

## YAPAY SİNİR AĞLARI KULLANILARAK EMG SİNYALLERİNİN SINIFLANDIRILMASI VE NEUROPATHY KAS HASTALIĞININ TEŞHİSİ

Fırat HARDALAÇ<sup>a</sup>, Mustafa POYRAZ<sup>b</sup>

<sup>a</sup>Fırat Üniversitesi, Tıp Fakültesi, Biyofizik ABD

<sup>b</sup>Fırat Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Müh.

### ÖZET

Bu çalışmada 59 hastaya ait Abductor Pollicis Brevis (APB) kası First Dorsal Interosseous (FDI) ve Abductor Digiti Minimi (ADM) kaslarına ait EMG işaretlerine Hızlı Fourier Dönüşümü (HFD) analizi uygulanmıştır. Bu uygulama sonucu elde edilen HFD katsayıları yapay sinir ağının (YSA) geriyayılım algoritmasıyla eğitilmiştir ve teşhis amaçlı sınıflama gerçekleştirilmiştir. Bu sınıflama esnasında Eşlenik gradyan ve hızlıprop öğrenme algoritmaları eğitim esnasında kullanılmıştır. 500 öğrenme çevriminden (epoch) sonra, her iki öğrenme algoritmasına ait performans değerleri hesaplanarak, karşılaştırmaları yapılmıştır. Sonuç olarak, HFD katsayıları geri yayımlı yapay sinir ağıyla eğitilmiş ve neuropathy ve normal EMG sinyalleri %97 doğrulukla sınıflandırılmıştır.

**Anahtar Kelimeler:** Yapay sinir ağı, Geri yayılım, Eşlenik gradyan ve Hızlıprop öğrenme algoritması, EMG, HFD

### CLASSIFICATION OF EMG SIGNALS USING ARTIFICIAL NEURAL NETWORK AND DIAGNOSIS OF NEUROPATHY NEUROMUSCULAR DISEASE

#### ABSTRACT

In this study, the fast Fourier transform (FFT) analysis was applied to EMG signals recorded from Abductor Pollicis Brevis (APB) First Dorsal Interosseous (FDI) ve Abductor Digiti Minimi (ADM) muscles of 59 patients. FFT coefficient obtained from the result of this application trained with backpropagation algorithm of artificial neural network (ANN) and classification for diagnosis was realized. Conjugate gradient and quickprop learning algorithms were used during this training. After 500 learning cycles (Epoch), performance values of test results was computed and compared. Consequently, FFT coefficients were trained in neural network and neuropathy and normal EMG signals were classified with correction rate of 97%.

**Keywords:** Artificial Neural Network, Backpropagation (BP), Quickprop and conjugate gradient learning algorithm, EMG, FFT

### 1. GİRİŞ

Elektromyogram (EMG), kasın kasılması sonucu ortaya çıkan biyopotansiyel işaretlerdir. Bunların kaynağı, vücutta meydana gelen çeşitli elektrokimyasal olaylardır. İstemli kas hareketleri, beyinde oluşan aksiyon potansiyellerinin sinirler yoluyla elektriksel uyarıların kasa iletilmesi sonucu ortaya çıkmaktadır. EMG işaretleri vücuttan özel elektrodlar yardımıyla alınır ve elektrod çeşidine göre değişik adlarla alınır. Bu işaretin kuvvetlendirilmesinde fark kuvvetlendiriciler kullanılır. EMG işaretlerinin değerlendirilmesi zaman domeninde veya frekans domeninde yapılmaktadır. Aynı zamanda EMG işareti, klinik uygulamaları da hastalık teşhislerinde, kol kesilmesi v.b. olaylarda kesik yere takılan protezin hareket ettirilmesini sağlayacak kaynak işareti olarak ta kullanılmaktadır.

EMG işareti, lineer ve durağan olmayan işaretlerdir (1). Bu işaretleri durağan hale getirmek için HFD analizi yapılarak işaretin anlamlı hale getirilmesi yani tanımlanması yapılır. Bu duruma ilişkin işaretin tanımlanması daha hızlı ve daha

doğru gerçekleştirilerek, analizi yapılan işaretin YSA da eğitimi amaçlanır.

