

Epileptik Nöbetlerin Tespiti için Aşırı Öğrenme Makinesi Tabanlı Uzman Bir Sistem

Yılmaz KAYA¹, Ramazan TEKİN²

¹Bilgisayar Mühendisliği Bölümü, Siirt, Türkiye

²Bilgisayar Mühendisliği Bölümü, Batman Türkiye

yilmazkaya1977@gmail.com; ramazan.tekin@batman.edu.tr

(Geliş/Received: 28.05.2012; Kabul/Accepted: 10.09.2012)

Özet— Epilepsinin tespiti ve epileptik atakların sınıflandırılmasında beyin elektriksel aktivitesi önemli bir veri kaynağı olarak kullanılmaktadır. Bu çalışmada epileptik EEG işaretlerinin sınıflandırılmasında aşırı öğrenme makinesi (extreme learning machine=ELM) kullanılmıştır. ELM, tek gizli katmanlı ileri beslemeli bir yapay sinir ağı modelidir. Ayrık dalgacık dönüşümü ile elde edilen istatistiksel özellikler ELM ile sınıflandırma işlemine tabi tutulmuştur. İki farklı veri kümesi için (A-D ve A-E veri setleri) %100 başarı elde edilmiştir. Ayrıca ELM, diğer makine öğrenme yöntemleriyle kıyaslanmış ve hem hız hem de performans açısından göz ardı edilemeyecek bir başarı gösterdiği görülmüştür.

Anahtar Kelimeler— Electroencephalogram, epilepsi, ayrık dalgacık dönüşümü, aşırı öğrenme makinesi, uzman sistem

An Expert System for for Epileptic Seizure Detection based on Extreme Learning Machine

Abstract—The brain's electrical activity is important source of data used in detection and classification of epileptic seizures. In this study, extreme learning machine (ELM) is used for the classification of epileptic EEG signals. ELM is a single hidden layer feedforward artificial neural network (ANN) model. The statistical features obtained with discrete wavelet transform are used in classification process through ELM. The achievement Results for of two different data sets (A-D, A-E data sets) are obtained as 100%. In addition, the recognition success rates with ELM compared to other machine learning methods and it was seen ELM has more a significant success rate in diagnosing of epileptic seizures than other methods.

Keywords— Electroencephalogram, epilepsy, discrete wavelet transform, extreme learning machine, expert system

1. GİRİŞ

Epilepsi, genellikle nöbetler şeklinde kendini gösteren beyinde bir grup nöronun anormal aktivitesi sonucu dengesiz vücut hareketleri, bilinç kaybı veya kasılmalarına neden olan sinirsel bir hastalıktır [1]. EEG, beyinde meydana gelen elektriksel aktivitelerin periyodik ölçümleridir [2] ve epileptik ataklar beyin tümünde veya lokal bir bölgesinde meydana gelme durumuna göre farklı şekillerde gerçekleşebilir [3]. Epilepsi teşhis ve tedavisinde beyin sinir hücrelerinin elektriksel aktivitesinin kayıtlayan EEG beyinin anormal aktivitesinin tespiti için önemli bir araçtır beyin elektriksel aktiviteleri olan Electroencephalogram (EEG) işaretler yoğun bir şekilde kullanılmaktadır. Epileptik ataklar sırasında EEG işaretlerinin formundaki değişim gözle dahi fark edilir olsada daha detaylı analiz ve erken kestirim için bilgisayar destekli uzman sistemlerin kullanılması gerekmektedir. Bundan dolayı günümüzde epileptik EEG işaretlerinin analizinde makine öğrenmesi gibi yöntemler yoğun bir şekilde kullanılmaktadır. Makine öğrenmesi

yöntemleri uzmanlara epilepsi tanısı koymada ve epileptik hastaların sınıflandırılmasında önemli avantajlar sağlamaktadır. Karar destek vektörleri [4], en küçük kare karar destek vektörleri [2], yapay sinir ağları [5], karar ağaçları [6], kaba küme yaklaşımı gibi farklı yapay zeka yöntemleri ile epileptik EEG sinyalleri analiz edilmiştir. Bu çalışmaların tümünde önemli başarılar sağlanmıştır.


