



Dalgacık Katsayıları ve Yapay Sinir Ağları Kullanılarak EEG İşaretlerinin Sınıflandırılması Classification of EEG Signals by using Wavelet Coefficients and Artificial Neural Networks

Hasan Polat¹, Mehmet Sıraç Özerdem²

¹ Mühendislik-Mimarlık Fakültesi
Muş Alparslan Üniversitesi
h2.polat@alparslan.edu.tr

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

Özetçe

Bu çalışmada EEG işaretlerinin dalgacık katsayıları kullanılarak yapay sinir ağı ile farklı EEG küme çiftlerinin sınıflandırılması amaçlanmaktadır. Çalışmada kullanılan EEG işaretleri Bonn Üniversitesinden alınmış olup ve her biri 100 bölüme ayrılan beş farklı kümeye (A,B,C,D,E) aittir. A ve B kümeleri sağlıklı kişilerden alınmış olup sırasıyla gözler açık ve kapalıdır. C ve D kümeleri epileptik hastalara ait olup sırasıyla nöbet öncesi hipokampal karşı yarım küreden ve epileptik bölgeden kayıt edilen EEG sinyalleridir. E kümesi ise nöbet esnasında ve elektrotlar epileptik bölgede konumlandırılarak kayıt edilen EEG sinyallerinden oluşmaktadır. EEG işaretlerinin farklı alt bantlarındaki dalgacık katsayıları öznelik vektörleri olarak ele alınıp ve elde edilen bu öznelik vektörlerin boyutları istatistiksel özellikler kullanılarak azaltılmıştır. Bu çalışmada sırasıyla kullanılan EEG küme çiftleri; A-B, A-C, A-D ve A-E veri kümeleridir. Bu EEG kümeleri kendi içinde yapay sinir ağlarıyla sınıflandırılmıştır. Farklı EEG küme çiftleri için sınıflandırma doğrulukları sırasıyla A-B veri setleri için %92, A-C veri setleri için %97, A-D veri setleri için %94 ve A-E veri setleri için %99 olarak elde edilmiştir.

Abstract

The aim of this study was to classify different sets of EEG signals by using wavelet coefficients and artificial neural networks. EEG data that used in this study have been acquired from database of University of Bonn. The complete data consists of five sets (A,B,C,D,E), each one containing 100 EEG segments. Sets A and B were taken from healthy volunteers with eyes open and eyes closed, respectively. Set C were recorded from the hippocampal formation of the opposite hemisphere of the brain and set D were recorded from within the epileptogenic zone. Sets C and D measured during seizure free intervals. Set E were taken within the epileptogenic zone and contain only seizure activity. Wavelet coefficients in different sub-bands of EEG were assumed as feature vector and statistical features were used to reduce

dimension of feature vector. In this study different EEG cluster pairs consisting of A-B, A-C, A-D and A-E data groups were classified by artificial neural network. Classification accuracies of EEG cluster pairs were obtained as 92% for A-B, 97% for A-C, 94% for A-D and 99% for A-E.

1. Giriş

Dünya nüfusunun yaklaşık olarak %1'i epilepsi hastalığına katlanmaktadır [1]. Beyin fonksiyonlarının geçici elektriksel bozuklukları epileptik nöbetlere sebep olur. Bazen gerçekleşen bu nöbetler gösterdikleri etkiye göre fark edilmeyebilirler. Bazen de farklı olaylarla örneğin felç gibi durumlarla karıştırılabilirler. En büyük sorunlardan biri epileptik nöbetlerin gerçekleşme anının önceden tahmin edilememesi ve oluşan bu nöbetlerin nedenlerinin yeterince anlaşılabilmesidir [2]. Epileptik nöbetlerin otomatik olarak tespiti için sayısal modellerin geliştirilmesine daha fazla odaklanıldığı günümüz çalışmalarında görülmektedir.