Yapay Sinir Ağları (YSA); insan beyninin çalışma sisteminin yapay olarak benzetimi çabalarının bir sonucu olarak ortaya çıkmıştır. YSA'nın pratik kullanımı, genelde, çok farklı yapıda ve formlarda bulunabilen verileri hızlı bir şekilde tanımlama ve algılama üzerinedir. Aslında mühendislik uygulamalarında YSA'nın geniş çaplı kullanımının en önemli nedeni, klasik tekniklerle çözümü zor problemler için etkin bir alternatif oluşturması ve lineer olmayan problemleri çözebilir olmasıdır. Aynı zamanda bu çalışmada, kaslardan alınan EMG işaretleri de lineer olmayan özelliklere sahip olması sebebiyle YSA kullanımı açısından büyük önem taşır. Ayrıca YSA, güçlü öğrenme algoritmaları ile doğrusal olmayan problemleri çözebilmeleri, paralel işlem olanağı, kolaylıkla erişebilir olmaları ve uygulamalarının kolaylığı işaret işleme alanında kullanımının popüler hale gelmesini sağlamıştır (2,3).

Bu çalışmada, hastalar istirahat halindeyken, ulnar ve median nerve bölgesinden iğne

elektrotları aracılığıyla uyarılan kas liflerinde oluşan birleşik aksiyon potansiyelleri EMG sinyalleri şeklinde alınmıştır ve kas lifinde, uyarma sonucu oluşan aksiyon potansiyelinin gelişmesinden kasılmanın başlamasına kadar süren olayların tümünü analiz etmek için HFD metodu uygulanmıştır. Elde edilen HFD parametreleri daha sonra teşhis amacıyla YSA'larında değerlendirilerek sınıflandırılmıştır.

## 2. MATERYAL VE METOT

Kliniklerde kullanılan EMG ölçüm düzeneği Şekil 1 de görüleceği üzere 5 kısımdan oluşmaktadır. Bilgisayar, kasın uyarılması için gerekli elektriksel darbeleri gönderir ve aynı zaman içerisinde elektrotlar vasıtasıyla kasın uyarılması sonucu oluşan EMG sinyallerini kaydetmektedir.


Şekil 1 de görüldüğü gibi bilgisayar stimulatöre gerekli uyarım sinyallerini gönderir. Gönderilen uyarım sinyallerinin süresi 0,5 ile 1 ms arasında ve tekrarlama frekansı ise 0,1 ile 50 Hz arasında değişmektedir. Stimulatörün sabit çıkış akımı 0 ile 100 mA arasında istenen bir değere ayarlanabilmektedir. Güç hattından kaynaklanan gürültü sinyallerini yok etmek için fark yükselteci kullanılmıştır. Kullanılan fark yükseltecinin giriş empedansı 100 M $\Omega$ 'dan büyük olup, hassasiyeti 2  $\mu$ V ile 10 mV arasındadır.

Yükselteç çıkışında elde edilen sinyalin çok iyi ölçülebilmesi için yükseltecin ortak işaret bastırma oranı (OİBO) çok yüksek olmalıdır. Burada OİBO 90 dB olan bir işlemsel yükselteç kullanılmıştır. EMG işaretlerinde mevcut olan ve şebeke-den kaynaklanan gürültülerin yok edilmesi için 50 Hz'lik çentik filtre kullanılmıştır. Ayrıca istenmeyen DC bileşenlerin yok edilmesi ve EMG işaretlerinin daha iyi sayısal hale getirilmesi için, yükselteç çıkışında yüksek geçiren filtre (0,1-15 KHz) ve alçak geçiren filtre (DC-500 Hz) kullanılmıştır.

Kullanılan bilgisayar, PIII700 işlemcili, 128 MB RAM, 10 GB HDD, 600 dpi lazer yazıcı ve 16 bit ses kartından oluşan bir sistemdir.

EMG cihazına ait iğne elektrot, median nerve bölgesindeki Abductor Pollicis Brevis (APB) kası ve ulnar nerve bölgesine ait First Dorsal Interosseous (FDI) ve Abductor Digiti Minimi (ADM) kaslarına odaklanarak her bir hastadan 6 sn'lik EMG işaretleri kaydedilmiştir (4). Bu işaretlerin spektral analizinin

yapılabilmesi için 10 KHZ'de örneklenen sinyaller eşit zaman aralıklarında çerçevelere ayrılmıştır.