Bu çalışmada farklı şartlarda ve beyinin farklı bölgelerinden elde edilen epileptik EEG işaretlerinin analizinde aşırı öğrenme makinesi kullanılmıştır (ELM). ELM, tek gizli katmanlı ileri beslemeli bir yapay sinir ağı modelidir. Bu modelde giriş katmandaki nöronlara ait ağırlıklar ve gizli katmandaki nöronlara ait eşik değerler rastgele üretilirken gizli katmandaki çıkışlar analitik olarak hesaplanmaktadır [7]. Bu modelin en önemli özelliği öğrenme sürecinin çok hızlı gerçekleşmesidir. Bu çalışmada, epileptik EEG işaretlerinin sınıflandırılmasında ELM aşağıdaki yenilikleri sunmuştur.

1. Epileptik EEG işaretlerinden elde edilen istatistiksel özellikler kullanılarak ELM ile sınıflandırma işlemi gerçekleştirilmiştir.
2. Geleneksel ileri beslemeli yapay sinir ağlarında ağırlıklar, eşik değerleri gibi parametrelerin gradyan bazlı öğrenme algoritmaları ile güncellenmesi gerekir. Ancak iyi performansın sağlanması için öğrenme süreci hem zaman almakta hem de hata lokal bir noktaya takılabilmektedir. ELM ile böyle bir sorun söz konusu değildir.
3. Bu çalışmada "A-E" ve "A-D" epileptik EEG setleri için farklı aktivasyon ve nöron sayıları ELM ağında deneyerek en iyi ağ modeli oluşturulmuştur.

ELM, gözleri açık sağlıklı gönüllüler ile (Küme A) epilepsi öncesi (Küme D) ve epilepsi krizi esnasında epilepsi hastalarından (Küme E) alınan EEG işaretlerine uygulanmıştır. Farklı ağ modellerine göre A-E veri kümesi için %98-%100, A-D veri kümesi için %97-%100 arasında değişen oranlarda sınıflandırma başarısı elde edilmiştir.

2. VERİ SETİ

Veri seti olarak çalışmada kullanılan EEG sinyalleri; Bonn Üniversitesi Epileptoloji bölümü veri tabanından alınmıştır [8]. Tüm veri, 5 kümeden oluşmaktadır (A-E) ve her küme 23.6 saniye süreli 100 tek kanal EEG segmenti içermektedir. Aşağıda Şekil 5'te beş kümeden elde edilen örnek işaretler görülmektedir. A ve B kümeleri sırasıyla gözler açıkken ve kapalıyken sağlıklı olan 5 gönüllüden elde edilen yüzey EEG kayıtlarını içermektedir. C kümesi, hasta olan gönüllülerden nöbet öncesinde hipokampal oluşumlu karşı yarım küreden ve D kümesi epileptojenik bölgeden elde edilmiştir. E kümesi ise hasta gönüllülerin kriz sırasındaki ölçümleridir. Sinyaller 12 bit analog sayısal dönüştürücü ile dönüştürüldükten sonra bilgisayar ortamına 173,61 Hz örnekleme frekansı ile (toplamda 4097 örnek) aktarılmıştır. Epileptik özellikler kendini 30-40 Hz altındaki frekans bantlarında gösterdiğinden spektral aralığı 0.5-85 Hz olan sinyallere 0.53-40 Hz bant geçiren filtre uygulanmıştır. Bu çalışmada EEG işaretlerinden epilepsi hastalığı teşhisi yapmak amacıyla sağlıklı gönüllülere ait işaretler ile epilepsi hastalarının kriz öncesi ve kriz sırasındaki epileptik işaretleri sınıflandırılmaya çalışıldığından sadece A, D ve E veri kümeleri kullanılmıştır. Analizlerde hasta, gözleri açık sağlıklı gönüllüler ile (Küme A) epilepsi öncesi (Küme D) ve epilepsi krizi esnasında epilepsi hastalarından (Küme E) alınan EEG işaretleri sınıflandırmaya çalışan iki ayrı çalışma yapılmıştır. A,D,E sinyallere ait zaman serisi Şekil 1'de verilmiştir.



