

Biyoelektriksel İşaretlerde Rahatsızlık Teşhisinin Yorumlanması

Duygu KAYA, Mustafa TÜRK

Fırat Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Elazığ
dgur@firat.edu.tr

(Geliş/Received:29.11.2016; Kabul/Accepted:24.02.2017)

Özet

Veri analiz ve sınıflandırma tekniklerinin gelişmesinin sonucu olarak biyomedikal çalışmalarda akıllı hesaplama yöntemlerinin kullanımı oldukça önemli bir yer tutmaktadır. Normal ve hasta kişilerden alınan biyoelektriksel işaretlerin (Elektroensefalografi-EEG, Elektrokardiyografi-EKG ve Elektromiyografi-EMG gibi) sınıflandırılması için elde edilen eğrilerin yorumlanması, üzerinde durulması gereken önemli bir noktadır. Bu çalışmanın amacı, biyoelektriksel işaretlerden biri olan EEG verilerinin Receiving Operation Curve (ROC) eğrileri ve hata matrisleri kullanılarak sınıflandırmanın ne oranda yapıldığını tespit etmektir. Böylece ağa yeni bir veri girdisi durumunda ağın doğru bir şekilde sınıflandırma yapması sağlanacaktır. Yapay sinir ağları (YSA), deneme yanılma yolu ile öğrenme ve genelleştirme yapabilmekte ve az da olsa hata payı ile öğrenme işlemine devam etmektedir. Yani amaç ağın ezberlemesini engelleyip, öğrenmesini sağlamaktır ki ancak bu durumda farklı veri girişlerinde doğru bir tespit yapılır. Bu çalışmada, sağlam ve epilepsi hastalarına ait veriler yapay sinir ağları ile eğitilerek, normal ve epilepsi tespiti performans analizi, hata matrisi ve ROC eğrisi ile incelenmesine imkân sağlar.

Anahtar Kelimeler: Yapay Sinir Ağları, Elektroensefalografi (EEG), Epilepsi, ROC Eğrisi, Hata Matrisi.

Interpretation Of Disorder Diagnosis In Bioelectrical Signals

Abstract

As a consequence of the development of data analysis and classification techniques, the use of intelligent computation methods in biomedical researches is very important. Interpretation of the curves obtained for the classification of electrical signals (such as Electroencephalography-EEG, Electrocardiography-ECG, and Electromyography-EMG) from normal and patient persons is an important point to be emphasized. The aim of the study is to determine what percentage of classification EEG data, which is one of the electrical signals, using Receiving Operation Curve (ROC) and confusion matrix. So, the network will be to classify correctly in case of a new group of data entry. Neural networks can learn and generalization by trial and error and continue to learn with little tolerance. Therefore, the aim of blocking the memorization of the network, but in this case is to ensure that the learning is done in a correct identification of different data entry. Therefore, the aim of blocking the memorization of the network is to ensure that learning. In this case, an accurate determination is made at different data entry. In this study, used normal and epileptic data are examined by performance analysis, ROC curve and confusion matrix.

Key Words: Artificial Neural Network, Elektroensefalografi (EEG), Epilepsy, ROC Curve, Confusion Matrix.

1. Giriş

Beyin, kalp atışı ve solunum dâhil olmak üzere insanın vücut fonksiyonlarının kontrol edilmesini ve düzenlenmesini sağlayan en önemli organdır. Beynin faaliyeti esnasında, sürekli ritmik elektriksel potansiyeller oluşurken aynı zamanda reseptör faaliyetlerine bağlı elektriksel potansiyeller de oluşur. Beyindeki elektriksel aktivitenin ani değişimi kişide kısa bir

süreliğine his ve hareketlerinde değişime sebep olabilir. Bu elektriksel potansiyellerin kaydedilmesi işlemi Elektroensefalografi (EEG) olarak adlandırılır. EEG işaretleri, biyoelektriksel işaretler olup frekans bileşenleri son derece önemlidir [1]. Elektrotlar yardımıyla kaydedilen biyoelektriksel işaretler, küçük genlik ve düşük frekans değerlerine sahiptirler. EEG sinyalleri, kafatası yüzeyine yerleştirilen elektrotlar yardımıyla temin edilir. Genlikleri 5-400 μV