Elektroensefalogram (EEG) sinyalleri epileptik nöbetlerin nedenlerinin anlaşılması için değerli bilgiler taşır [3]. EEG sinyallerinin spektral analizi beynin aktiviteyi hakkında bilgiler sağlamaktadırlar. Bu çalışmada da EEG işaretleri kullanılarak, nörolojik işaretlerin sınıflandırılabilmesine ilişkin bir uygulama gerçekleştirilmiştir.

Yapay sinir ağı (YSA) klasik spektral analizinin aksine sinyal modellemenin yanında sinyalin ilgili sınıfı hakkında karar verebilme yetisine sahiptir [2,4]. Bu yüzden YSA, kullanıcılara özellikle medikal teşhiste önemli destekler sağlayabilmektedir.

YSA ile sınıflandırma işlemleri literatürde sıklıkla kullanıldığı görülmektedir. Biyolojik işaretlerin ayrıştırılmasında (hasta/normal, vb.) doğrudan işaretlerin sınıflandırıcıda eğitim kümesi olarak kullanılması, sistem performansını negatif yönde etkilemektedir. Bunun yerine işaretlerin öznelikleri elde edilir ve öznelikler üzerinden işaretlerin ayrıştırılması sağlanır. Öznelikler işaretlere ilişkin önemli karakteristik bilgileri içeren veri kümesi olarak tanımlanabilir.

Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uygulamaları

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

Literatürde öznitelik vektörlerinin sınıflandırılmasına ilişkin birçok çalışma görmek mümkündür. Özellikle EEG işaretlerinin sınıflandırılmalarına ilişkin benzer çalışmaların bazıları şunlardır; EEG işaretlerinin dalgacık özellik çıkarımı ve bir uzman karışım modeli ile EEG işaretlerinin sınıflandırılması [2], EEG işaretlerinin Sınıflandırılması için dalgacık katsayıları kullanan birleştirilmiş sinir ağı modeli [5], Öznitelikler üzerinde istatistikler: EEG sinyal analizi [6] ve K ortalama kümeleme ve çok katmanlı perseptron sinir ağı modeli kullanarak EEG işaretlerinin sınıflandırılmasıdır [7].

Bu bildiri çalışmasında yukarıda sözü edilen çalışmalara benzer bir çalışma yapılmıştır. Sağlıklı gözleri açık (A) kişilerden alınan EEG kayıtları, sırasıyla aşağıda belirtilen EEG türleri ile sınıflandırılmıştır.

- Sağlıklı gözler kapalı (B) kişilerin alınan EEG işaretleri
- Epileptik hasta (C) olup nöbete geçiş sürecinde hipokampal karşı yarım küreden kayıt edilen EEG işaretleri
- Epileptik hasta (D) olup nöbete geçiş sürecinde ve elektrotlar kafatasında epileptik bölgeye yerleştirilerek kayıt edilen EEG işaretleri
- Epileptik hasta (E) olup nöbet sırasında ve elektrotlar kafatasında epileptik bölgede konumlandırılarak alınmış EEG işaretleri

A-B, A-C, A-D ve A-E kayıtları için kendi içerisinde ayrı olarak dört ayrı sınıflandırma işlemi yapılmıştır. Her bir çalışmanın doğruluk performansı değerlendirilmiştir.


2. Materyal ve Metot

2.1. Veri Seti

Bu çalışmada kullanılan EEG verileri Bonn Üniversitesi veritabanından alınmıştır [8]. Toplam veri seti beş kümeden (A,B,C,D,E) oluşmaktadır. Her bir kümede 23.6sn süreli ve tek kanallı 100 bölüt yer almaktadır. A (gözleri açık) ve B (gözleri kapalı) kümeleri standart 10-20 uluslar arası elektrot konumlandırma sistemi kullanılarak alınmış EEG kayıtlarıdır. C ve D kümeleri nöbet öncesi sırasıyla hipokampal karşı yarım küre ve epileptik bölgeden kayıt edilen EEG sinyalleridir. E kümesi ise nöbet esnasında ve elektrotlar epileptik bölgede konumlandırılarak kayıt edilen EEG sinyallerinden oluşmaktadır. Kayıt edilen EEG sinyalleri 0.53-40Hz bant geçiren filtre ile filtelenmiştir. Filtrelenen EEG sinyalleri örnekleme hızı 173.61Hz olan 12 bit analog sayısal dönüştürücü ile sayısallaştırılmıştır. Sırasıyla A, B, C, D ve E veri kümelerinden alınan örnek EEG bölütleri şekil 1' de gösterilmiştir.