Şekil 1. EEG sinyallere ait zaman serisi

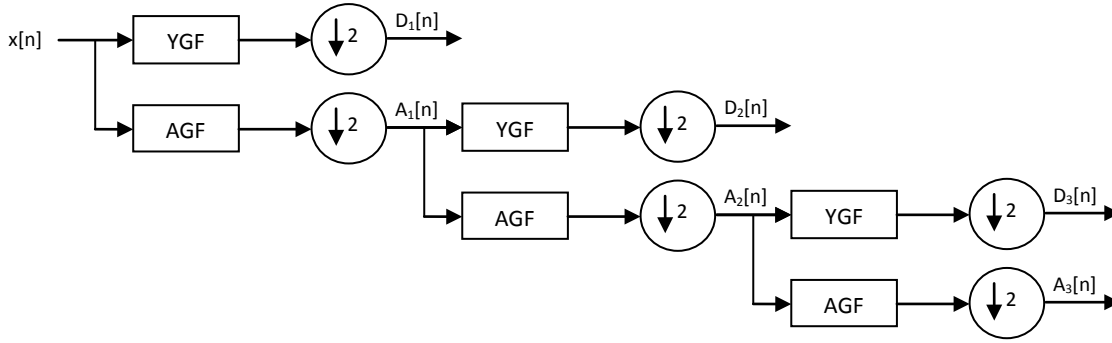
3. DALGACIK DÖNÜŞÜMÜ

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 metod hem zaman hem de frekans boyutlarında *Uncertainty principle* gereği eşit bir çözünürlük ve dolayısıyla çok iyi bir sonuç vermeyebilir. Problemi kısmen gidermek için KSFD yerine Dalgacık Dönüşümü (DD) kullanılmıştır. DD yüksek frekanslar için küçük ve düşük frekanslar için büyük boyutlu pencere kullandığından zaman ve frekans açısından en uygun çözünürlüğü sağlamaya çalışır [9,10].

Dalgacık dönüşümünün sürekli veya ayrık formları kullanılabilir. Ancak bu çalışma için Sürekli dalgacık dönüşümü 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. Sürekli dalgacık dönüşümünde ölçek ve kaydırma parametreleri $a=2^j$ ve $b=k.2^j=k.a$ ile ayrık hale getirilerek ADD temel ifadesi aşağıdaki gibi ifade edilebilir:

$$W(j, k) = \sum_j \sum_k x(n) 2^{-j/2} \psi(2^{-j}n - k) \quad (1)$$

Burada $x(n)$ işaretin kendisi ve ψ ana dalgacıktır. Logaritmik ve dengeli yapıya sahip çok frekanslı süzgeç banklarıyla AD analizi yapılabilir [11, 12]. 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 2 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. Bu ayrıştırma işleminin zaman alanındaki matematiksel



Şekil 2. Ayrık dalgacık dönüşümünde yüksek-geçiren filtre (YGF) ve alçak-geçiren filtre ile alt bantlara ayırma

ifadesi $g[n]$ ve $h[n]$ sırasıyla yüksek-geçiren ve alçak-geçiren filtreler olmak üzere aşağıdaki gibi ifade edilir:

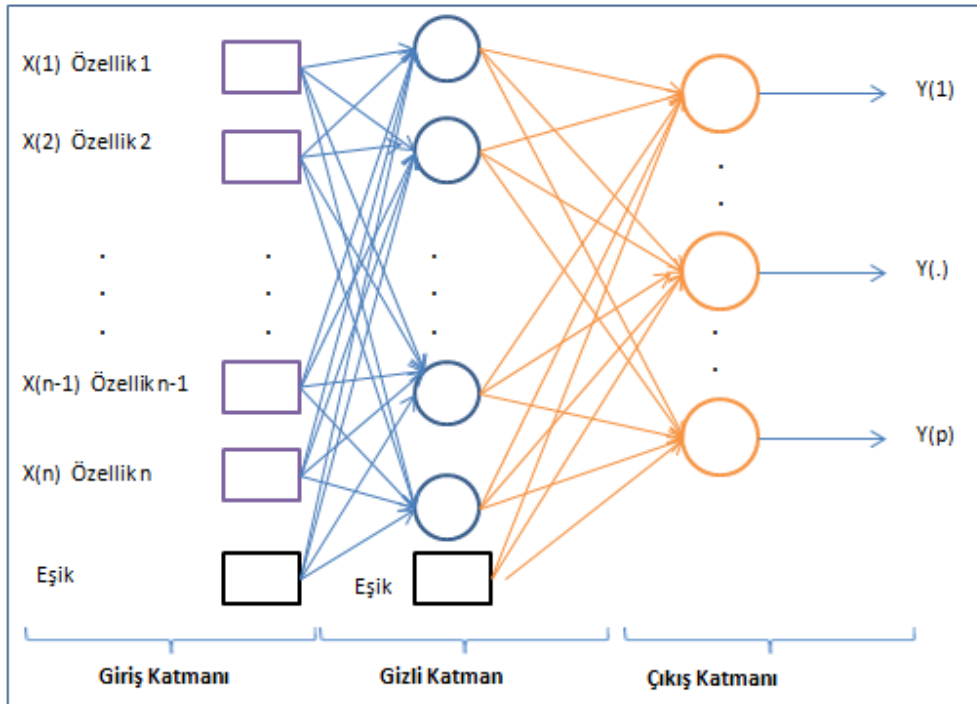
$$\begin{aligned} h_{i+1}(k) &= \sum_n h_i[n]h[2k-n] \\ g_{i+1}(k) &= \sum_n h_i[n]g[2k-n] \end{aligned} \quad (2)$$

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

4. AŞIRI ÖĞRENME MAKİNESİ

Bu bölümde Huang ve arkadaşları (2006) tarafından geliştirilen aşırı öğrenme makinesi (extreme learning machine=ELM) anlatılacaktır. ELM giriş ağırlıkları rastgele çıkış ağırlıkları ise analitik olarak hesaplanan tek gizli katmanlı ileri beslemeli bir YSA modelidir. ELM de gizli katmanda sigmodial, sine, Guassian ve hard-limitin gibi aktivasyon fonksiyonları kullanılırken çıkış katmanda doğrusal fonksiyon kullanılmaktadır. ELM de türevlenemeyen veya kesikli aktivasyon fonksiyonlar kullanılabilir [13].

Geleneksel ileri beslemeli yapay sinir ağlarında ağırlıklar ve eşik değerleri gibi parametrelerin gradyan bazlı öğrenme algoritmaları ile güncellenmesi gerekir. Ancak iyi performansın sağlanması için öğrenme süreci hem zaman almakta hem de hata yerel bir noktaya takılabilmektedir. Momentum değerinin değiştirilmesi belki hatanın lokal bir noktaya takılmasını engelleyebilir ancak öğrenme sürecinin uzun sürmesi etkilemeyecektir. Tek gizli katmanlı ileri beslemeli bir ağda giriş-çıkış ağırlıkları ve eşik değerleri ağın performansını etkilememektedir [7]. ELM de giriş ağırlıkları ve eşik değerleri rastgele üretilmekte ancak çıkış ağırlıkları hesaplanmaktadır. Bu yüzden ELM geleneksel yöntemlere göre bazı görevlerde daha iyi performanslı ve hızlıdır [7]. ELM ağı tek gizli katmanlı ileri beslemeli bir YSA modelin özelleştirilmiş halidir. Şekil 3'de tek gizli katmanlı ileri beslemeli bir YSA gösterilmiştir.



Şekil 3. İleri beslemeli yapay sinir ağı

Şekilde $X = (X_1, X_2, X_3 \dots X_N)$ giriş ve Y çıkış özelliklerini belirtmek üzere, gizli katmanda M nörona sahip ağın matematiksel ifadesi aşağıdaki gibi belirtilir [13].

$$\sum_{i=1}^M \beta_i g(W_i X_k + b_i) = O_k, k = 1, 2 \dots N \quad (3)$$

burada $W_i = (W_{i1}, W_{i2} \dots W_{in})$ giriş katmandaki $\beta_i = (\beta_{i1}, \beta_{i2} \dots \beta_{im})$ çıkış katmandaki ağırlıkları, b_i gizli katman nöronların eşik değerlerini ve O_k çıkış değerlerini belirtir. $g(.)$ aktivasyon fonksiyonudur.