Şekil 1 EMG işaretlerinin elde edilmesi

## EMG İşaretlerine HFD Analizi Uygulanması

Periyodik sayısal bir işaret, bir Fourier serisi ile temsil edilebilir veya bir dalga şekli Fourier katsayılarından yeniden oluşturulur. Fourier analizinin önemi şuradadır; tek frekans bileşenli bir işarete ait bir çok fiziksel sistemin cevabı, diğer frekans bileşenlerinin genliğinden ve görüntüsünden bağımsızdır. Böyle sistemler, giriş işaretinin büyüklüğündeki bir değişim çıkış işaretinde de aynı oranda değişim verdiği için doğrusal sistemler olarak bilinir. Bundan dolayı, örneğin, kas lifinde uyarma sonucu oluşan aksiyon potansiyeli ile bu kas liflerinin kasılması potansiyelleri arasındaki ilişki doğrusal ise ve verilen bir frekansta uyarılma kasılma arasındaki ilişki biliniyorsa, üç basit adımda kompleks bir potansiyel değişiminden, bu potansiyellere ait genlik ve süre hesaplanabilir. İlk olarak potansiyel değişiminin Fourier katsayıları bulunur; her frekanstaki genlik kat sayıları, aynı frekanstaki potansiyel değişiminden hesaplanır, üçüncü olarak hesaplanan potansiyel değişim kat sayıları tüm değişimin dalga şeklini vermesi için birbirleriyle toplanır.

Sonlu uzunlukta olan bir EMG sinyalinin HFD sini almak için mevcut sinyal ikinin katları şeklinde 64, 128, 256 gibi çerçevelenir. Her bir çerçeveye karşılık düşen frekans spektrumu bulunurken pencereleme yapılır. Pencereleme sayesinde, gerçekte olmayan frekans bileşenlerinin spektrumunda ortaya çıkması önlenir.

Ayrık zamanlı periyodik bir işaretin ayrık Fourier dönüşümü;

$$X_k = \sum_{n=0}^{N-1} x(n) \exp\left(-jkn \frac{2}{N}\right) \quad (1)$$

şeklinde tanımlanır.

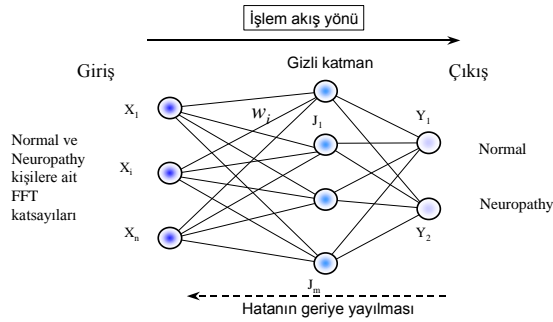
Buradaki  $X_k$  katsayıları ayrık Fourier katsayıları olarak adlandırılır.  $N$  çerçeve boyu,  $x(n)$  zaman domeni giriş işaretidir. Bu işaretin frekans spektrumunu bulmak için ayrık Fourier dönüşüm katsayıları olan  $X_k$  sayılarının mutlak değerlerinin karelerinin logaritmaları alınır (5,6).

$$P(k) = 10 \log |X_k|^2 \quad (2)$$

Burada HFD analizi yardımıyla durağan olmayan EMG işaretleri durağan hale getirilerek işaret analizini yapmak için EMG işaretlerine ait spektral eğriler elde edilmiştir. Fakat HFD yapısı gereği çerçeve boyu 10 ms' yi geçen işaretlerde iyi bir spektral çözünürlük yakalayamadığından elde edilen spektral eğride yanıtıcı frekanslar bulunmaktadır. Bu durum teşhiste yanılmayı aynı zamanda teşhisi de geciktirmektedir. Bunu gidermek için analiz sonuçlarını daha hızlı ve daha doğru değerlendiren bir algoritma olan YSA'na ihtiyaç duyulmaktadır.