olan bu sinyallerin frekansları 0,5-100 Hz arasında değişiklik göstermektedir. Normal bir insanda beyin dalgaları dört grupta incelenir. Delta dalgaları 3-5 Hz altındaki frekansları içerirken, derin uykuda meydana gelmektedir. Teta dalgaları, 4-7 Hz arasındaki frekansları içerirken, stres sırasında meydana gelmektedir. Alfa dalgaları, 8-13 Hz arasındaki frekansları içerirken, uyanık ve dinlenme halinde meydana gelmektedir. Beta dalgaları ise 13-30 Hz arasındaki frekansları içerirken beynin tüm aktivitelerinden etkilenir [2]. Beynin aktivite düzeyi arttıkça EEG dalga frekansı yükselirken, genlikleri ise azalmaktadır.

EEG sinyalleri beyin fonksiyonel yapısı ve çeşitli sinir sistemi rahatsızlıkları hakkında ışık tutabilir [3,5]. EEG sinyalleri çoğu zaman çeşitli psikolojik durumlar altında beyin aktivitelerinin incelenmesi konusunda teşhis indikatörü olarak kullanılmaktadır [6]. Sara olarak da bilinen epilepsi, beyin içinde bulunan sinir hücrelerinin olağan dışı bir elektrokimyasal boşalma yapması sonucu ortaya çıkan nörolojik bir rahatsızlıktır [7]. Epileptik nöbetler, beyindeki elektriksel aktivitenin aşırı ve kontrolsüz yayılımı sonucu oluşur [8], insan davranış ve hareketlerini etkileyerek geçici bilinç kaybına neden olur [9]. Epileptik dalga şekilleri diğer bazı beyin rahatsızlıklarındaki dalga şekilleriyle benzerlik göstermektedir. EEG sinyallerinden epilepsi tespiti, hastalığın tedavi ve nöbetlerin önceden tahmin edilmesi açısından çok önemlidir. EEG sinyallerinde bulunan dik darbeler uzman kişiler tarafından yorumlanmaktadır. EEG sinyallerinin karmaşık karakterde olması epileptik rahatsızlıkların anlaşılması konusunda önemli bir mekanizmaya ihtiyaç duymaktadır [10]. Kişinin epilepsi hastası olup olmadığına karar verilmesi uzun süreli deneyime dayalı olup [11] aynı zamanda EEG sinyallerinin frekans bilgisinin yol gösterici olması, EEG araştırmacılarını frekans aralıklarına bağlı olarak rahatsızlık teşhisinde aşına olmalarına imkan sağlamaktadır.

Sinyal analizinde kullanılan yöntemlerden biri olan Fourier Dönüşümü, zaman bölgesindeki bir sinyalin frekans bilgisini elde edebilmek için kullanılır. Durağan sinyallerin frekansları zamanla değişmezken, durağan olmayan sinyallerde kısa süreli ortaya çıkan dik darbeler teşhis açısından önemli bilgiler taşır. Bu durumda özel spektral bileşenlerin hangi zaman


aralığında meydana geldiği önemli olabilir ve bu durumda Fourier analizi yetersiz kalır [12]. Bu olumsuzluğun üstesinden gelebilmek için geliştirilen Kısa Zamanlı Fourier Dönüşümü (KZFD), zaman aralığı hakkında bilgi edinmemize imkân sağlar. Fakat KZFD’de her frekans için sabit çözünürlük sağlandığından dolayı durağan olmayan sinyaller için KZFD’ye alternatif bir yöntem olarak geliştirilen Dalgacık Dönüşümü (DD) zaman ve frekans bölgesi arasında bir köprü oluşturmuştur [13,14]. Sinyaldeki geçici durumları saptamak ve zaman-frekans analizini çıkarmak için Sürekli Dalgacık Dönüşümü (SDD) kullanılmıştır [15]. Ayrık Dalgacık Dönüşümüne (ADD) ve entropiye dayalı yöntem kullanılarak EEG sinyalleri yaklaşık ve detay katsayılarına ayrılarak entropi değeri hesaplanmış, epilepsi teşhis yoluna gidilmiştir [16]. Pencere fonksiyonları genetik algoritma kullanılarak optimizasyon teknik performansı incelenmiştir [17].

