

EEG İŞARETLERİNİN DALGACIK SİNİR AĞI İLE SINIFLANDIRILMASI

Abdulhamit SUBAŞI* Ahmet ALKAN* Etem KOKLÜKAYA**

*Kahramanmaraş Sütçü İmam Üniversitesi, Elektrik-Elektronik Mühendisliği Böl.-46100, Kahramanmaraş,

**Sakarya Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 54187. Sakarya, Türkiye

ÖZET

Epilepsi terapisinde EEG en önemli bilgi kaynağı olduğu için, birçok araştırmacı EEG'den bu amaca uygun bilgi elde etmeye çalışmışlardır. Bu çalışmada sunulan yeni metotta, EEG'de en yüksek olabilirlik kestirimi(maximum likelihood estimation:MLE) kullanılarak elde edilen öz bağımlı (AR) ve hızlı fourier dönüşümü (HFD) metotları uygulanarak katsayılar elde edilmiştir. Bu katsayılar dalgacık sinir ağına girilerek, çıkışta epileptik veya değil şeklinde sınıflandırma gerçekleştirilmiştir. İşaretteki özelliklerin belirlenerek hekime tanı işleminde yardımcı olacak, otomatik bir sistem elde edilmesi amaçlanmıştır. MLE kullanan öz bağımlı yöntem ile dalgacık sinir ağı kullanılarak, yeni ve güvenli bir sınıflandırıcı mimarisi elde edilmiştir. Ağ, morlet ana dalgacığı temel fonksiyonunu düğüm aktivasyon fonksiyonu olarak kullanan, geri yayımlı sinir ağıyla oluşturulmuştur. Dalgacık sinir ağıyla yapılan EEG sınıflandırmasının daha iyi sonuçlar verdiği ve bu sonuçların hastalık teşhisinde kullanılabileceği görülmüştür.

Anahtar Kelimeler : EEG, Hızlı Fourier Dönüşümü (HFD) Epilepsi, AR, En Yüksek Olabilirlik Kestirimi (MLE), Dalgacık Sinir Ağı (DSA).

WAVELET NEURAL NETWORK CLASSIFICATION OF EEG SIGNALS

ABSTRACT

Since EEG is one of the most important sources of information in therapy of epilepsy, several researchers tried to address the issue of decision support for such a data. We present a novel method for classifying epilepsy of full spectrum EEG recordings. This novel method uses autoregressive (AR) model by using maximum likelihood estimation (MLE) of EEG signals as an input to a wavelet neural networks (WNNs) with two discrete outputs: epileptic seizure or non-epileptic seizure. By identifying features in the signal we want to provide an automatic system that will support a physician in the diagnosing process. By applying AR with MLE in connection with wavelet neural network, a novel and reliable classifier architecture is obtained. The network is constructed by the error backpropagation neural network using

Morlet mother wavelet basic function as node activation function. It is observed that, WNN classification of EEG signals gives better results and these results can also be used for diagnosis of diseases.

Key Words : EEG; Epileptic seizure; Autoregressive method (AR); Maximum likelihood estimation (MLE); Fast Fourier Transform (FFT); Wavelet Neural Networks (WNNs).

1.GİRİŞ

Berger'in çalışmasından itibaren EEG, hekimler ve araştırmacılar için önemli bir bilgi kaynağı olmuştur. Önceleri, EEG analizi sadece EEG kayıtlarının görsel analizi ile sınırlıydı. Uzmanlarca geliştirilen kesin kriterler olmadığından görsel analiz yetersiz kalmaktadır. Rutin klinik teşhis için EEG işaretlerinin analizine ihtiyaç duyulmaktadır. Bu sebeple bazı otomasyon ve bilgisayar tekniklerinin kullanılması gerekmektedir[1]. Bu amaçla başlangıçta Fourier tabanlı dönüşümler yaygın olarak kullanılmıştır. Bu yaklaşım EEG

spektrumunun temelde delta (1-4Hz), teta (4-8Hz), alfa (8-13 Hz) ve beta (13-30Hz) şeklinde dört frekans bandı içerdiği gözlemlerine dayanmaktaydı. Bu metodların birçok EEG tanımlaması için faydalı olduğu ispatlanmıştır. Ama hızlı fourier dönüşümü (HFD) gürültüye karşı çok hassastır. AR gibi parametrik spektrum tahmin metodları, spektral kayıp problemlerini azaltarak daha iyi frekans çözünürlüğü verir. Aynı zamanda AR metodu HFD'ne göre daha kısa süreli veri kayıtlarına ihtiyaç duyması gibi bir avantaja sahiptir [2].