### 3. NEURO SINIFLAMA

Bu çalışmada ileri beslemeli (feed forward), çok katmanlı idrak (Multi Layer Perceptron-MLP) YSA mimarisi kullanılmıştır




Şekil 2. İleri beslemeli Yapay Sinir Ağı mimarisi

YSA, yaklaşım olarak, insan beynini oluşturan fonksiyonlar arasında bir benzerlik olduğu kabul edilir. İleri beslemeli YSA ağları Şekil 2 de izlenildiği gibi giriş, gizli ve çıkış katmanlarındaki nöronlardan oluşmaktadır. Burada giriş, gizli ve çıkış katmanlarındaki her vektörel bağlantının ağırlık katsayıları olan  $w_i$  değerleri mevcuttur. Burada, giriş katmanı  $(x_1..x_i..x_n)$ , EMG

işaretlerinin HFD analizi sonucu elde edilen istatistiksel bilgileri hiçbir değişikliğe uğratmadan gizli katmandaki  $(j_1..j_m)$  hücrelere iletir ve daha sonra iletilen bu veriler, gizli ve çıkış katmanında işlenerek ağ çıkışına ait sonuçların  $(y_1,y_2)$  belirlenmesini sağlar (7).

Giriş, gizli ve çıkış katmanları arasındaki her vektörel bağlantının ağırlık katsayısı, katmanlar arasındaki her işlem elemanının yani bağlantının diğer işlem elemanı üzerinde bir etkiye sahiptir.

YSA içerisinde gerçekleştirilen işlemler sonucunda, çıkış katmanında oluşan sonuç değerleri ile arzulanan sonuç karşılaştırılır ve aradaki farka bağlı olarak ağırlık değerleri yeniden düzenlenir. Ağın eğitilmesi sırasında ilk anda ağırlıklar 0 ile 1 arasında rastgele olarak atanır. Bu rastgele atamalardan dolayı çıkıştaki değer ile istenilen sonuç arasında bir hata oluşacaktır. YSA öğrenme esnasında, oluşan bu hataları kendi içerisinde değerlendirerek, sonuç en az hataya ulaşmaya kadar bu öğrenme devam edecektir. Burada ağırlık düzeltme işlemi çıkışa yakın ağırlıklardan başlayarak, işleme ters yönde giriş seviyesine varıncaya kadar devam edecektir. Bütün bu işlemler istenilen sonucu elde etmek için, hatayı belli bir değerin altına indirinceye kadar tekrarlanacaktır. Ayrıca, nöronların girişine ve çıkışına veri aktarımı için kullanılan transfer fonksiyonu tanjant hiperbolik (Tanh) olarak ele alınmıştır. Şekil 4 de görüleceği üzere Tanh transfer fonksiyonu çıkışı +1 ile -1 arasında değişmektedir



Şekil 4 Tanh transfer fonksiyonu

YSA'da öğrenme esnasında yapılması gereken en önemli konulardan bir tanesi de öğrenme katsayılarının ayarlanmasıdır. Ağırlıkların çok yüksek tutulması yüzünden YSA'nın öğrenme davranışı bozulabilir. Bunu önlemek için öğrenme katsayısını küçük tutmak gerekir. Öğrenme katsayısı, 0,01 ile 10 aralığında seçilen sabit bir sayıdır. Öte yandan küçük öğrenme orantıda, öğrenme işleminin yavaşlamasına yol açacağından, bu çalışmada eşlenik gradyan ve hızlıprop öğrenme tek-

nikleri kullanılarak bunların sınıflamadaki performansları incelenmiştir.

Eşlenik gradyan algoritması (8) ağırlık değerlerinin en iyi şekilde karar verebilmek için performans yüzeyinin eğiminden yararlanır. Bu algoritma yardımıyla istenen ve gerçek ağ çıktıların arasındaki ortalama karesel hata değeri azaltılmıştır.

Hızlıprop Scott Fahlman (9) tarafından geliştirilen çok katmanlı ağlar için kullanılan bir öğrenme algoritmasıdır. Temel olarak ikinci derece bir yüzeydeki hata tahmini üzerine dayanır. Normal geri yayılım algoritmasına göre daha hızlı eğitmektedir.