Sinyal analiz metodlarının yanı sıra YSA da sinyal işleme, sınıflandırma, sistem tanımlama ve denetimi konusunda oldukça başarılı sonuçlar vermektedir. Yapay sinir hücreleri, biyolojik sinir hücrelerine benzer yapıdadır. Yapay nöronlar aralarında bağ kurarak yapay sinir ağlarını oluştururlar. Kişinin epilepsi hastası olup olmadığına karar verme süreci çok zaman alacağından sinyallerin yorumlanmasını kolaylaştırmak amacıyla literatürde birçok çalışma yapılmıştır [13,18]. Bu çalışmada amaç, MATLAB YSA araç kitini kullanarak normal ve epilepsi hastalarına ait veriler ağı eğitilerek yeni veri girişi durumunda ağın otomatik olarak sınıflandırma yapabilmesini sağlamaktır. Bu amaçla, ön korteks bölgesine yerleştirilen elektrotlar yardımıyla kaydedilen sinyallerin normal ve epileptik olarak sınıflandırılması performans analizi, hata matrisi ve ROC eğrisi kullanılarak değerlendirilmiştir.


2. YAPAY SİNİR AĞLARI (ARTIFICIAL NEURAL NETWORKS)

YSA, birbirleri ile bağlantılı yapay sinir hücrelerinden oluşan bir sistemdir. Biyolojik sinir hücresinin matematiksel olarak modellenmesi amacı ile geliştirilen yapay sinir hücresinde nöronlarla bilgi işleme gerçekleştirilirken, sinyaller nöronlar arasındaki

bağlantılarla gerçekleştirilmektedir (Şekil 1). YSA, yapay sinir hücrelerinin gruplanması sonucunda oluşmaktadır. Oluşan bu grup katmanları, katmanların da birbirine bağlanması ile yapay sinir ağı oluşmaktadır. YSA'lar, gerçek dünyadan verileri alan nöronların bulunduğu girdi katmanından, ağı sonuçlarını dışarıya veren nöronların oluşturduğu çıkış katmanından ve bu iki katman arasındaki bir ya da daha fazla gizli katmandan oluşurlar (Şekil 2).



Şekil 1. Yapay sinir hücresi



Şekil 2. Yapay sinir ağının yapısı

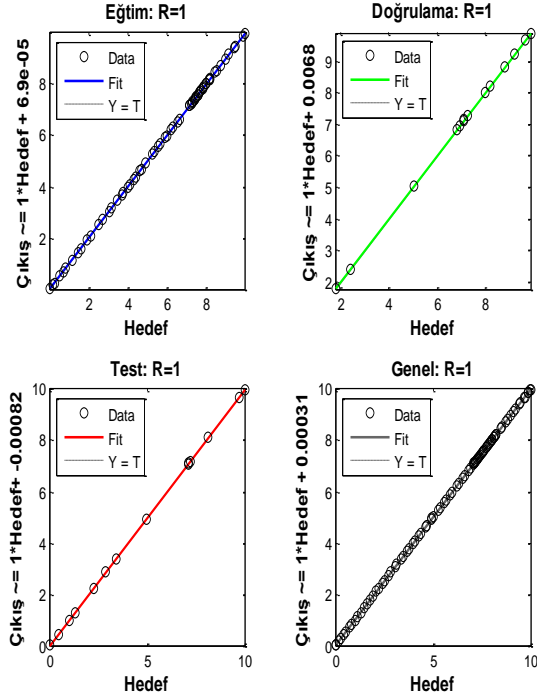
YSA'nın doğrusal olmayan sistemleri modelleyebilmesi, paralel dağılmış yapısı, öğrenme ve genelleme yapabilme yeteneği, farklı problemler için uygulanabilirliği, hata toleransına sahip olması en önemli özelliklerindedir. Ayrıca YSA, uzman yardımı olmaksızın ve programlamaya ihtiyaç duyulmadan çözme kabiliyetini sağlamak için yapılandırılır. İlk geliştirilen yapay sinir hücresi, girdilerin ağırlıklı toplamının eşik değeri ile karşılaştırılması sonucuna göre çıktı üretip, herhangi bir öğrenme kuralı içermemektedir. Sonraki çalışmalarda tek katmanlı ve çok katmanlı olmak üzere sinir ağı geliştirilmiştir. İlk geliştirilen çok katmanlı ağlarda geri yayılım algoritmasının olmayışı dezavantaj yarattığından, daha sonraki çalışmalarda geri yayılım ağı (GYA) kullanılmaya başlanmıştır. Geri yayılım ağı çok katmanlı ağlarda en çok tercih edilen algoritmadır. GYA'da girdi katmanından verilen ağ girdisi, çıktı katmanında bir sonuç üretir, çıktı biriminde hesaplanan hatanın geriye doğru

