

AR VE ARMA METOTLARININ KULLANIMI İLE TEŞHİS SİSTEMLERİ İÇİN ÖZNETELİK ÇIKARMA: OFTALMİK ATARDAMAR DOPPLER İŞARETLERİNİN DURUM ANALİZİ

Elif Derya ÜBEYLİ ve İnan GÜLER*

Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, TOBB Ekonomi ve Teknoloji Üniversitesi,
Söğütözü, Ankara.

* Elektronik-Bilgisayar Bölümü, Teknik Eğitim Fakültesi, Gazi Üniversitesi, Teknikokullar, Ankara,
iguler@gazi.edu.tr

ÖZET

Teşhis sistemleri için özbağlımlı (autoregressive - AR) ve özbağlımlı yürüyen ortalamalı (autoregressive moving average - ARMA) metotların kullanımı ile işaretlerden öznetelik çıkarılmakta ve işaretlerin güç seviyesi-frekans dağılımları istatistiksel özellikler ile gösterilmektedir. Bu çalışmada, farklı kişilerden alınan oftalmik atardamar Doppler işaretlerinin spektral analizi AR ve ARMA metotları ile gerçekleştirilmiş ve işaret hakkında önemli bilgi içeren Doppler güç yoğunluk spektrum değerleri işareti temsil eden öznetelik vektörleri olarak ele alınmıştır. Öznetelik vektörlerinin boyutlarının azaltılabilmesi için Doppler güç yoğunluk spektrum değerleri üzerinde istatistiksel işlemler yapılmış ve sınıflama işleminde kullanılan çok katmanlı perseptron sinir ağlarının giriş öznetelik vektörleri seçilmiştir. Farklı algoritmalar ile eğitilen çok katmanlı perseptron sinir ağlarının performansları incelenerek AR ve ARMA metotlarının Doppler işaretlerinin analizindeki başarısı tespit edilmiştir. Gerçekleştirilen ağların toplam sınıflama doğrulukları, Levenberg-Marquardt algoritması ile eğitilen ve ARMA Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznetelik vektörlerinin giriş olarak kullanıldığı çok katmanlı perseptron sinir ağının oftalmik atardamar Doppler işaretlerinin sınıflandırılmasında kullanılabileceğini göstermiştir.

Anahtar Kelimeler: AR metodu, ARMA metodu, öznetelik çıkarma, Doppler güç yoğunluk spektrumu, sınıflama doğruluğu, oftalmik atardamar.

FEATURE EXTRACTION FOR DIAGNOSTIC SYSTEMS BY USAGE OF AR AND ARMA METHODS: OPHTHALMIC ARTERIAL DOPPLER SIGNALS CASE STUDY

ABSTRACT

For diagnostic systems, features are extracted from signals by the usage of autoregressive (AR) and autoregressive moving average (ARMA) methods and power level-frequency distributions of the signals are demonstrated by statistical features. In the present study, spectral analysis of ophthalmic arterial Doppler signals obtained from different subjects was performed using the AR and ARMA methods and Doppler power spectral density values which contain a significant amount of information about the signal were considered as feature vectors representing the signal. In order to reduce the dimensionality of the extracted feature vectors, statistical processes were performed over the Doppler power spectral density values and input feature vectors of multilayer perceptron neural networks used in classification were selected. Performances of the AR and ARMA methods in the analysis of Doppler signals were determined by examining performances of multilayer perceptron neural networks trained by different algorithms. Total classification accuracies of the constructed networks were demonstrated that multilayer perceptron neural network trained by Levenberg-Marquardt algorithm which used ARMA Doppler power spectral density values as inputs could be used in classification of ophthalmic arterial Doppler signals.

Keywords: AR method, ARMA method, feature extraction, Doppler power spectral density, classification accuracy, ophthalmic artery.