2.2. Dalgacık Dönüşümü

Durağan olmayan özellikler barındıran sinyallerin spektral analizi için dalgacık dönüşümünün diğer spektral analiz metotlarına göre avantajları vardır. Dalgacık dönüşümünün en önemli avantajı düşük frekanslar için geniş pencereler, yüksek frekanslar için ise dar olacak şekilde değişebilen pencereler kullanmasıdır. Bu özelliğinden dolayı sinyalin farklı frekans bileşenleri için başarılı bir şekilde zaman-frekans çözünürlüğü sağlamaktadır [1,9-11].



Şekil 1: A,B,C,D ve E kümelerinden alınan EEG örnekleri. Grafiklerde x eksenı ms, y eksenı μV 'u ifade eder.

Dalgacık dönüşümünün, sürekli ve ayrık dalgacık dönüşümü olmak üzere iki yaklaşımı vardır. Sürekli dalgacık dönüşümde hesap yükü oldukça fazladır. Hesap yükünü azaltmak için Ayrık Dalgacık Dönüşümü (ADD) kullanılır. Sürekli dalgacık dönüşümü matematiksel ifadesi denklem 1'de verilmiştir.

$$C(\tau, s) = \frac{1}{\sqrt{s}} \int_{\tau} f(t) \psi \left(\frac{t-\tau}{s} \right) dt \quad (1)$$


Denklem 1'de τ öteleme parametresi s ise ölçekleme parametresidir. ψ_t ise ana dalgacığı temsil etmektedir. Sürekli dalgacık dönüşümünde her bir ölçek için dalgacık katsayılarını bulmak oldukça büyük veri yığınlarının oluşmasına neden olacaktır. Aynı zamanda sürekli dalgacık dönüşümü zaman alıcı hesaplamalar gerektirmektedir. Bu gibi dezavantajlardan dolayı ölçek (scale) ve pozisyonların (shift) belli bir basamağa göre seçip ve bu şekilde yapılacak analizler daha az hesaplama yükü ve daha verimli sonuçlar sunacaktır. Bu şekilde analizlerin yapılabilmesi ayrık dalgacık dönüşümü ile mümkündür. Ayrık dalgacık dönüşümü ölçekleme ve dalgacık fonksiyonunu kullanır. Ölçekleme fonksiyonu alçak geçiren filtreyi, dalgacık fonksiyonu ise yüksek geçiren filtreyi temsil eder. Sinyalin farklı bantlara ayrışımı ardışık olarak zaman alanında yüksek ve alçak geçiren süzgeçlerle filtrelenerek gerçekleştirilir. Uygun dalgacık seçimi ve ayrıştırma seviyesi seçimi sinyalin ayrık dalgacık dönüşümü ile analiz edilmesi için oldukça önemlidir [2].

Bu çalışmada EEG sinyallerin önemli alt bantları olan delta (0,5- 4Hz), teta (4-8Hz), alfa (8-12Hz) ve beta (12 – 32Hz) bileşenlerine ayrıştırılmış. Çalışmada 5. seviyeye kadar olan katsayılar değerlendirilmeye katılmıştır.

Örnek olarak A kümesine ait sağlıklı bir EEG işaretinin 5.seviye yaklaşık ve detay dalgacık katsayıları Şekil 2'de gösterilmiştir.

Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uygulamaları

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



Şekil 2: A kümesine ait EEG sinyalinin yaklaşık ve detay dalgacık katsayılarına ayrıştırılması.