Hızlıprop tekniği için adım büyüklüğü 0,1 ve momentum katsayısı da 0,5 ve eşlenik gradyan tekniği için ise adım büyüklüğü 0,1 olarak verilmiştir.

Bu çalışmada, YSA'nın performansının değerlendirilmesinde Ortalama Karesel Hata (MSE), Normalize Edilmiş Ortalama Karesel Hata (NMSE) ve korelasyon katsayısı kullanılmaktadır.

MSE, istenen çıkışın, ağ çıkışına ne kadar iyi uyup uymadığına karar vermek için kullanılan bir değerdir (10). Özellikle MSE değeri 0,01'in altına inmelidir. NMSE ise ağ çıkışını normalize ederek istenen çıkışın arzulanan çıkışa uyup uymadığını kontrol etmek amacıyla kullanılan bir değerdir. Korelasyon katsayısı (r) yapay sinir ağı çıkışının iyi eğitilip eğitilmediğine karar vermek için kullanılan bir büyüklüktür. Korelasyon katsayısı istenen ağ çıkışı ile hedeflenen çıkış arasında farka bağlı olarak elde edilen bir katsayıdır. Korelasyon katsayısı -1 ile 1 arasında değişir. r=1 olması durumunda ağ çıkışı ile hedeflenen çıkış arasında mükemmel bir benzerlik olduğu kabul edilir. r=-1 olduğunda ağ çıkışı ile hedeflenen çıkış arasında ters yönde bir ilişki olduğu kabul edilir. r=0 olduğunda ise ağ çıkışı ile hedeflenen çıkış arasında herhangi bir benzerlik bulunmamaktadır.

#### 4. BULGULAR VE İRDELEME


Kaydedilen EMG işaretlerine HFD analizi uygulanmıştır. Bu uygulama sonucu oluşturulan spektral eğriler 50 000 örnekleme verisi kullanılarak elde edilmiştir. Her bir spektral eğrinin çevrim dışı oluşma süresi 6 saniyede gerçekleştirilmiştir.

Bu çalışmada, sağlıklı normal kasa ve neuropathy hastalıklı kasa ait EMG işaretlerinin


HFD katsayıları elde edilmiştir. Normal ve Neuropathy'li kasa ait HFD sonuçlarına ait spektral eğriler Şekil 4a ve 4b'de verilmiştir.

30 yaşındaki sağlıklı bir kişiden kaydedilen EMG işaretlerine HFD analizi uygulanması sonucu elde edilen spektral eğriler Şekil 4a da sunulmuştur. Bu spektral eğriye bakıldığında 0-1000Hz arasında tekrarlanan frekanslara karşılık gelen genliklerin normal oldukları görülmektedir.

Şekil 4b de ise 32 yaşındaki Neuropathy'li bir kişiden kaydedilen EMG işaretlerinde 0-1000Hz arasında tekrarlanan frekanslar çok sık ve bu tekrarlanan frekanslara karşılık gelen genlikler çok yüksek olması nedeniyle kas hassasiyeti ve duyarlılığı artmıştır.



Şekil 4a Normal durumdaki bir kasa ait HFD sonuçları



Şekil 4b Neuropathy görülen bir kasa ait HFD sonuçları

Elde edilen EMG işaretlerine ait HFD sonucu elde edilen katsayılar YSA da sınıflamak için en iyi ve en kolay öğrenmenin gerçekleştiği ileri beslemeli mimari, geri yayılım algoritması ile hızlıprop ve eşlenik gradyan öğrenme teknikleri

kullanılmıştır. Yapay sinir ağına girilen, 59 veriden 30 tanesi eğitime için uygulanmıştır. Geriye kalan 29 adet test verisi kullanılarak ağın performansı izlenmiştir.