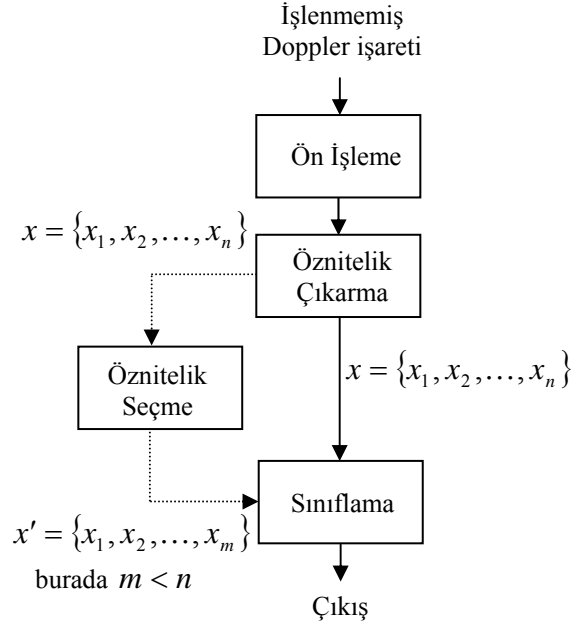
1. GİRİŞ

Ultrasonik Doppler, kan akış hızını, yönünü ve debisini incelemeye kullanılmaktadır. Doppler sistemlerinde, ultrasonik dönüştürücünün gönderdiği ultrasonik dalganın kandaki kırmızı kan hücrelerinden saçılması ve yansımından dolayı frekansta değişimler gözlenir. Doppler kayma frekansı, damara gönderilen dalganın frekansı ile geri yansıyan dalganın frekansı arasındaki farktır:

$$f_D = f_t - f_r = \frac{2f_t v \cos \theta}{c} \quad (1)$$

Burada, f_D Doppler kayma frekansı, f_t damara gönderilen dalganın frekansı, f_r damardan geri yansıyan dalganın frekansı, v kandaki parçacıkların hızı, c ultrasonik dalganın ortamdaki hızı, θ ultrasonik dalga ile parçacıkların hareket yönü arasındaki açıdır [1-4]. Ultrasonik dalganın kandan saçılması tek ve aynı hızda hareket eden parçacıklardan olmadığı için eşitlik 1'deki gibi tek bir Doppler frekansı değil birden fazla Doppler frekansı spektrum şeklinde gözlenir. Doppler güç spektrumunun şekli ile ölçüm yapılan bölgedeki kan akış hızının şekli benzerdir. Bu durumda, Doppler işaretlerinin spektral analizi ile atardamarlardaki hız dağılımı hakkında bilgi elde edilebilir. Özbağlımlı metot (autoregressive - AR), yürüyen ortalamalı metot (moving average - MA) ve bunların birleşimi olan özbağlımlı yürüyen ortalamalı metot (ARMA) model tabanlı spektral analiz metotlarıdır. AR ve ARMA metotları, ultrasonik Doppler kan akış işaretlerinin spektral analizinde en çok kullanılan metotlardır [2-4]. Spektral analiz metotlarının kullanılması ile Doppler işaretlerinin güç yoğunluk spektrumlarının kestirimi yapılır ve tıbbi bilgi elde etmek için Doppler spektrumlarındaki değişimler incelenir. Doppler işaretlerinin spektral içeriğinden kan akışı ile ilgili sonuçlar çıkarılabilir. Spektral şeklin ve parametrelerin analizi ile işaretin sağlıklı veya hastalıklı atardamara ait olduğu belirlenir [2-4].

Hastalık teşhisleri, şekil sınıflama işlemi olarak incelenebilmektedir. Girişlerin belirsiz olması ve değişkenlik göstermesi durumunda geleneksel şekil sınıflama sistemleri sınıflamada başarılı olamayabilir. Yapay sinir ağları (YSA) ise girişlerin değişkenlik göstermesi durumunda şekil sınıflamada başarılı olmaktadır. Tıbbi alandaki uygulamalar, YSA'ların hastalık teşhisini içeren şekil sınıflama için uygun olduklarını göstermektedir [5-9]. Teşhis sistemlerinde çeşitli metotlar kullanılmakla birlikte bu sistemler genellikle şu işlemlerden oluşmaktadır: ön işleme, öznitelik çıkarma/seçme ve sınıflama (Şekil 1). İşaret/görüntü elde etme, bozucu etkenlerin yok edilmesi, ortalama alma, eşik değeri belirleme, işaret/görüntü iyileştirme gibi işlemler ön işlemeyi