2.3. Öznitelik Çıkarma

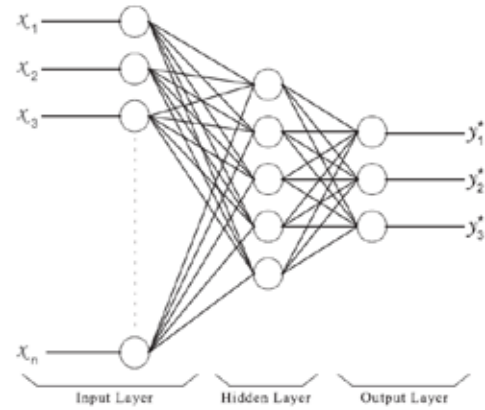
Dalgacık katsayıları, ilgili işaretlerin karakteristik özellikleri hakkında önemli bilgiler barındırmasından dolayı EEG işaretlerinin dalgacık katsayıları öznitelik vektörleri olarak ele alınmıştır [11]. Öznitelik vektör boyutlarının azaltılabilmesi için dalgacık katsayıları üzerinde istatistiksel parametreler hesaplanmıştır. Çalışmada kullanılan istatistiksel parametreler sırasıyla;

1. Her bir alt banttaki katsayıların mutlak değerlerinin ortalaması
2. Her bir alt banttaki katsayıların mutlak değerlerinin maksimumu
3. Her bir alt banttaki katsayıların ortalama gücü
4. Her bir alt banttaki katsayıların standart sapması

Bu çalışmada her küme için EEG bölütleri için A5 yaklaşık, D5, D4, D3 detay dalgacık katsayıları kullanılmıştır. Her bant için dört istatistik değerin hesaplanması ile her küme için 16 elemandan oluşan bir öznitelik vektörü elde edilmiş olur. Yukarıdaki işlemler A,B,C,D,E kümelerine ait her EEG işaretleri için uygulanmıştır. Bu şekilde elde edilen öznitelik vektörleri, YSA için eğitim ve test kümeleri olarak kullanılmıştır. Dalgacık katsayıların elde edilmesinde ve nihai olarak elde edilen öznitelik vektörlerin YSA girişine uygulanmasında, MATLAB program paketleri kullanılmıştır.

2.4. Yapay Sinir Ağları

YSA, biyolojik sinir sisteminden esinlenerek modellenir ve biyolojik sinir sistemine göre daha basit bir yapıya sahiptir. Birçok sinir ağı biyolojik sinir ağlarının öğrenme, tepki verme gibi karakteristik bir takım özelliklerine benzetilmek için geliştirilmiştir. Yapı olarak, YSA bir giriş katmanı, bir veya birden fazla gizli katman ve bir çıkış katmanından oluşur [12]. Şekil 3'de n:5:3 yapısına sahip çok katmanlı bir örnek YSA modeli verilmiştir.



Şekil 3: Çok katmanlı perceptron sinir ağı için örnek bir model yapısı [7].

Bu çalışmada kullanılan EEG işaret (A,B,C,D,E) kümelerinin birbirlerine göre farklı karakteristiklere sahip olduklarını göstermek amacıyla, sırasıyla A-B, A-C, A-D ve A-E çiftleri kendi içinde sınıflandırılmıştır. Her kümenin öznitelik vektörü toplam 16 değere sahip olduğundan, oluşturulan YSA modelinde giriş katmanı 16 nörondan oluşmaktadır. YSA'da çıkış vektörleri Tablo 1'de gösterildiği şekilde tanımlanmıştır. Bu tanımlamaya göre YSA'nın yapısında, çıkış katmanı toplam 2 nöron içermektedir.