Weng, Khorasani [3] ve Pradhan [4] başta olmak üzere birçok araştırmacı sinir ağı kullanan sistemleri önermişlerdir. Pradhan ham EEG datasını sinir ağına giriş olarak kullanırken, Weng, Gotman [5] tarafından önerilen özellikleri uyarlamalı sinir ağıyla kullanmıştır. Ama elde ettiği sonuçlar düşük hata sezme oranlıdır. Osaria ve arkadaşları ECoG kayıtlarına dalgacık dönüşümü uygulamıştır. Kullanılan dalgacık ölçeği yaklaşık 5-40 Hz'lik band geçiren filtreye karşılık gelmektedir. Çıkışın karesi alınmış, medyan filtrelenmiş ve son olarak daha önceki bir ölçüyle karşılaştırılmıştır. Qu ve Gotman [6] epilepsi başlangıcını belirlemek için hem zaman hem de frekans bölgesinden çıkartılan EEG özellikleri üzerinde en yakın komşuluk sınıflandırmasının kullanımını önermişlerdir. Petrosian ve arkadaşları [7] epilepsiyi oluşmadan tahmin etmek için, özel olarak eğitilmiş ve dizayn edilmiş dalgacık ön işlemeli özyinelemeli sinir ağına (RNN) başarıları araştırılmıştır. Kalaycı ve Özdamar [8] giriş ve çıkış verisi işaretin karakteristik özelliklerinin belirlenmesi için işlenmesinde yapay sinir ağına daha başarılı olduğunu göstermiştir. EEG dikenlerinin otomatik belirlenmesinde dalgacık yapay sinir ağı kullanılmışlardır.

Dalgacık teorisi , dalgacık sinir ağlarının yaklaşıklık özelliklerinin anlaşılmasına ve hızlı öğrenme için sezgisel başlatma sağlamak için kullanılabilir. EEG işaretlerinin uygun ifadesinin bulunması güvenilir ayrıştırma öğrenme ve çıkartılan ilişkileri anlamada anahtardır. Amaç EEG kaydı ve klinik veriyi giriş olarak alıp, kaydın anormal olup olmadığı ve klinik bir yorum çıktısı şeklinde hüküm oluşturmaktır. Ham EEG zaman serilerini YSA için giriş olarak kullanmak uygulanabilir değildir. Bu sebeple bazı işleme ve veri azaltma tekniklerine ihtiyaç duyulur. YSA 'na giriş olarak belli frekans bantlarının güç içeriklerini kullanmak uygun olmaktadır.

Bu çalışmanın amacı, insan EEG'sinden sınıflandırılabilir bilginin çıkartılmasında en yüksek olabilirlik tahmini (MLE) kullanan AR modeli kullanımının uygulanabilirliğinin araştırılmasıdır. Çalışmanın başarıları farklı durumların doğru olarak sınıflandırılması için gerekli bilgi içeren bir işaret sunumunun bulunmasına bağlıdır. Burada bu amaç için MLE kullanan AR modeli kullanılmıştır. Bu model baz alınarak değişik özellikler dalgacık sinir ağıyla sınıflandırılmıştır. Ayrıştırma tek bir görev çifti arasında yapılmıştır. MLE kullanan AR ön işlemesi HFD'ne göre daha iyi sınıflandırma sonuçları vermiştir.

2.MATERYAL VE METOT

2.1. EEG Veri Toplanması

Çalışmada kullanılan EEG verileri Dicle Üniversitesi Tıp Fakültesi Hastanesinden alınmıştır. Alınan EEG verileri değişik yaşlardan sağlıklı ve hasta (epilepsi geçiren) kişilere aittir. Mevcut EEG verileri kişisel bilgisayar ortamında analiz edilmiştir. Bu amaçla veri toplama kartı (DAQ), işaret düzenleyiciler ve kişisel bilgisayardan oluşan veri toplama sistemi ile gerçek EEG işareti bilgisayar ortamına aktarılmıştır. Çalışmanın gerçekleştirilmesi için TÜBİTAK tarafından sağlanan PCI-MIO-16-E4 tipi yüksek performanslı veri toplama (Data Acquisition) kartı kullanılmıştır. Bu kart, bilgisayarın PCI veri yoluna takılmış olup bu kart yardımıyla alınan veriler hızlı bir şekilde bilgisayarın hafızasına aktarılabilmektedir [9].

2.2. Autoregressive Parametre Tahmini ve MLE

Kararlı ve performansı yüksek bir AR modeli elde etmek için bazı etkenlerin göz önünde bulundurulması gerekmektedir. Bunlar, modele göre algoritma seçimi, model derecesi seçimi, modellenen işaretin uzunluğu ve verinin durağanlık derecesi olarak sıralanabilir. AR modelde Yule-Walker eşitliklerinin çözümünde En Yüksek Olabilirlik Kestirimi(MLE) kullanılmıştır. Model derecesi seçiminde Akaike kriteri dikkate alınmış ve belirlenen model derecesi düşük olduğundan $p=10$ alınmıştır. AR yönteminde model derecesinin seçimi çok önemlidir. Seçilen derece düşük olduğunda, spektrumda belirgin tepelikler oluşmaz, yani işaretin frekans içeriği net olarak belirlenemez. Model derecesi çok yüksek olduğunda ise yanıtıcı, hatalı pikler oluşur ve spektrum bozulur [1].