Bu çalışmada 59 kişiden kaydedilen EMG verilerinin HFD analizi sonucu 33 tanesinin normal, 26 tanesinin ise Neuropathy'li olduğu teşhis edilmiştir. Tablo 1'de, YSA eğitiminde kullanılan eşlenik gradyan ve hızlıprop öğrenme tekniklerinin

Şekil 5a Hızlıprop öğrenme tekniğine ait MSE değerleri



Tablo 1 YSA eğitimine test ve performans sonuçları

<i>Performans</i>	Hızlıprop		Eşlenik gradyan	
	<i>Normal</i>	<i>Neuropathy</i>	<i>Normal</i>	<i>Neuropathy</i>
MSE	0.044814345	0.045259413	0.025950606	0.02579799
NMSE	0.182292422	0.184102839	0.105559926	0.104939125
MAE	0.094737986	0.096361858	0.076616143	0.077751628
Min Mutlak Hata	0.001077941	0.001155403	0.000325077	0.000346771
Maks Mutlak Hata	0.95924139	0.958350856	0.71324558	0.711847335
r (korelasyon kat.)	0.904673004	0.905124085	0.946534974	0.947881901
Doğruluk yüzdesi	92.59259033	97.14286041	96.29629517	97.14286041

500 Epoch sonunda elde edilen eğitime ve test performansları verilmiştir.

Bu performanslara göre, eşlenik gradyan tekniği, MSE (ortalama karesel hata) %42, NMSE (normalize edilmiş ortalama karesel hata) %42, MAE (ortalama mutlak hata) %19, Minimum Mutlak Hata %69, Maksimum Mutlak Hata %26 hızlıprop öğrenme tekniğine göre verileri daha iyi öğrenmiştir.

Aynı zamanda r (korelasyon katsayısı) değeri conjugate öğrenme tekniğinde 1'e daha yakın değer almıştır. Ayrıca conjugate öğrenme tekniği normal'e ait HFD katsayılarını %96 doğru sınıflarken, hızlıprop öğrenme tekniği %93 doğru sınıflayabilmiştir. Diğer Neuropathy'e ait HFD katsayılarını ise her iki öğrenme tekniği %97 doğru sınıflamıştır.



Şekil 5b. Eşlenik gradyan öğrenme tekniğine ait MSE değerleri

Şekil 5a da hızlıprop ve Şekil 5b de eşlenik gradyan öğrenme tekniğine ait MSE eğrileri sunulmuştur. Burada görüldüğü gibi hızlıprop öğrenme tekniğine ait MSE değeri 500 adım sonunda 0,07'in altına inerken, eşlenik gradyan öğrenme tekniğine ait MSE değeri 500 adım sonunda 0,04'in altına inmiştir. Bu nedenle, conjugate öğrenme tekniği hem performans analizi yönünden hem de MSE açısından hızlıprop öğrenme tekniğine göre daha avantajlıdır.

Aynı zamanda, bu çalışmaya ait sınıflamanın başarılı olup olmadığını test etmek için hastalık tayinleri yapılmamış EMG işaretlerinden elde edilen HFD katsayıları, ileri beslemeli geri yayılım algoritmaları YSA da eşlenik gradyan

öğrenme tekniğiyle sınıflama yapılmış ve bu sınıflamaya ait sonuçlar Tablo 2 de sunulmuştur.

gradyan öğrenme tekniği hızlıprop öğrenme tekniğine göre daha az hatayla öğrendiği performans ve test sonuçlarında görülmüştür.

Tablo 2 YSA tahmin değerleri

EMG işaretinden elde edilen HFD katsayıları																	YSA çıkış değeri		Arzulanan çıkış değeri	
HFD	HFD	HFD	HFD	HFD	HFD	HFD	HFD	HFD	HFD	HFD	HFD	HFD	HFD	HFD	HFD	HFD	normal	neuropath	normal	neuropath
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17		y		y
256	228	180	177	176	173	173	168	159	149	137	132	123	107	85	75	73	0,003	1,0012	0	1
256	228	180	179	176	177	172	164	160	150	139	129	122	105	78	70	69	0,004	1,0018	0	1
256	227	174	176	178	179	175	167	158	150	138	131	124	108	80	73	75	-0,001	1,0027	0	1
257	228	180	175	179	174	172	170	162	152	142	132	124	108	89	87	90	0,001	0,9998	0	1
257	228	180	175	179	174	172	170	162	152	142	132	124	108	89	87	90	0,001	0,9998	0	1
-15	18	23	10	5,8	2,6	-4	-14	-22	-23	-26	-34	-43	-54	-67	-79	-83	0,993	0,0025	1	0
-55	-28	-22	-30	-42	-43	-49	-59	-71	-81	-87	-93	-100	-107	-116	-123	-127	1,006	-0,007	1	0
-2	30	30	-6	-35	-64	-72	-81	-91	-98	-105	-120	-127	-134	-153	-161	-169	0,996	-0,006	1	0
-63	-28	-22	-33	-42	-48	-57	-61	-63	-64	-69	-79	-90	-104	-121	-126	-133	1,001	0,0017	1	0
-4	28	32	27	22	15	10	0,6	-12	-23	-29	-34	-45	-58	-72	-81	-89	0,988	0,0039	1	0