Şekil 1. Teşhis sistemlerinde gerçekleştirilen işlemler

oluşturmaktadır. Öznitelik çıkarma, şekil tanımlama ve şeklin önemli özniteliklerinin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir. Öznitelik seçme isteğe bağlı olarak yapılan bir işlem olup sınıflama işlemi açısından en belirleyici özniteliklerin seçilmesi ile öznitelik vektörünün boyutunun azaltılmasıdır. Teşhis sistemlerinin son aşaması olan sınıflamada, kullanılan algoritmaya bağlı olarak giriş öznitelik vektörleri incelenir ve sınıflama sonucu belirlenir. Sınıflama sonucunu belirlemesi açısından ele alındığında öznitelik çıkarma ve gerekli durumlarda öznitelik seçme, YSA gibi sınıflama sistemlerinin başarısını oldukça etkilemektedir [5-9].

Bu çalışmada, farklı kişilerden alınan oftalmik atardamar Doppler işaretlerinin spektral analizi AR ve ARMA metotları ile gerçekleştirilmiş ve işareti temsil eden öznitelik vektörleri elde edilmiştir. Öznitelik vektörlerinin boyutlarının azaltılabilmesi için Doppler güç yoğunluk spektrum değerleri üzerinde istatistiksel işlemler yapılmış ve sınıflama işleminde kullanılan çok katmanlı perseptron sinir ağlarının giriş öznitelik vektörleri seçilmiştir. Çok katmanlı perseptron sinir ağlarının performansları, yakınsama hızları (eğitim iterasyonlarının sayısı), ortalama karesel hataları ve toplam sınıflama doğruluklarının değerlendirilmesi ile belirlenmiştir. Farklı algoritmalar ile eğitilen çok katmanlı perseptron sinir ağlarının performansları incelenerek AR ve ARMA metotlarının Doppler işaretlerinin analizindeki başarısı tespit edilmiştir.

2. AR METODU İLE SPEKTRAL ANALİZ

Model-tabanlı metotlarda $x(n)$ işareti, rasyonel

sistem ile karakterize edilen doğrusal sistemin çıkışı olarak modellenir ve spektrum kestirim işlemi iki adımdan oluşur. Eldeki $x(n)$, $0 \leq n \leq N-1$, işaretinin model parametreleri kestirilir ve daha sonra bu kestirim değerlerinden güç yoğunluk spektrumunun kestirimi hesaplanır. AR metodunda işaret, nedensel, tüm-kutup, girişi beyaz gürültü olan ayrık filtrenin çıkışı olarak modellenir. p 'inci dereceden AR metodu şu şekilde ifade edilir,

$$x(n) = -\sum_{k=1}^p a(k)x(n-k) + w(n) \quad (2)$$

burada $a(k)$ AR katsayıları ve $w(n)$ varyansı σ^2 olan beyaz gürültüdür. AR(p) modeli, AR parametreleri $\{a[1], a[2], \dots, a[p], \sigma^2\}$ ile tanımlanabilir. Güç yoğunluk spektrumu,

$$P_{AR}(f) = \frac{\sigma^2}{|A(f)|^2} \quad (3)$$

burada $A(f) = 1 + a_1e^{-j2\pi f} + \dots + a_pe^{-j2\pi fp}$ 'dir [2-4, 10].

AR kestirim metotlarından biri olan en küçük kareler metodu ile kestirilen AR parametreleri güç yoğunluk spektrumu ifadesinde yerine konur (eşitlik 3) ve güç yoğunluk spektrum kestirimi şu şekilde bulunur [2, 10]:

$$\hat{P}_{EKK}(f) = \frac{\hat{\sigma}^2}{\left|1 + \sum_{k=1}^p \hat{a}_p(k)e^{-j2\pi fk}\right|^2} \quad (4)$$

burada, $\hat{P}_{EKK}(f)$ en küçük kareler AR metodu ile kestirilen güç yoğunluk spektrumudur.