AR modelde, model parametrelerinin belirlenmesi için Yule-Walker eşitsizliklerinin çözümünü kullanan Levinson-Durbin algoritması kullanılmıştır. Yule-Walker metodunda veriden özilişki (autocorrelation) tahmini yapılır. Daha sonra da bu özilişkidenden AR model parametreleri tahmin edilir. Bu amaçla özilişki tahmininin yanlı (biased) formu kullanılır.

$$r_{xx} = \frac{1}{N} \sum_{n=0}^{N-m-1} x(n).x(n+m) \dots \dots \dots m \geq 0 \quad (1)$$

Çalışmada kaydedilmiş EEG verisinden , AR(autoregressive) model parametrelerinin tahmini için en yüksek olasılık tahmini (MLE) kullanılmıştır. Uygun şartlar yerine getirildiğinde , parametrenin MLE tahmini tutarlı(consistent), asimtotik olarak yanlı (unbiased), verimli ve normal dağılımlıdır. MLE tahmincisinin eldesi çok zor ve kullanışsızdır. Özellikle EEG'de log-likelihood yaklaşımının maksimizasyonu kullanılarak model parametrelerinin tahmini önerilmektedir. Whittle yaklaşımı olarak ta adlandırılan bu yöntem Gauss dağılımlı rastgele olaylar için MLE tahmininin özelliklerini asimtotik olarak sağlar [2].

Büyük boyutlu kovaryans matrisinin tersinin alınması gereğinden dolayı güç olasılık yoğunluk fonksiyonu gauss olan birçok durumda MLE parametre tahmini zordur. Eğer $x \propto N(0, c(\theta))$, ise θ 'nın MLE'si

$$P(x; \theta) = \frac{1}{(2\pi)^{n/2} \cdot \det(c(\theta))} e^{-1/2 X^t \cdot c^{-1}(\theta) X} \quad (2)$$

nin maksimizasyonu ile bulunur. Eğer kapalı formda kovaryans matrisinin tersi bulunamazsa , aranacak her θ değeri için NxN matrisin tersini veren bir teknik gerekir. Alternatif bir yaklaşım metodu, eğer x sıfır ortalamalı rastgele bir gauss işlemi ise kovaryans matrisi Toeplitz'dir. Böyle bir durumda log-likelihood fonksiyonu

$$\ln P(x, \theta) = -\frac{N}{2} \ln 2\pi - \frac{N}{2} \int_{-1/2}^{1/2} \left[\ln P_{xx}(f) + \frac{I(f)}{P_{xx}(f)} \right] df \quad (3)$$

olur. Burada

$$I(f) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n) \cdot e^{-j2\pi fn} \right|^2 \quad (4)$$

verinin periodogramı ve P_{xx} ise spektral güç yoğunluğudur[1].

Log - likelihood fonksiyonunun θ 'ya bağımlılığı spektral güç yoğunluğundan dolayıdır. θ 'ya göre türev alırsa;

$$\frac{\partial \ln P(x, \theta)}{\partial \theta} = -\frac{N}{2} \int_{-1/2}^{1/2} \left[\frac{1}{P_{xx}(f)} - \frac{I(f)}{P_{xx}^2(f)} \right] \frac{\partial P_{xx}(f)}{\partial \theta} df \quad (5)$$

$$\text{veya} \int_{-1/2}^{1/2} \left[\frac{1}{P_{xx}(f)} - \frac{I(f)}{P_{xx}^2(f)} \right] \frac{\partial P_{xx}(f)}{\partial \theta} df = 0 \quad (6)$$

bu ifade verinin periodogramı ve $P_{xx}(f)$ 'de spektral güç yoğunluğudur. Bu durum daha basit tekrarlı uygulamalara yol açar ve daha çok kullanılır.

MLE 'yi bulmak için log - likelihood ' un asimtotik formu kullanılacaktır. Spektral güç yoğunluğu

$$P_{xx}(f) = \frac{\delta_u^2}{|A(f)|^2} \quad (7)$$

olarak bilindiğinden , yapılan türetimler sonucu[6] tahmin edilen özilişki ;

$$\hat{R}_{xx}(k) = \begin{cases} \frac{1}{N} \sum_{n=0}^{N-1-|k|} x(n)x(n+|k|) \dots \dots \dots & |k| \leq N-1 \\ 0 \dots \dots \dots & |k| \geq N \end{cases} \quad (8)$$

olur. AR filtre parametreleri yaklaşık MLE 'leri için çözülecek eşitlikler ;

$$\sum_{l=1}^p \hat{a}(l) \hat{R}_{xx}(k-l) = -\hat{R}_{xx}(k) \dots \dots \dots k = 1, 2, \dots, p \quad (9)$$

Bu eşitlikler doğrusal tahminde özilişki (autocorrelation) metodu olup, tahmin edilen Yule-Walker eşitlikleri diye bilinirler. Dikkat edilirse , buradaki matris özel bir matris (Toeplitz) olup Levinson metoduyla tekrarlamalı çözüme izin verir [1]. Açık bir varyans ifadesi için , varyansın MLE 'si ;

$$\hat{\delta}_u^2 = \sum_{k=0}^p \hat{a}(k) \hat{R}_{xx}(-k) = \sum_{k=0}^p \hat{a}(k) \hat{R}_{xx}(k) \quad (10)$$


olur. Elde edilen bu parametreler ;

$$P_{xx}^{YW}(f) = \frac{\hat{\delta}_u^2}{\left| 1 + \sum_{k=1}^p \hat{a}(k) e^{-j2\pi f k} \right|^2} \quad (11)$$


ifadesinde kullanılarak AR spektral güç yoğunluğu hesaplanır.