yayımları ile ağırlıklar değiştirilir. Algoritmayı sonlandırma kriteri sağlanana kadar devam eden bu işlemde eğitim uzun sürmesine rağmen, eğitilmiş ağı yeni girdiler için sonuç üretmesi çok hızlıdır. Eğitimini tamamlanmış bir ağı hata fonksiyonunu minimum yapması beklenmektedir. Fakat ağı bazen öğrenme yerine ezberleme yapmasından dolayı hata fonksiyonunu minimum yapan her ağı iyi bir eğitim geçirdiği söylenememektedir. Bu sebeple ağı öğrenmesini sağlamak amacıyla eldeki veri kümesi eğitim, doğrulama ve test olmak üzere farklı kümelerle ayrılması gerekmektedir. Eğitim setinde ağı hata oranına göre ayarlanır, ağırlık ve biaslar güncellenir. Doğrulama setinde iyileştirme durduğunda eğitim işlemi sonlandırılır ve eğitim sırasında geçerlilik hatasının azalması beklenir. Ağı, veriyi aşmaya başladığında doğrulama hatası yükselmeye başlar. Test seti ise ağı performansını değerlendirir. Dolayısıyla test hatasının çizdirilmesi sonuçların yorumlanması açısından önem taşımaktadır.

MATLAB programında bulunan YSA araç kiti, sinir ağlarının tasarlanması, değerlendirilmesi, eğitilmesi ve benzetimlerinin yapılması amacıyla kullanılır. MATLAB YSA araç kiti fonksiyon uygunlaştırma, parçacık tanıma, veri gruplandırma ve zaman serisi analizine erişmeye imkân vermektedir.

Bahsedilen araç kutusunda ortalama karesel hata, doğrusallık (korelasyon-regresyon analizi), hata matrisi yüzdesi ve ROC eğrisinin çıkarılması gibi analizler yapmak mümkündür. Nitekim yapılan çalışmada bu eğriler kullanılarak sonuçların yorumlanması amaçlanmıştır. Ortalama karesel hata ile çıkış ve hedef değerler arasında ilişkilendirme yapılarak ağı performansı değerlendirilir. Çıkış ve hedef değerler arasındaki farkın küçük olması beklenmektedir. Test hatası ve doğrulama hatası benzer karakteristik gösterir. Korelasyon analizi, iki değişken arasındaki doğrusal ilişkiyi veya bir değişkenin iki ya da daha çok değişken ile olan ilişkinin derecesini ölçmek için kullanılan istatistiksel bir yöntemdir. R değerinin yaklaşık 1 olması (eğim yaklaşık 45°- Şekil 3), değişkenler arasında doğrusal bir ilişki olduğunu, 0 olması ise doğrusal bir ilişki olmadığını ifade eder. R değerinin istenilen değerden küçük olduğu durumlarda daha doğru sonuç elde etmek için ağı

yeniden eğitilir. Yeniden eğitilen ağ ile başlangıç ağırlıkları ve biaslar değişecektir ve daha iyileşmiş bir ağ elde edilecektir [19]. Kısacası korelasyon eğrisi ağ performansını doğrulamak için kullanılır.



Şekil 3. Korelasyon analizi

		Eğitim Hata Matrisi			Doğrulama Hata Matrisi		
Gerçek Sınıf	Hedef Sınıf	1	2		1	2	
		1	312 63.8%	2 0.4%	99.4%	63 60.0%	0 0.0%
2	11 2.2%	164 33.5%	93.7%	4 3.8%	38 36.2%	90.5%	
		96.6%	98.8%	97.3%	94.0%	100%	96.2%
		3.4%	1.2%	2.7%	6.0%	0.0%	3.8%