N giriş özellikli bir ağda amaç hatanın $\sum_{k=1}^N (o_k - Y_k) = 0$ olması veya $\min K=1 N o_k - Y_k 2$ hatanın elde edilmesidir. Dolayısıyla Eşitlik 3 aşağıdaki gibi yazılabilir [7].

$$\sum_{i=1}^M \beta_i g(W_i X_k + b_i) = Y_k, k = 1, 2 \dots N \quad (4)$$

Yukarıdaki eşitlikte,

$$H\beta = Y \quad (5)$$

Yazılabilir. Burada

$$H(W_1, \dots, W_M; b_1, \dots, b_M; X_1, \dots, X_N) = \begin{bmatrix} g(W_1 X_1 + b_1) & \dots & g(W_M X_1 + b_M) \\ \vdots & \ddots & \vdots \\ g(W_1 X_N + b_1) & \dots & g(W_M X_N + b_M) \end{bmatrix} \quad (6)$$

ve

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_M^T \end{bmatrix}_{M \times m} \quad \text{ve} \quad Y = \begin{bmatrix} Y_1^T \\ \vdots \\ Y_N^T \end{bmatrix}_{N \times m} \quad (7)$$

şeklinde ifade edilebilir [13]. Burada H gizli katman çıkış matrisidir. ELM'de giriş ağırlıkları $W_i = (W_{i1}, W_{i2} \dots W_{in})$ ve b_i gizli katman nöronların eşik değerleri rastgele üretilmekte ve H gizli katman çıkış matrisi analitik olarak elde edilmektedir. Geleneksel ileri beslemeli bir YSA da ağın eğitilmesi, ELM'de $H\beta = Y$ doğrusal denklemde en küçük kareler çözümünün aranmasıdır. ELM algoritması üç adımda aşağıdaki gibi özetlenebilir [14].

1. Aşama: $W_i = (W_{i1}, W_{i2} \dots W_{in})$ giriş ağırlıkları ve gizli katman b_i eşik değerleri rastgele üretilir.
2. Aşama : H gizli katman çıkış hesaplanır.
3. Aşama: $\hat{\beta}$ çıkış ağırlıkları $\hat{\beta} = H^+ Y$ göre hesaplanır. Y hedef özelliklerdir.

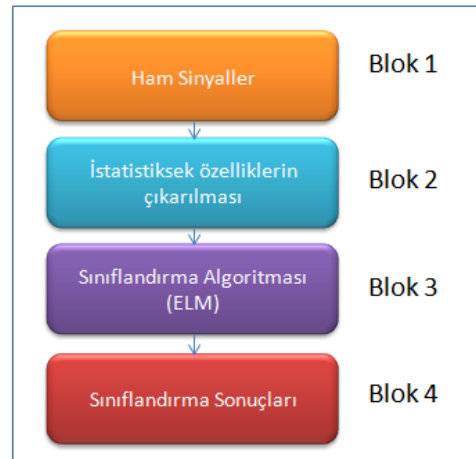
5. EPİLEPTİK EEG İŞARETLERİNİN SINIFLANDIRILMASI İÇİN ÖNERİLEN METOT

Bu çalışmada epileptik EEG işaretlerinin sınıflandırılması için ELM yöntemi kullanılmıştır. ELM 'ye ait bazı önemli özellikler aşağıdaki gibi verilebilir.

- Hızlıdır ve geliştirilebilir bir performans sağlar.

- Klasik yapay sinir ağlarındaki öğrenme oranı, momentum gibi bir parametreye ihtiyaç duymaz.
- Diferansiyel olmayan aktivasyon fonksiyonları da kullanılabilir.

Çalışmadaki modele ait diyagram şekil 4'de görüldüğü gibi dört bloktan oluşmaktadır. 1.blokta ham(raw) sinyaller elde edilmiştir. 2.blokta ham EEG sinyallerinden ADD (Ayrık Dalgacık Dönüşüm) ile istatistiksel özellikler çıkarılmıştır. 3. Blokta elde edilen istatistiksel özellikler ELM sınıflandırma algoritması için giriş özellikler olarak kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Son blokta ise sınıflandırma sonuçları paylaşılmıştır.