2.3. EEG İşaretlerinin Spektral Analizi

Bu çalışmada Matlab yazılımı kullanılarak EEG işaretlerinin HFD ve MLE optimizasyonuna sahip AR metotları kullanılarak analizi yapılmıştır. Şekil.1'de epileptik EEG işareti ve onun Hızlı Fourier Dönüşümü verilmiştir. HFD spektrumu incelendiğinde, 1 ve 3Hz de pik değerler görülmektedir. İşaretin AR spektrumu şekil.2'de verilmiş olup, burada 3 Hz de yüksek genlikli olmak üzere 6, 9.5 ve 13.5 Hz değerlerinde de pikler görülmektedir. Bu iki spektrum incelendiğinde MLE optimizasyonuna sahip AR spektrumundaki frekans çözünürlüğünün daha net ve yanıltıcı tepelerin daha az olduğu dikkat çekmektedir. Bu sebeple AR spektrumu ile elde edilen spektrumun yorumlanması ve işaretin içindeki aktivitelerin belirlenmesi daha kolaydır. İşaret bir epileptik işaret olduğundan , epilepsinin tipik özelliği olan düşük frekanslarda yığılma (2 ile 4 Hz arası) yani delta aktivitesi net bir şekilde görülmektedir [1].

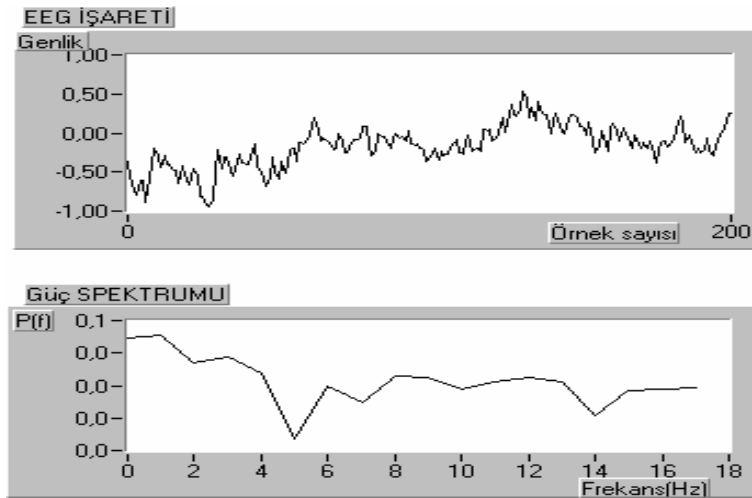


Şekil.1. Epileptik EEG işareti ve onun Hızlı Fourier Dönüşümü




Şekil.2. EEG işaretinin MLE kullanılarak elde edilen güç spektrumu.

Şekil 4.'te ise MLE kullanılarak elde edilen AR spektrumu görülmektedir. İki spektrum incelendiğinde AR spektrumunda frekans netliğinin HFD'ye göre daha iyi olduğu görülmektedir. HFD spektrumunda, piklerin geniş ve hatalı yorumlamaya yol açacak şekilde girintili çıkıntılı olduğu dikkat çekerken bu durum AR spektrumunda piklerin daha keskin olmasından dolayı daha azdır. Kaydedilen EEG işaretinin normal olduğu baskın olan alfa ve delta aktivitelerinden anlaşılmaktadır. HFD spektrumunda varyasyonun fazla olması alfa ve delta aktivitelerinin net bir şekilde görülmesini engellemektedir.



Şekil 3'te sağlıklı bir insandan alınan normal EEG işareti ve Hızlı Fourier Dönüşümü (HFD)'ne ait spektrum verilmiştir.



Şekil.4. EEG işaretinin MLE kullanılarak elde edilen güç spektrumu

2.4.Dalgacık Sinir Ağları

Yapay Sinir Ağlarında (YSA) giriş ve çıkış arasında ilişki ağın davranışını belirler. Geleneksel hesaplama tekniklerinin tersine, YSA'ları istenen giriş-çıkış ilişkisini elde edecek şekilde eğitilir. Eğitim esnasında veri örnekleri ağa verilir ve uygun bir öğrenme algoritması kullanılarak ağın davranışını ayarlayacak parametreler

hesaplanır. Problem hakkında elde edilebilecek bilgi ve amaca göre, öğreticili, öğreticisiz veya her ikisinin olduğu öğrenme algoritmaları kullanılabilir. Öğreticili öğrenme uygulaması bilinen giriş-çıkış örnekleri ile yapılırken, öğreticisiz öğrenme ise, ağ girişine eğitim örnekleri sunulur ve ağ örneklerin olan sınıfları arasında en iyi ayrımı kendi kendine yapar. YSA'ların uygulama alanı oldukça geniş olmakla birlikte bunun en yaygın kullanım alanlarından biride nesne tanımadır. Nesne YSA'da kullanıldığı gibi bir özellik vektörüne dönüştürülür ve çıkış mümkün girişlerin belli sayıda sınıflarından birinin bir üyesi olduğunun belirlenmesidir.

