı sınıfa ayrıştırılmıştır. Farklı seviyelerde ve farklı katsayılarla yapılan analizlerde, %100 başarı elde edilmiştir. Her eğitim işleminde elde edilen başarımın %100 olması, önerilen öznelik vektörlerinin etkin rol oynadığını gösterir. Tablo 2’den görüldüğü üzere, seviye yükseldikçe ağın eğitim aşamasındaki iterasyon sayısının arttığı görülmüştür. Bu durum, işaretlerin karakteristiklerinde bozulmaların oluştuğu şekilde yorumlanabilir.

4. Kaynakça

- [1] Mohammad, N., Achmad, J., Mohamad, A.M., Automatic Detection of Epileptic Spikes Based on Wavelet Neural Network. IEEE APCCAS Asia- Pacific Conference on Circuits and Systems, 2002, 2, 483–486.
- [2] Kalaycı, T., 1996. EEG Dikenlerini Yapay Sinir Ağlarıyla Tanınması. Ege Üniversitesi Sağlık Bilimleri Enstitüsü, Doktora Tezi, 52s, İzmir.
- [3] Wan, B., Dhakal, B., Qi, H., Zhu, X., Multi-method Synthesizing to Detect and Classify Epileptic Waves in EEG. IEEE Proceedings of the Fourth International Conference on Computer and Information Technology, 2004.
- [4] Saraoğlu, H.M., 1998. Beyin Sinyallerinin Geri Yaymalı Yapay Sinir Ağı ile Eğitilmesi ve Haritalanması. Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, 131s, Sakarya.
- [5] Güler, İ., Übeyli, E.D., Çok Katmanlı Perseptron Sinir Ağları ile Diyabet Hastalığının Teşhisi. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 2006, 21(2), 319–326.
- [6] Daubechies, I., The Wavelet Transform, Time-Frequency Localization and Signal Analysis. IEEE Transactions on Information Theory, 1990, 36(5), 961–1005.
- [7] Batar, H., “EEG İşaretlerinin Dalgacık Analiz Yöntemleri Kullanılarak Yapay Sinir Ağları İle Sınıflandırılması”, Yüksek Lisans Tezi. Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, 2005.
- [8] Toprak, İ.B., “EEG Sinyallerinin Dalgacık Dönüşümü Ve Yapay Sinir Ağları İle Analizi”, Yüksek Lisans Tezi. Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, 2007.
- [9] The EEG signals can be downloaded from <http://www.vis.caltech.edu/~rodri/>
- [10] Grossman A. and Morlet J., “Decomposition of Hardy functions into square integrable wavelets of constant shape,” SIAM J. Math., vol. 15, pp. 723–736, 1984.
- [11] Englehart, K., Hudgins, B., Parker, P.A., A Wavelet-based continuous classification scheme for multifunction myoelectric control, IEEE Transactions on Biomedical Engineering, 48, 302–311, 2001.
- [12] Vetterli M. and Herley C., “Wavelets and filter banks: theory and design,” IEEE Trans. Signal Processing, vol. 40, pp. 2207–2232, 1992.
- [13] Daubechies I., “Orthonormal bases of compactly supported wavelets,” Commun. Pure Appl. Math., vol. XLI, pp. 909–996, 1988.
- [14] Mallat S. G., “A theory for multiresolution signal decomposition: the wavelet representation,” IEEE Trans. Pattern Analysis and Machine Intelligence, vol. 11, pp. 674–693, 1989.
- [15] Cohen A. and Kovacevic J., “Wavelets: the mathematical background,” Proceeding of the IEEE, vol. 84, pp. 514–522, 1996.
- [16] Karabatak, M., İnce, M., An expert system for detection of breast cancer based on association rules and neural network. Expert Systems with Applications, 36, 3465–3469, 2009.