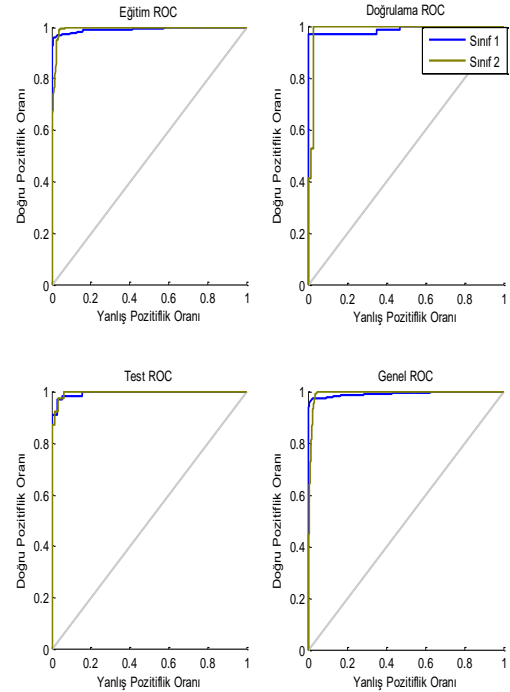
		Test Hata Matrisi			Genel Hata Matrisi		
Gerçek Sınıf	Hedef Sınıf	1	2		1	2	
		1	67 63.8%	2 1.9%	97.1%	442 63.2%	4 0.6%
2	1 1.0%	35 33.3%	97.2%	16 2.3%	237 33.9%	93.7%	
		98.5%	94.6%	97.1%	96.5%	98.3%	97.1%
		1.5%	5.4%	2.9%	3.5%	1.7%	2.9%

Şekil 4. Hata matrisi (confusion matrix)

Hata matrisi ile eğitim, doğrulama ve test sonuçları gösterilir. Yüzde hatası,

sınıflandırılmayan örnek oranını ifade eder. Her bir karedeki renklerin de bir anlamı vardır. Gerçek sınıf, hedef sınıf sıralaması ile Yeşil kare (1,1) ve (2,2) yüksek oranda doğru yüzdeyi, kırmızı kare (2,1 ve 1,2) düşük oranda doğru olmayan yüzdeyi, açık mavi kare (en alt en son) de tüm doğruluğu gösterir (Şekil 4).

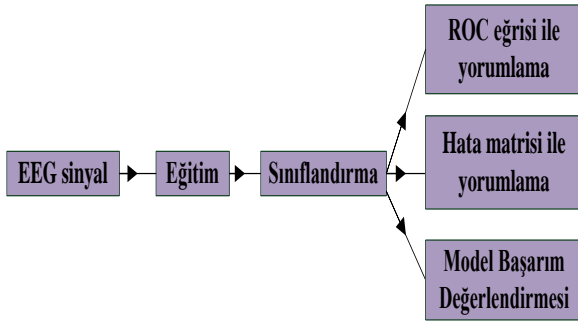
ROC eğrisi ise farklı eşik değerleri için düşey ekseninde doğru pozitiflik, yatay ekseninde yanlış pozitiflik oranlarının yer aldığı bir eğridir (Şekil 5). Doğru pozitiflik oranı arttıkça yanlış pozitiflik oranı da artmaktadır. En faydalı tanı testi doğru pozitiflik oranı yüksek, yanlış pozitiflik oranı düşük olan testtir [20-23]. Mükemmel yakın bir tanı testi, hemen hemen dikey (0,0)'dan (0,1)'e ve sonra yatayda (1,1)'den geçen bir ROC eğrisine sahip olmalıdır. Kısaca sol üst köşeye en yakın geçen ROC eğrisini veren test en kullanışlı testtir [24,25]. ROC eğrisi, köşegene yaklaştıkça başarısız bir test ortaya çıkar. (0,0) ile (1,1) noktalarını birleştiren köşegen çizgi referans çizgisi olarak kabul edilir. Bu çizgiye yakın bir ROC eğrisine sahip bir tanı testi rahatsızlıkların taranmasında yararsız bir tanı testidir [26,27].



Şekil 5. ROC eğrisi

3. Kullanılan Yöntem

Bu çalışmada kullanılan sistemin yapısı Şekil 6'da gösterilmiştir. MATLAB YSA araç kiti içerisindeki parçacık sınıflandırma arabiriminde bahsi geçen ROC eğrileri ve hata matrisleri kullanılarak eğrilerin ne anlama geldiği ve mevcut verilerin nasıl yorumlanması gerektiğine değinilmiştir. Olası farklı bir veri durumunda elde edilen sonuçların bu grafiklerle nasıl yorumlanması gerektiği amaçlanmıştır.