Tablo 1: Örüntülerin hedef kümelerinin kodlanması

	A	B	C	D	E
A - B	[1 0]	[0 1]			
A - C	[1 0]		[0 1]		
A - D	[1 0]			[0 1]	
A - E	[1 0]				[0 1]

YSA'nın bir gizli katman ve gizli katmandaki nöron sayısı 10 olarak belirlenmiştir. Gizli katmandaki nöron sayısı farklı değerlerde alınarak, çeşitli testler yapılmıştır. En iyi sonucu 10 nöron içeren YSA modelinin ürettiği gözlemlenmiştir. Bu durumda oluşturulan YSA modeli 16:10:2 yapısındadır. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu seçilmiştir. Öğrenme algoritması olarak, geriye yayılım algoritması kullanılmıştır ki, literatürdeki başarılı performansına dayanarak bu yöntem seçilmiştir. İyi bir eğitim algoritması ağı kısa sürede eğitebilen, yüksek doğrulukta genelleme yapabilen algoritma olarak tanımlanır [4,12]. Öğrenme algoritmasında öğrenme katsayısı 0.7, momentum ise 0.9 değerinde alınmıştır. Eğitim ve test örüntülerinin nasıl oluşturulduğu aşağıda anlatılmıştır. Bu çalışmada ilk olarak A (sağlıklı gözler açık) ve B (sağlıklı gözler kapalı) kümeleri sınıflandırılmaya çalışılmıştır. A kümesi 100 ve B kümesi için 100 örüntü olmak üzere toplam 200 örüntü yer almaktadır. A kümesinden rastgele 35 tane ve yine rastgele 35 tane ise B kümesinden toplamda 70 tane örüntü eğitim için ayrılmıştır. A ve B'den yine rastgele 15 tanesi seçilerek, geçerlilik verisi olarak kullanılmıştır. Her kümeden kalan örüntülerden 50'şer adet örüntü test örüntüsü olarak kullanılmıştır. Bu uygulama A-C, A-D ve A-E içinde uygulanmıştır.

3. Deneysel Sonuçlar

Yapılan sınıflandırmanın performansı değerlendirmek için doğruluk önemli bir parametredir. EEG işaretlerinin



Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uygulamaları

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

sınıflandırılması işleminde doğruluk, test karışıklık (confusion matrix) matrisinden elde edilmiştir. Doğruluk hesabı denklem 2 de gösterilmiştir.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (2)$$

Doğruluk hesabında yer alan DP (Doğru Pozitif), DN (Doğru Negatif), YP (Yanlış Pozitif) ve YN (Yanlış Negatif) olarak adlandırılır.

A-B kümelerinin sınıflandırılmasında elde edilen karışıklık matrisi, Tablo 2 de gösterilmiştir. A-B veri setleri için sınıflandırma doğruluğu %92 olarak elde edilmiştir.

Tablo 2: A-B için test karışıklık matrisi

Sınıf	A	B
A	46	4
B	4	46

Diğer bir sınıflandırılan EEG işaretleri, A – C kümeleridir. YSA eğitiminden sonra elde edilen sonuçların yer aldığı test karışıklık matrisi Tablo 3 de gösterilmiştir. A-C veri setleri için sınıflandırma doğruluğu %97 olarak elde edilmiştir.

Tablo 3: A-C için test karışıklık matrisi

Sınıf	A	C
A	49	1
C	2	48

Diğer bir sınıflandırılan EEG işaretleri, A – D kümeleridir. YSA eğitiminden sonra elde edilen sonuçların yer aldığı test karışıklık matrisi Tablo 4 de gösterilmiştir. A-D veri setleri için sınıflandırma doğruluğu %94 olarak elde edilmiştir.

Tablo 4: A-D için test karışıklık matrisi

Sınıf	A	D
A	46	4
D	2	48

Son olarak sınıflandırılan EEG işaretleri, A – E kümeleridir. YSA eğitiminden sonra elde edilen sonuçların yer aldığı test karışıklık matrisi Tablo 5 de gösterilmiştir. A-E veri setleri için sınıflandırma doğruluğu %99 olarak elde edilmiştir.