Şekil 4. Önerilen yönteme ait diyagram

6. SONUÇLAR

6.1. ELM Ağına Ait Parametreler

ELM, Bonn Üniversitesi Epileptoloji bölümünden elde edilen üç farklı epileptik EEG işaret setine (A,D ve E kümeleri) uygulanmıştır. Bu çalışmada kullanılan ELM ağına ait öğrenme parametreleri Tablo 1'de verilmiştir.

Tablo 1. ELM ağına ait öğrenme parametreleri

Katman Sayısı	Giriş :30 Gizli Katman :1 Çıkış Katmanı :1 Gizli katmandaki nöron sayısı : 10...100
Aktivasyon Fonksiyonları	Tangent Sigmoid, Sigmoid, Radial basis, Tringular, Sine
Öğrenme Algoritması	Tek katmanlı ileri besleme ağ için ELM
Hata Kareler Toplamı	0.0001

Tablo 2. “A-E” ve “A-D” EEG veri setleri için ELM modelleri

(A-E) EEG Veri Seti		(A-D) EEG Veri Seti	
Aktivasyon Fonksiyonu	Başarı %	Aktivasyon Fonksiyonu	Başarı %
# Gizli katman nöron		# Gizli katman nöron	
Sigmoid -17	100	Sigmoid-25	99
Sigmoid -55	100	Sigmoid-26	99
Sigmoid -12	99	Sin-23	98
Sin-77	98	Sin-44	98
Sin-28	99	Radial basis-47	98
Radial basis-16	100	Radial basis-59	98
Radial basis-42	99	Hard limit-99	97
Hard limit -19	100	Hard limit-72	97
Hard limit -47	100	Tangent sig.-35	99
Tangent sig.-40	99	Tangent sig.-33	97
Tringular basis-36	100	Tringular basis-45	100
Tringular basis-41	100	Tringular basis-57	100

ELM ağının performansı gizli katmandaki nöron sayısı ve kullanılacak aktivasyon fonksiyonuna bağlıdır. Bu yüzden Tablo 1’deki parametreler denemeler sonucunda elde edilmiştir. Bu amaçla sigmoid, tangant sigmoid, sin, radial basis gibi aktivasyon fonksiyonları ağın eğitimi ve test edilmesi için kullanılmıştır. Gizli katmandaki nöron sayısı ise 10-100 arasında birer birer artırmak suretiyle denemeler yapılarak elde edilmiştir. En uygun aktivasyon fonksiyonuna ve nöron sayısına, ağın eğitim ve test performansına göre karar verilmiştir.

6.2. ELM Performans Sonuçları

Farklı aktivasyon ve gizli nöron sayılarına göre oluşturulan ELM modelleri ile elde edilen sınıflandırma başarı oranları Tablo 2’de verilmiştir.

Tablo 2’de görüldüğü gibi ELM ağının gizli katmanında farklı aktivasyon fonksiyonları (Sigmoid, Sin, Radial basis, Hard limit, Tringular basis) ve farklı sayılarda nöron kullanılarak modeller oluşturulmuş ve denemeler yapılmıştır. “A-D” veri seti için en uygun model 57

tringular basis aktivasyon fonksiyonlu nörondan oluşan ELM modeli olurken, “A-E” seti için ise birkaç model başarılı bulunmuştur. Ayrıca “A-E” ve “A-D” EEG setleri farklı makine öğrenmesi yöntemler ile sınıflandırma işlemi gerçekleştirilmiş ve elde edilen başarı oranları Tablo 3’te verilmiştir.

Tablo 3’de görüldüğü gibi ELM her iki epileptik veri seti için önemli bir başarı göstermiştir. ELM ile elde edilen başarı sonuçları diğer makine öğrenmesi yöntemlere göre daha iyi olmuştur. Ayrıca ELM hız açısından diğer makine öğrenmesi yöntemlerine göre çok daha yüksek hız performansı göstermiştir.

6.3. ELM Sonuçlarının Literatürdeki Çalışmalar ile Karşılaştırılması

Bonn Üniversitesi Epileptoloji bölümünden elde edilen epileptik EEG sinyalleri (A,D ve E kümeleri) üzerinde yapılan çalışmalar Tablo 4’te verilmiştir. Tablo 4’e bakıldığında ELM’nin performansı diğer çalışmalara göre daha yüksektir.