Dalgacık Sinir Ağları (DSA) ayrık dalgacık fonksiyonunun düğüm aktivasyon fonksiyonu olarak kullanıldığı, dalgacık dönüşümü temelli bir ağıdır[10]. Dalgacık uzayının örüntü tanıma uzay karakteristiği olarak kullanıldığı için, sinyal karakteristiğinin çıkarımı dalgacık baz ve işaret vektörünün içsel çarpımının ağırlaştırılmış toplamı ile gerçekleştirilir. Hatta onun dalgacık dönüşümü ile zaman-frekans birleştirmesinden ve sinir ağının kendi kendine çalışmasından, ağ dayanıklılık kapasitesine sahip olur. Burada tek gizli katmanlı düğüm aktivasyon fonksiyonu olarak ayrık morlet temel fonksiyonu olan ileri DSA dizayn edilmiştir.

Dalgacık sinir ağlarının uygulamaları üzerine yapay sinir ağlarının işlemde öğrenme ve dalgacık ayrıştırabilmesi için [10-14], dizge tanımlama ve dinamik dizgelerin kontrolü için [13],[15] birçok araştırma yapılmıştır. Zhang ve Benveniste'nin çalışmasında, dalgacık ağının yeni bir gösterimi dalgacık dönüşüm teorisi temelli gelişigüzel doğrusal olmayan fonksiyonlar için ileri beslemeli sinir ağlarına alternatif olarak ve dalgacık ağı eğitimi için bir geri yayımlı algoritmanın uyarlaması önerilmiştir [14]. Zhang ve arkadaşları [16] öğrenme ve tahmin fonksiyonu için bir dalgacık-tabanlı sinir ağı önermiş olup, bu ağın yapısı radyal fonksiyonların ortonormal ölçekleme fonksiyonlarıyla yer değiştirmesi dışında radyal basis fonksiyonlu ağa benzemektedir. Zhang [11] parametrik olmayan regresyon tahmini için dalgacık ağı oluşturma algoritmaları sunmuştur.

2.4.1. Dalgacık Çatıları ve Dalgacık Ağları

Ortogonal dalgacıklar ve dalgacık çatısı olmak üzere iki dalgacık fonksiyonu kategorisi farklı gruplarca ayrı olarak geliştirilmiştir. Ortogonal dalgacıkların kapalı formda ifade edilememesi onların fonksiyon yaklaşımı ve süreç modellemeye uygulanması için ciddi bir dezavantajdır. Bunun tersine dalgacık çatıları ise ortogonalite şartlarında daha az dayanıklı olan şartlara uyan ana dalgacık denilen sabit bir fonksiyonun basit kaydırma işlemleri ile oluşturulur.

Bir dalgacık $\psi(x)$ ana dalgacık $\psi(z)$ 'ten aşağıdaki ilişki türetilir.

$$\psi_j(x) = \psi\left(\frac{x - m_j}{d_j}\right) = \psi(z_j) \quad (12)$$

burada m_j faktörü ve d_j faktörleri sırasıyla \mathbb{R} ve \mathbb{R}_+ ' da tanımlı reel sayılardır. Ψ ile üretilen aile fonksiyonları;

$$\Omega_c = \left\{ \frac{1}{\sqrt{d_j}} \psi \left(\frac{x - m_j}{d_j} \right), m_j \in \mathbb{R} \quad \text{and} \quad d_j \in \mathbb{R}_+^* \right\} \quad (13)$$

şeklinde tanımlanabilir. Herhangi bir integrali alınabilir f fonksiyonu için eğer $c > 0$ ve $c < +\infty$ gibi sabiti varsa Ω_c ailesi $L^2(\mathbb{R})$ ' nin iskeleti(frame) denebilir ve aşağıdaki eşitsizlikler yazılabilir.

$$C \|f\|^2 \leq \sum_{\substack{j \\ \psi_j \in \Omega_c}} \left| \langle \psi_j, f \rangle \right|^2 \leq C \|f\|^2 \quad (14)$$

burada $\|f\|$ f fonksiyonunun normunu ve $\langle f, g \rangle$ f ve g fonksiyonlarının içsel çarpımını göstermektedir. $L^2(\mathbb{R})$ dalgacık çatı aileleri evrensel yaklaşımcılardır.