Şekil 6. Sistem yapısı

4. YSA Uygulanması

Çalışmada kullanılan sağlam ve epilepsi hastalarına ait verilerin boyutları Tablo 1'de görülmektedir. Bu veriler yapay sinir ağları ile eğitilerek, normal ve epilepsi yüzdesini incelememize dolayısıyla da sınıflandırma yapılmasına olanak sağlamaktadır.

Tablo 1. Sağlam ve Epileptik verilere ait boyutlar

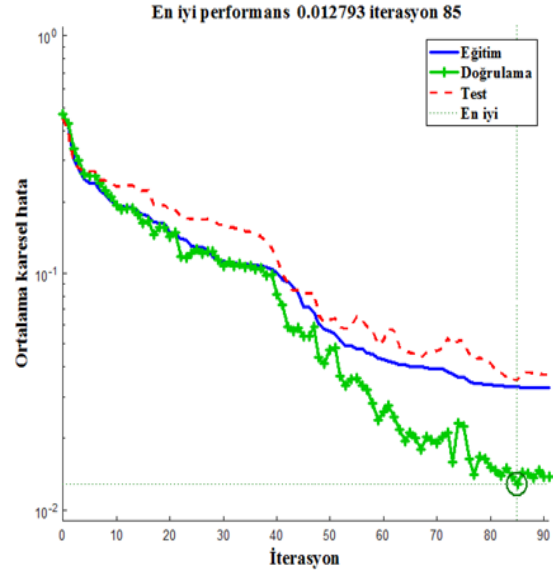
Özellik	Giriş Boyut	Çıkış Boyut
Sağlam	2x257	257x1
Epilepsi	2x257	257x1
Toplam Veri	4x257	257x2

Tablo 2. Ağ özellikleri

Giriş Sayısı	4
Katman Sayısı	3
Girdi Katmanı Nöron Sayısı	20
Gizli Katmanı Nöron Sayısı	30
İterasyon Sayısı	1000

Kullanılan ağ 4 girişli olup, çıkış hasta ve sağlam olmak üzere 2'dir. Ağ 3 katmanlı olup, girdi katmanı 20, gizli katman ise 30 nörondan oluşmaktadır. Kullanılan YSA modelinde

iterasyon sayısı 1000 seçilmiştir. Toplam verinin %70'i eğitim, geri kalan %30'u ise test için kullanılmıştır. Ağ, programı 85. iterasyonda sonlandırmış olup, ortalama karesel hatanın 0,012793 olduğu görülmektedir (Şekil 7). Ağ eğitimi için seçilen bu özellikler (Tablo 2) deneme yanılma yolu ile seçilmiş olup en iyi sonuçlar tablodaki değerlerle elde edilmiştir.



Şekil 7. YSA'nın eğitim hata grafiği (Training-error graph of ANN)

Şekil 8'de verilen hata matrisi ile mevcut 257 verinin 172'si hasta, 85'i sağlam kişilere aittir. 172 hasta veriden 164'ü hasta 8'i yanlış ve aynı şekilde 85 sağlam veriden 83'ü sağlam 2'si hasta olmak üzere bir sınıflandırılma yapılmıştır. Sonuç olarak genel sınıflandırma yüzdesi incelendiğinde doğru sınıflandırma yüzdesi % 96,1, yanlış sınıflandırma yüzdesi %3,9 dur.

		Hata Matrisi		
		1	2	
Çıkış sınıfı	1	164 63.8%	2 0.8%	98.8% 1.2%
	2	8 3.1%	83 32.3%	91.2% 8.8%
		1	2	
		95.3% 4.7%	97.6% 2.4%	96.1% 3.9%
		Hedef sınıfı		

Şekil 8. Sınıflandırma yüzdesi

Benzer şekilde, doğru ve yanlış sınıfa atanan örnek sayıları göz önüne alınarak YSA modelinin başarımının değerlendirilmesi yapılabilmektedir. Bu çalışmada model başarımı için doğruluk, kesinlik, duyarlılık ve hata oranı ele alınmıştır. Hesaplama için Tablo 3'te belirtilen DP (doğru pozitif), YP (yanlış pozitif), YN (yanlış negatif), DN (doğru negatif) değerleri kullanılmıştır.