Tablo 3. “A-E” ve “A-D” EEG veri setleri için farklı makine öğrenme yöntemlerine göre performans değerleri

Model	(A-E) EEG Veri Seti		(A-D) EEG Veri Seti	
	Başarı %	İşlem Zamanı (san.)	Başarı %	İşlem Zamanı (san.)
MLP	100	1.3300	98.5	1.5200
SVM	100	0.1600	99	0.0100
Naive Bayes (NB)	100	0.1000	99	0.1300
J48	100	0.0500	97	0.0500
PART	100	0.0500	98.5	0.0900
ELM	100	0.0028	100	0.0030

Tablo 4. Literatürdeki diğer çalışmalar

Yazar(lar) / Yıl	Model	Data set	Başarı %
Janjaraşitt(2010)[1]	WT/k-means	C-E	99.0
		D-E	97.0
		CD-E	97.67
Thasneem Fathima and M. Bedeuzzaman[15]	WT/LC(linear classifier.)	A-E	99.5
Güler ve Ülbeyli (2007)[16]	WT+LE(Lyapunov exponents)/SVM	A-B-C-D-E	99.28
Guo ve ark.(2010)[17]	MWT(Multiwavelet transform)+ approximate entropy feature /ANN	A-E	99.85
		ABCD-E	98.27
Nigam ve ark. (2004)[18]	Non-linear preprocessing filter/diagnostic neural network	A-E	97.2
Srinivasan ve ark.(2005)[19]	Time-frequency domain features/recurrent neural network	A-E	99.6
Polat ve Gunes(2007)[6]	Fast Fourier transform/decision tree	A-E	98.72
Subasi(2007)[20]	DWT/ mixture of expert model	A-E	94.5
Tzallas ve ark.(2007)[21]	Time–frequency analysis/artificial neural network	A-E	100
		ABCD-E	97.73
		A-D-E	99.28
Kumar ve ark.(2010)[22]	wavelet entropy features / recurrent Elman networks	A-E	99.75
Orhan ve ark.(2011)[23]	DWT+k-means/MLPNN	ABCD-E	99.60
		A-E	100
		A-D-E	96.67
Kannathal ve ark.(2005)[24]	Entropy measures/adaptive neuro-fuzzy inference system	A-E	92.22
Bu çalışma (2012)	ELM	A-E	100
		A-D	100

7. SONUÇ

Medikal tanı sistemlerinde kullanılan sınıflandırma algoritmaları tanı kararının çok kısa sürede verilmesini sağlamaktadır. Bu çalışmada ELM ile epileptik EEG sinyalleri sınıflandırılmıştır. ELM giriş ağırlıkları rastgele çıkış ağırlıkları ise analitik olarak hesaplanan tek gizli katmanlı ileri beslemeli bir YSA modelidir. ELM de gizli katmanda sigmodial, sine, Guassian ve hard-limitin gibi aktivasyon fonksiyonları kullanılırken çıkış katmanda doğrusal fonksiyonlar kullanılmaktadır. ELM de türevlenemeyen veya kesikli aktivasyon fonksiyonları kullanılabilir. Her iki veri kümesi için farklı aktivasyon ve nöron sayılarıyla oluşturulan ELM modelleri başarılı bulunmuştur. “A-D” veri kümesi için ELM modelin gizli katmanında “Tringular basis” aktivasyon fonksiyonlu 57 nöron kullanılarak %100 başarı elde edilmiştir. “A-E” veri kümesi için ise ELM modelin gizli katmanında farklı

aktivasyon fonksiyonlu ve farklı sayılarda nöron kullanılarak %100 başarı elde edilmiştir. Önerilen yöntemin medikal tanı sistemlerinde karar verme aşamasında fayda sağlayan bir araç olabileceği düşünülmektedir.

KAYNAKLAR

- [1] R. Andrzejak, K. Lehnertz, F. Mormann, C. Rieke, P. David, C. Elger, “**Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state**”, *Phys. Rev. E* 64, 061907, 2001.
- [2] Siuly, Y. Li, P. Wen, “ Clustering technique-based least square support vector machine for EEG signal Classification”, *Computer methods and programs in biomedicine*, 104(3), 358-372, 2011.
- [3] S. Altunay, Z. Telatar, O. Erogul, “Epileptic EEG detection using the linear prediction error energy”, *Expert Systems with Applications*, 37(2), 5661–5665, 2010.