Çok değişkenli işlemlerin modellenmesi için, çok boyutlu dalgacıklar tanımlanmalıdır. Bu çalışmada N_i skaler dalgacıkların çarpımı olarak oluşturulan çok boyutlu dalgacıklar kullanılmıştır (N_i değişken sayısıdır).

$$\Psi_j(x) = \prod_{k=1}^{N_i} \psi(z_{jk}) \quad \text{ile} \quad z_{jk} = \frac{x - m_{jk}}{d_{jk}} \quad (15)$$

m_j ve d_j sırasıyla translation ve dilation vektörleridir. Bu scheme göre üretilen çok boyutlu dalgacık aileleri $L^2(\mathbb{R}^{N_i})$ çatısı olarak gösterilir[17]. Statik modelleme mimarisi iskeletinde ifade edilen dalgacık ağlarında ağ çıkışı;

$$y = y(x) = \sum_{j=1}^{N_w} c_j \Psi_j(x) + \sum_{k=0}^{N_j} a_k x_k \quad (16)$$

şeklinde hesaplanır.

Bir N_i bileşenli giriş vektörü, bir N_w ağırlıklı çok boyutlu dalgacıklar katmanı ve doğrusal bir çıkış nöronu bir ağ olarak görülebilir. Ağın doğrusal kısmının katsayıları direkt bağlantılar olarak adlandırılır. Dalgacık ağ eğitimi en küçük kareler fonksiyonunun minimize edilmesini içerir.

$$J(\theta) = \frac{1}{2} \sum_{n=1}^N (y_p^n - y^n)^2 \quad (17)$$

burada θ vektörü tahmin edilecek tüm ağ parametrelerini içerir: dalgacıklar ve çıkış arasında bağlantıların ağırlıkları ve direkt bağlantı ağırlıkları ; N eğitim setinin eleman sayısı, y_p^n n.örneğin çıkışı ve y^n buna karşılık gelen ağın çıkışıdır. Ayrık dalgacık dönüşümünün iskeletinde bir dalgacık ailesi

$$\Omega_d = \left\{ \alpha^{m/2} \psi(\alpha^m x - n\beta), (m, n) \in \mathbb{Z}^2 \right\} \quad (18)$$

şeklinde tanımlanır, burada α ve β sabitlerdir. Aslında (17)'deki ilişki (12)'nin özel bir durumu olarak düşünülebilir ki, burada

$$m_j = n\alpha^{-m}\beta,$$

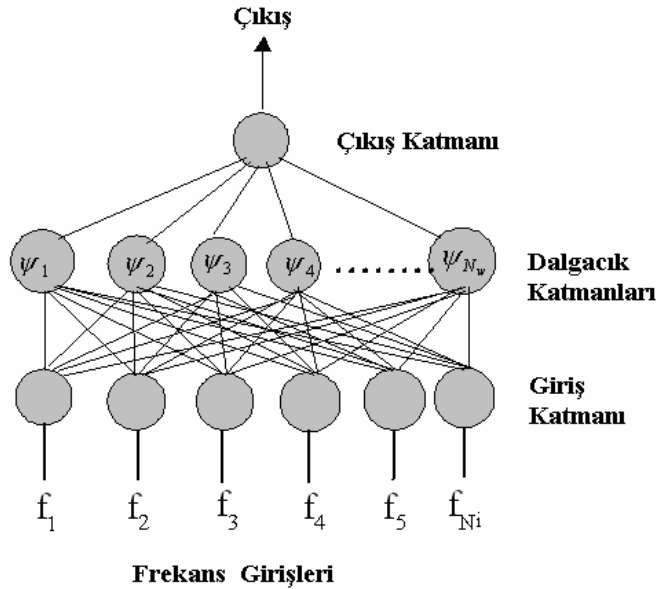
$$d_j = \alpha^{-m} \quad (19)$$

dır. Bu iliřkiler sürekli yaklařımdan farklı olarak, dalgacık parametrelerinin sürekli olarak deđiřtirilemeyeceđini gstermektedir. Bu sebeple onları ayarlamakta eđim-temelli (gradient-based) teknikler kullanılamaz. Genelde ayrıık dđnüşümden üretilen eđitilmiş dalgacık ađları Gram-Schmidt seęme metodu kullanılarak geręekleřtirilir [11]. Bu yaklařım sıklıkla eđim-temelli tekniklerce eđitilenlerden daha az karmařık olan büyük ađlar oluřturur. Bu biręok uygulamalar için dezavantajdır [17].

3. TARTIřMA

Çalıřmada kullanılan veri epilepsili oldukları deđerlendirilen hastalardan Dicle Üniversitesi Tıp Fakóltesinden alınmıřtır. Epileptik hastalar yapay sinir ađı arařtırma modellerinin eđitim ve deđerlendirme topluluđu olarak dđřünülmüřtür. Deđerlendirmenin nörologlara epilepsinin olup olmadıđı kararını verebilecek yeterlilikte olması gerekmektedir.