Tablo 5: A-E için test karışıklık matrisi

Sınıf	A	E
A	50	0
E	1	49

Elde edilen yüksek doğruluk sonuçları, üzerinde çalışılan EEG işaret gruplarının kendilerine özgü karakteristiklerinin olduğunu göstermiştir.

Bu çalışma, literatürde yer alan çalışmalara benzer bir uygulama çalışması olup, literatürde Subaşı (2007) çalışmasında EEG işaretlerini, dalgacık özellik çıkarımı ve bir uzman karışım modeli kullanarak sınıflandırmış ve A-E veri setleri için sınıflandırma doğruluğunu %94.5 olarak elde etmiştir. Orhan, Hekim, ve Özer (2011) çalışmalarında K

ortalama kümeleme ve çok katmanlı perseptron sinir ağı modeli kullanarak EEG işaretlerini sınıflandırmış ve A-E veri setleri için sınıflandırma doğruluğunu %100 olarak elde etmiştir. Bu çalışmada elde edilen sınıflandırma doğruluklarının literatürdeki benzer çalışmalardaki doğruluk sonuçlarına yakın değerler olarak elde edildiği görülmüş ve EEG işaretlerinin kendine özgü bir karakteristiğe sahip olduğu gözlemlenmiştir. Sınıflandırmada doğruluk performansının artması özneliklerin seçimi ile ilişkilidir. Dalgacık katsayıları ile özneliklerin elde edilmesi, sınıflandırma performansını artırmıştır. Farklı alt bantlarda ki dalgacık katsayılarını öznelik vektörü olarak seçilerek ya da mevcut dalgacık katsayıları üzerinde farklı istatistiksel özellikler kullanılarak diğer veri setleri için de sınıflandırma doğruluk performansları artırılabilir.

4. Kaynakça

- [1] Adeli,H.,Zhou,Z., & Dadmehr,N., "Analysis of EEG records in an epileptic patient using wavelettransform", *Journal of Neuroscience*, 33.,69-87, 2003.
- [2] Subasi, A., "signal classification using wavelet feature extraction and a mixture of expert model", *Expert Systems with Applications*, 32., 1084-1093, 2007.
- [3] Guo, L.,Rivero, D., & Pazos, A., "Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks", *Journal of Neuroscience Method*, 193.,156-163, 2010.
- [4] Subasi, A. ve Ercelebi, E., "Classification of EEG signals using neural network and logistic regression", *Computer Methods and Programs in Biomedicine*, 78., 87-99,2005.
- [5] Ubeyli, E.D., "Combined neural network model employing wavelet coefficients for EEG signals classification ", *Digital Signal Processing*, 19., 297-308, 2009.
- [6] Ubeyli, E.D., "Statistics over features: EEG signals analysis", *Computers in Biology and Medicine*, 39., 733-741, 2009.
- [7] Orhan, U., Hekim, M., ve Özer., "EEG signals classification using the K-means clustering and a multilayer perceptron neural network model", *model Expert Systems with Applications*, 38., 13475-13481 , 2011.
- [8] 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*, 64(6)., 061907, 2001.
- [9] Daubechies I., " The wavelet transform, time-frequency localization and signal analysis",*IEEE TRANSACTIONS ON INFORMATION THEORY*, 36., 961-1005, 1990.
- [10] Hazarika ,N.,Chen, J.Z.,Tsoi,A.C., & Sergejew,A., " Classification of EEG signals using the wavelet transform ", *Signal Processing*, 59., .61-72, 1997.
- [11] Ubeyli, E. D., ve Güler, İ., "Dalgacık Dönüşümü ile EEG İşaretlerinden Çıkarılan Öznelik Vektörleri Üzerinde İstatistiksel İşlemlerin Gerçekleştirilmesi",*Elektrik Elektronik – Bilgisayar Sempozyumu*, 2004, 230-234.
- [12] Tagluk,M.E.,Akın,M.,Sezgin,N., "Classification of sleep apnea by using wavelet transform and artificial neural Networks", *Expert Systems with Applications*, 37.,1600-1607, 2010.