Tablo 3. Hata Matrisi Tablosu

		<i>Hedef Sınıf</i>	
		<u>Sınıf 1</u>	<u>Sınıf 2</u>
<i>Gerçek Sınıf</i>	<u>Sınıf 1</u>	DP	YP
	<u>Sınıf 2</u>	YN	DN


$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YN+YP} = \%96,1 \quad (1)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} = \%98,8 \quad (2)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} = \%95,3 \quad (3)$$

$$\text{Hata oranı} = \frac{YP+YN}{DP+DN+YN+YP} = \%3,9 \quad (4)$$

Elde edilen bu sayısal sonuçlar Şekil 8'deki hata matrisi ile ilişkilendirildiğinde doğruluk yüzdesi mavi kareye (üçüncü satır son sütun), kesinlik yüzdesi ilk satırdaki gri kareye (ilk satır son sütun), duyarlılık yüzdesi ilk sütundaki gri (ilk sütun son satır) kareye, hata oranı ise yine mavi (son satır son sütun) yanlış sınıflandırma yüzdesine karşılık gelmektedir.



Şekil 9. ROC eğrisi

Mükemmel yakın bir tanı testi için, hemen hemen dikeyde (0,0)'dan (0,1)'e ve sonra yatayda (1,1)'den geçen bir ROC eğrisi elde edilmelidir. Şekil 9'da elde edilen ROC eğrisi görülmektedir. Eğrinin altın kalan alan (AUC- Area Under Curve) 1'e ne kadar yakın olursa sınıflandırma o kadar mükemmel olmaktadır. Dolayısıyla eğrilerin köşegenden uzaklaşması tanı testi için yararlı olmaktadır. Grafikten de görüldüğü gibi eğrilerin altında kalan alan 1'e yakındır.

5. Sonuçlar ve Tartışma

Bu çalışmada amaç, YSA kullanılarak farklı özelliklere sahip sinyallerin sınıflandırılmasını sağlamaktır. Mevcut teknikler biyolojik sinyallerden EEG sinyallerine uygulanmıştır. Çalışma için kullanılan veriler, Bonn Üniversitesinin veri tabanından alınmıştır [28]. Tüm veri 5 setten oluşup, ön korteks bölgesine yerleştirilen elektrotlar yardımıyla 23,6 saniye boyunca kayıt edilmiş, 0,5-100 Hz arasında filtrelenmiş ve örnekleme frekansı 173,61 Hz'dir. Çalışmada sağlam kişiye ve epilepsi hastasına ait 257 sütundan oluşan veriler kullanılmıştır. Mevcut verilerin normal ve epileptik olarak sınıflandırılması performans analizi, hata matrisi ve ROC eğrisi kullanılarak değerlendirilmiştir.

Bu çalışma referans alınarak ileriki çalışmalarda YSA'da farklı algoritmalar kullanılarak sınıflandırma özelliği daha etkin olarak kullanılabilir ve farklı algoritmaların performansları kıyaslanabilir. Ayrıca YSA ile diğer sınıflandırma yöntemleri (genetik algoritma, veri madenciliği), denetimli (SVM, kNN) ve denetimsiz (k-means) sınıflandırma algoritmaları kullanılarak birbirleri arasındaki üstünlükleri ve farklılıkları incelenebilir.

6. Kaynaklar

1. A. Ersöz, ve S. Özşen. (2011). Uyku EEG Sinyalinin Yapay Sinir Ağ Modeli İle Sınıflandırılması, *Elektrik Elektronik Bilgisayar Sempozyumu*, Elazığ.
2. M. M. Shaker. (2005). EEG Waves Classifier using Wavelet Transform and Fourier Transform, *Int. Journal of Biological and Life Sciences*, **1(3)**, pp. 85-90.