Tüm ađlar Matlab yazılımı kullanılarak eđitilmiřtir. Öđrenme oranı ađ eđitilirken, ađın standart karesel hatasını azaltacak, öđrenme oranını arttıracak ve standart karesel hata arttıđında öđrenme oranının tekrar daha önce belirlenen minimuma geri dđnecek řekilde dinamik olarak ayarlanmıřtır. Bu amaç için oluřturulan ve řekil.5 ' te gsterilen sınıflandırıcı bir gizli katman ve bir çıkıř katmanlı bir dalgacık sinir ađıdır. Tüm giriřlerin ilk gizli katmandaki her birime dađıtıldıđı bir giriř vektörü, giriř katmanına uygulanır. Tüm birimler bu giriř vektörleriyle çarpılan ađırlık vektörlerine sahiptir. Her birim bu giriřleri toplar ve bir dalgacık aktivasyon fonksiyonu ile dđnüşürülen bir deđer üretir. Daha sonra son katmanın çıkıřı gizli katmandaki çıkıř vektörüyle son katmandaki ađırlıklar çarpılarak hesaplanır. Bu birimlerde daha fazla toplamalar ve aktivasyonlar ađın geręek çıkıřını verir. Burada deđerken sayıda gizli birimli ve bir çıkıř birimli ađ kullanılmıřtır. Sadece ikili sınıflama yapıldıđından , bir çıkıř birimine ihtiyaç vardır.



řekil.5. Dalgacık sinir ađı.

Teoriye göre, ađın gizli katmandaki düđüm sayısı dalgacık bazına eřittir. Eđer sayı çok küçükse, DSA giriř ve çıkıř deđerleri arasında kompleks fonksiyonlu iliřki oluřturmayacaktır. Bunun tersine, büyük bir sayı deđerine ise eđitim örneđinin ařırı uyumunun (over-fitting) sebep olduđu çok büyük çıkıř hatasına yol açabilecek řekilde kompleks bir ađa neden olacaktır. Gizli katmandaki düđüm sayısı 21 ' dir.

Sonuç olarak, bu çalışmada oluşturulan ağ, düğüm aktivasyon fonksiyonu olarak morlet ana dalgacık fonksiyonu kullanılarak hata geri yayımlı sinir ağıyla oluşturulmuştur. Ağırlıkların her basamakta ayarlandığı miktar öğrenme oranı sabitleriyle parametrize edilir. Burada gizli katman için bir öğrenme oranı, çıkış katmanı içinde farklı bir öğrenme oranı kullanılmıştır. Farklı sayıda birçok değerden sonra, gizli katman ve çıkış katmanı için en iyi performansın 0,001 ' lik öğrenme oranı ile elde edildiği görülmüştür. Ağı eğitmek için eğitim verisinin aşırı uyumunu kontrol etmede aşağıda verildiği üzere çapraz geçirme uygulaması gerçekleştirilmiştir. Veri setinin %80 ' i ağı eğitmek için ve her eğitim döneminden sonra %10 ' u geçirme için rasgele seçilmiştir. Geçerleme verisi üzerinde ağın hatası her geçiş döneminden sonra hesaplanmıştır. Geçerleme hatasının en küçük olduğu dönemdeki ağ ağırlıkları bu yeni veri üzerinde en iyi işlem yapacaktır. Bu en iyi ağ geriye kalan %10 ' luk test verisine uygulanır. Tüm sunumlar rasgele eğitim, geçerleme, test setleri ve başlangıç ağırlık değerleri kullanılarak 30 kez sınıflandırılmıştır. Ağın sınıflandırmasının bir bölümden diğerine nasıl değiştiğinin kontrolü , en iyi sonucun takip eden bölümler üzerindeki ağ çıkışının

ortalaması alınarak elde edilebileceğini göstermiştir. Bunu araştırmak için DSA , MLE kullanan AR ile ön işleme tabi tutulan veri ile eğitilmiştir.

MLE'li AR ve HFD kullanarak en iyi işlem yapan dalgacık sinir ağının performansı için sonuçlar tablo.1'de gösterilmiştir. Doğruluk doğru tahminlerin toplam yüzdesidir. Özgüllük(specifity) EEG esnasında epilepsi geçiren hastalar için doğru tahmin yüzdesidir ve duyarlılık ise epilepsi geçirmeyen hastalar için doğru tahmin yüzdesidir.

Tek gizli katmanlı sınıflandırıcı olarak DSA kullanımı ile %93 civarında bir sınıflandırma oranı elde edilmiştir. Veri her pencerede 6. dereceden AR modeli kullanılmıştır. Her veri için toplam özellik vektörleri sayısı yaklaşık 300'dür. Geçerleme ve test setlerinin her biri toplam özellik vektörlerinin %10'u dur, geri kalan da eğitim seti içindir. Sınıflandırma oranları %90 uygunluk aralığındadır. Gizli katman sayısı arttıkça eğitim verisinde hatanın artmasına rağmen, test verisi üzerindeki hata gizli katman sayısı ile belirgin olarak değişmemiştir. Test verisi üzerinde MLE kullanan AR'ın sınıflandırma yüzdeleri %93'ün üzerindedir. Sinir ağında ön işlemci olarak HFD kullanılarak %92.1 ' lik ortalama bir sınıflama elde edilmiştir.