Burada, hastalardan kaydedilen EMG işaretlerine ait HFD analizi sonucu elde edilen katsayılar, bu katsayılarla ilişkin YSA'nın hesapladığı çıkış değerleri sunulmuştur. YSA'nın hesapladığı çıkış değerleri 1 ve 0 değerlerine yuvarlatıldığında, arzulan çıkış değeriyle karşılaştırılırsa bu çalışmadaki sınıflamanın %100 başarılı olduğu gözlenmiştir. Bu sınıflama sonucu 10 hastanın EMG işaretinin 5'i normal ve 5'i neuropathy olduğu gözlenmiştir.

## 5. SONUÇ

Bu çalışma gerçekleştirilirken 59 kişi üzerinde çalışılmıştır. EMG işaretleri alınan kişilerin 33'i normal ve 26 tanesi de neuropathy olarak tespit edilmiştir. YSA'nın eğitilmesi sonucunda eşlenik gradyan öğrenme tekniği normal hastaya ait EMG işaretlerini %96 doğrulukla ve neuropathy'li hastaya EMG işaretlerini de %97 doğrulukla sınıflamıştır. Diğer hızlıprop öğrenme tekniği ise normal hastaya ait EMG işaretlerini %92 doğrulukla ve neuropathy'li hastaya EMG işaretlerini de %97 doğrulukla sınıflamıştır. Her iki öğrenme tekniğinin öğrenme hızlarını incelemek için MSE eğrisine başvurulmuştur. Elde edilen sonuca göre yapay sinir ağları, ileri beslemeli mimari ile geri yayılım algoritması kullanılarak, eşlenik gradyan ve hızlıprop öğrenme tekniği aynı hızda ve eşlenik

## KAYNAKLAR:

1. Aminof M. J. ,“Clinical electromyography. In: Electrodiagnosis in Clinical Neurology. 3<sup>rd</sup> ED Ed.: M.J Aminoff. New York: Churchill Livingstone. ,1992
2. Cichocki, Andrzej 0471930105 Neural networks for optimization and signal processing Wiley Chichester 1996
3. Hudson D. L., and Cohen E. M. ,“Neural network and artificial intelligence for biomedical engineering”, IEEE press, New York, 2000
4. David C Breston, Shapiro B E, “Electromyography and neuromuscular disorders”, Butterworth-Heinemann, USA, 1998
5. Hardalac F., “Transcranial doppler sinyalleri için en iyi spektral analiz metodunun belirlenmesi”, Fırat Üniv, Doktora tezi,1997
6. Steven M. K., “Modern spectral estimation”, Prentice-Hall signal processing series, 1998
7. Chen, J. D. Z., Lin, Z., Wu, Q, and McCallum, R.W. “Non-invasive identification of gastric contractions from surface electrogastrogram

- using backpropagation neural network”, Med Eng Phys, 17(3):219-225, 1995
- 8 Wing-Fai Chang, Man-Wai Mak , “A eşlenik gradyan learning algorithm for recurrent neural networks”, Neurocomputing 24 173-189, 1999.
- 9 Fahlman S. E. “Faster learning variations on backpropagation: An emprical stufy”, Proceedings of the 1988 Conectionist Model Summer School, San Mateo, CA:Morgan Kaufmann, 38-51,1988
- 10 Greger G. Andersson and Peter Kaufmann, “Development of a generalized neural network”, Chemometrics and Intelligent Laboratory Systems, Volume 50, Issue 1, Pages 101-105, 2000.