3. J. Bhattacharya and H. Petsche. (2001). Universality in the brain while listening to music, *Proc. Royal Society Lond. B.*, **268(1484)**, pp. 2423-2433.
4. C. J. Stam, J.P.M. Pijn, P. Suffczynski and F.H. Lopes da Silva. (1999). Dynamics of the human alpha rhythm: evidence for non-linearity?, *Clinical Neurophysiology*, **110(10)**, pp. 1801-1813.
5. G. Buzsaki. (2006). *Rhythms of the Brain* Oxford University Press, Oxford.
6. S. P. Kumar, N. Sriiram, P.G. Benakop and B.C. Jinaga. (2010). Entropies based detection of epileptic seizures with artificial neural network classifiers, *Expert Syst. Appl.*, **37(4)** pp. 3284–3291.
7. S. Sanei, and J. A. Chambers. (2007). *EEG signal processing*, Wiley Interscience.
8. D. Easwaramoorthy and R. Uthayakumar. (2010). Analysis of Biomedical EEG Signals Using Wavelet Transform and Multifractal Analysis, *Communication Control and Computing Technologies (ICCCCT) IEEE International Conference, Ramanathapuram*.
9. A.H., Siddiqi, H.K. Sevindir, C. Yazıcı, A. Kutlu, and Z. Aslan. (2010). Spectral Analysis of EEG Signals by Using Wavelet and Harmonic Transforms, *The Fifth International Symposium on Wavelets Applications to World Problems*.
10. L.D. Iasemidis. (2003). Epileptic seizure prediction and control, *IEEE Trans Biomed Eng.* **50(5)**, pp. 549-558.
11. Z. Haydari, Y. Zhang, and H.S. Zadeh. (2011). SemiAutomatic Epilepsy Spike Detection from EEG Signal Using Genetic Algorithm and Wavelet Transform, *IEEE International Conference on Bioinformatics and Biomedicine Workshops*, Atlanta, GA, USA.
12. O. Rioul, and M. Vetterli. (1991). Wavelets and Signal Processing., *IEEE SP Magazine*, pp. 14-38, October.
13. S. Mallat. (1987). A compact multiresolution representation: the wavelet model, in *Pmt. IEEE Workshop Comput. Vision*, **11(7)** Miami, FL. Dec.
14. S. Guzel Aydın, T. Kaya and H. Guler. (2016). Wavelet-based study of valence–arousal model of emotions on EEG signals with LabVIEW, *Brain Informatics*, **3(2)**, pp. 109-117, Springer.
15. R.Sankar and J. Natour. (1992). Automatic computer analysis of transients in EEG, *Computers in biology and medicine*, **22(6)**, pp. 407-422.
16. H.Ocak. (2009). Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy. *Expert Systems with Applications*, **36(2)** pp. 2027-2036.
17. T. Kaya. and M.C. Ince. (2012). The Obtaining of Window Function Having Useful Spectral Parameters by Helping of Genetic Algorithm, *Procedia-Social and Behavioral Journal*, **83** pp. 563-568, Elsevier.
18. H. S. Park, Y. H. Lee, N. G. Kim, D.S. Lee and S. I. Kim. (1998). Detection of epileptic form activities in the EEG using neural network and expert system, *Studies in health technology and informatics*, **9(2)**, pp. 1255–1259.
19. Matlab Yapay Sinir Ağları Toolbox.
20. L. Tomak ve Y. Bek. (2009). İşlem Karakteristik Eğrisi Analizi ve Eğri Altında Kalan Alanların Karşılaştırılması, *Journal of Experimental and Clinical Medicine*, **27(2)**, pp.58-65.
21. A. Dirican. (1991). ROC eğrisi çözümlenmesi ile tanı testlerinin değerlendirilmesi ve bilgisayar uygulaması, Doktora tezi, İstanbul Üniversitesi, İstanbul.
22. RG. Knapp and MC. Miller III. (1992). *Clinical Epidemiology and Biostatistics*. United States of America, Williams and Wilkins Press, Le CT. *Introductory Biostatistics*. United States of America, Wiley and Sons Pres, pp. 336-337.
23. RF Wagner, CE Metz and G. Campbell. (2007). Assessment of medical imaging systems and computer aids: a tutorial review. *Acad Radiol.* **14**, pp. 723-748.
24. A. Dirican. (2001). Tanı testi performansının değerlendirilmesi ve kıyaslanması. *Cerrahpaşa Tıp Dergisi*. **32(1)**, pp. 25-30.
25. EA. Sasse. (2002). Objective evaluation of data in screening for disease. *Clin Chim Acta*. **315**, pp. 17-30.
26. S. Weinstein, NA. Obuchowski and ML. Lieber (2005). Clinical evaluation of diagnostic tests. *AJR Am J Roentgenol.* **184**, pp. 14-19.
27. NA. Obuchowski. (2005). ROC analysis. *AJR Am J Roentgenol.* **184**, pp. 364-372.
28. EEG Data <http://www.meb.uni-bonn.de/epileptologie/science/physik/eegdata.html>.