Tablo 1. Yapay sinir ağının hastalık sınıflandırma performansı.

Sınıflandırma Yöntemi	Doğruluk	Özgüllük	Hassaslık
Dalgacık Sinir Ağı	92.1	95	90.3
Standart Geriyayılımlı Sinir Ağı	91.7	92.3	89.8

4. SONUÇLAR

Epilepsinin teşhisi önemli bir konu olup, hastanın ve EEG ' sinin gözlenmesine ve ek klinik bilgilere ihtiyaç vardır. Hastaları epilepsi var veya yok şeklinde sınıflandıran bir yapay sinir ağı hekim için çok değerli bir karar verme destek aracı olacaktır. Bu çalışmada EEG kayıtlarında epilepsi varlığını belirlemede sınıflandırıcı olarak bir dalgacık sinir ağı geliştirilmiştir. Bu yeni metotta HFD ve MLE optimizasyonuna sahip AR spektrumlarını dalgacık sinir ağına bir giriş olarak girilir. Çıkışta epilepsi var veya yok şeklinde iki ayrık çıkış vardır. Değişik yapay sinir ağı öğrenme algoritmaları değerlendirilmiştir. DSA %95.8 özgüllük ve %91 duyarlılıklı sınıflandırma doğruluğu nu %93 yapan bir performans iyileştirmesi vermiştir. %90 ' dan yüksek özgüllük ve hassaslık veren DSA sınıflandırma önemli bir teşhis karar verme mekanizması olup epilepsi hastalarının tedavisinde hekimlere yardım edebilir.

KAYNAKLAR

- 1- Guler, I., Kiymik, M. K., Akin, M. & Alkan, A. AR spectral analysis of EEG signals by using maximum likelihood estimation, **Computers in Biology and Medicine**, 2001, 31, 441-450.
- 2- Zoubir, M., & Boashash, B. Seizure Detection of Newborn EEG Using a Model Approach. **IEEE Transactions on Biomedical Engineering**, 1998, 45, 673-685.
- 3- Weng, W. & Khorasani, K. An adaptive structure neural network with application to EEG automatic seizure detection. **Neural Networks**, 1996, 9, 1223-1240.
- 4- Pradhan, N., Sadasivan, P. K. & Arunodaya, G. R. Detection of seizure activity in EEG by an artificial neural network: A preliminary study, **Computers and Biomedical Research**, 1996, 29, 303-313.
- 5- Gotman, J. Automatic recognition of epileptic seizures in the EEG. **Electroencephalography and Clinical Neurophysiology**, 1982, 54, 530-540.
- 6- Qu, H. & Gotman, J. A Patient-Specific Algorithm for the Detection of Seizure Onset in Long-Term EEG Monitoring: Possible Use as a Warning Device. **IEEE Transactions on Biomedical Engineering**, 1997, 44, 115-122.
- 7- Petrosian, A., Prokhorov, D., Homan, R., Dashei, R., & Wunsch, D. Recurrent neural network based prediction of epileptic seizures in intra- and extracranial EEG. **Neurocomputing**, 2000, 30, 201-218.
- 8- Kalayci, T. & Ozdamar, O. Wavelet preprocessing for automated neural network detection of EEG spikes., **IEEE Engineering in Medicine and Biology Magazine** 1995, 16, 0-166.
- 9- **Instrumentation Reference and Catalogue**, 1997. National Instruments .
- 10- Pati, Y.C. & Krishnaparasad, P.S. Analysis and synthesis of feedforward neural networks using discrete affine wavelet transformations, **IEEE Transactions Neural Networks**, 1993, 4 (1), 73-85.
- 11- Zhang, Q. Using wavelet network in nonparametric estimation, **IEEE Trans. Neural Networks**, 1997, 8 (2), 227-236.
- 12- Xu, J. & Ho, D. W.C. A basis selection algorithm for wavelet neural Networks, **Neurocomputing**, 2002, 48, 681-689
- 13- Wong, K. & Leung, A. On-line successive synthesis of wavelet Networks, **Neural Processing Letters**, 1998, 7, 91-100.
- 14- Zhang, Q. & Benveniste, A. Wavelet Networks, **IEEE Trans. Neural Networks**, 1992, 3 (6), 889-898.
- 15- Sureshbabu, A. & Farrell, J.A. Wavelet-based system identification for nonlinear control **IEEE Trans. Autom. Control**, 1999, (2) 412-417.
- 16- Zhang, J., Walter, G.G. & Lee, W. Wavelet neural networks for function learning **IEEE Trans. Signal Process**, 43 (6), 1995, 1485-1497.
- 17- Qussar, Y. & Dreyfus, G. Initialization by selection for wavelet network training, **Neurocomputing**, 2000, 34, 131-143
- 18- Daubechies, I. Ten Lectures on Wavelets. CBMS-NSF Regional Series in Applied Mathematics, **SIAM**, 1992, Philadelphia, PA, USA.