- [4] E. D. Übeyli, "Analysis of EEG signals by combining eigenvector methods and multiclass support vector machines", *Computers in Biology and Medicine*, 38(1), 14-22, 2008.
- [5] E. D. Übeyli, "Implementing eigenvector methods/probabilistic neural networks for analysis of EEG signals", *Neural Networks*, 21(9), 1410-1417, 2008.
- [6] K. Polat, S. Günes, "Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform", *Applied Mathematics and Computation*, 187(2):1017–26, 2007.
- [7] G. B. Huang, Q. Y. Zhu, C. K. Siew, "Extreme learning machine: theory and Applications", *Neurocomputing*, 70(1-3), 489–501, 2006.
- [8] Internet: EEG time series (epileptic data), <http://www.meb.uni-bonn.de/epileptologie/science/physik/eeegdata.html>, 31.07.2012.
- [9] I. Daubechies, "The wavelet transform, time-frequency localization and signal Analysis", *IEEE Transactions on Information Theory*, 36(5), 961-1005, 1990.
- [10] K. Englehart, B. Hudgins, P. A. Parker, "A Wavelet-based continuous classification scheme for multifunction myoelectric control", *IEEE Transactions on Biomedical Engineering*, 48, 302–311, 2001.
- [11] I. Daubechies, "Orthonormal bases of compactly supported wavelets", *Commun. Pure Appl. Math.*, 41(7), 909–996, 1988.
- [12] S. G. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation", *IEEE Trans. Pattern Analysis and Machine Intelligence*, 11(7), 674–693, 1989.
- [13] S. Suresh, S. Saraswathi, N. Sundararajan, "Performance enhancement of extreme learning machine for multi-category sparse data classification problems", *Engineering Applications of Artificial Intelligence*, 23(7), 1149–1157, 2010.
- [14] N. Y. Liang, P. Saratchandran, G. P. Huang, N. Sundararajan, "Classification of mental tasks from EEG signals using extreme learning machine", *Int. J. Neural Systems*, 16(1), 29-38, 2006.
- [15] T. Fathima, M. Bedeuzzaman, "Wavelet Based Features for Epileptic Seizure Detection", *MES Journal of Technology and Management*, 108-112, 2011.
- [16] I. Guler, E.D. Ubeyli, "Multiclass Support Vector Machines for EEG-Signals Classification", *Information Technology in Biomedicine, IEEE Transactions on*, 11(2), 117-126, 2007.
- [17] L. Guo, D. Rivero, A. Pazos, "Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks", *Journal of Neuroscience Methods*, 193(1), 156-163, 2010.
- [18] V.P. Nigam, D. Graupe, "A neural-network-based detection of epilepsy", *Neurological Research*, 26(1), 55–60, 2004.
- [19] V. Srinivasan, C. Eswaran, N. Sriraam, "Artificial Neural Network Based Epileptic Detection Using Time-Domain and Frequency-Domain Features", *J. Med. Syst.*, 29(6), 647-660, 2005.
- [20] A. Subasi, "EEG signal classification using wavelet feature extraction and a mixture of expert model", *Expert Systems with Applications*, 32(4), 1084–93, 2007.
- [21] A. Tzallas, M. Tsipouras, D. Fotiadis, "Automatic seizure detection based on time–frequency analysis and artificial neural networks", *Computational Intelligence and Neuroscience*, 2007(18), 2007.
- [22] S. Pravin Kumar, N. Sriraam, P. G. Benakop, B. C. Jinaga, "Entropies based detection of epileptic seizures with artificial neural network classifiers", *Expert Systems with Applications*, 37(4), 3284-3291, 2010.
- [23] U. Orhan, M. Hekim, M. Ozer, "EEG signals classification using the K-means clustering and a multilayer perceptron neural network model", *Expert Systems with Applications*, 38(10), 13475-13481, 2011.
- [24] N. Kannathal, M. Choo, U. Acharya, P. Sadasivan, "Entropies for detection of epilepsy in EEG", *Computer Methods and Programs in Biomedicine*, 80(3), 187–94, 2005.