3. ARMA METODU İLE SPEKTRAL ANALİZ

ARMA metodunda, işaret girişi beyaz Gauss gürültüsü olan nedensel, kutup-sıfır, ayrık filtrenin çıkışı olarak modellenir. (p, m)'inci dereceden ARMA modelinin fark denklemi şu şekilde ifade edilir:

$$x(n) = -\sum_{k=1}^p a(k)x(n-k) + \sum_{k=0}^m b(k)w(n-k) \quad (5)$$

burada, $x(n)$ filtrenin çıkışındaki gözlenen işaret, $w(n)$ varyansı σ^2 olan beyaz Gauss gürültüsü, $a(k)$ AR katsayıları, $b(k)$ MA katsayılarıdır. ARMA(p, m) metodu, ARMA parametreleri $\{a(1), a(2), \dots, a(p), b(1), b(2), \dots, b(m), \sigma^2\}$ ile tanımlanabilir. Güç yoğunluk spektrumu,

$$P(f) = \frac{|B(f)|^2}{|A(f)|^2} \sigma^2 \quad (6)$$

burada, $A(f) = 1 + a_1e^{-j2\pi f} + \dots + a_pe^{-j2\pi fp}$, $B(f) = 1 + b_1e^{-j2\pi f} + \dots + b_me^{-j2\pi fm}$ 'dir [3, 4, 10].

ARMA kestirim metotlarından biri olan en küçük kareler değiştirilmiş Yule-Walker metodu ile kestirilen ARMA parametreleri güç yoğunluk spektrumu ifadesinde yerine konur (eşitlik 6) ve güç yoğunluk spektrum kestirimi şu şekilde bulunur [3, 4, 10]:

$$\hat{P}_{ARMA}(f) = \frac{\hat{P}_{MA}(f)}{\left|1 + \sum_{k=1}^p \hat{a}(k)e^{-j2\pi fk}\right|^2} \quad (7)$$

burada, $\hat{P}_{ARMA}(f)$ ARMA metodu ile kestirilen güç yoğunluk spektrumudur, $\hat{P}_{MA}(f)$ MA metodu ile kestirilen güç yoğunluk spektrumudur ve şu şekilde ifade edilir $\hat{P}_{MA}(f) = \sum_{k=-m}^m \hat{r}(k)e^{-j2\pi fk}$.

4. YAPAY SİNİR AĞLARI

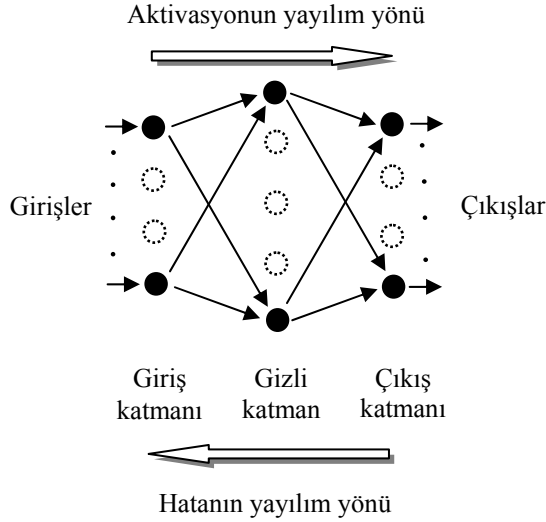
YSA'lar, paralel hesaplama tekniğini kullanabilen yapay nöronların birbirlerine bağlanması ile oluşan karmaşık sistemlerdir. YSA'lar, girişler (sistemin bağımsız değişkenleri) ile çıkışlar (bağımlı kestirimci değişkenler) arasında ilişki kuran karmaşık ve doğrusal olmayan modeller oluşturmaktadır [11]. YSA'lar 15 yıldan beri şekil sınıflamada kullanılmaktadır [5-9]. Bu konudaki çalışmaların artması ile farklı ağ yapıları ve eğitim algoritmaları üzerinde araştırmalar yapılmıştır [11-13]. Öğrenme için daha az veriye ihtiyaç duymalarından, hızlı işlem yapabilmelerinden ve gerçekleştirilmelerinin kolay olmasından dolayı çok katmanlı perseptron sinir ağlarının, YSA uygulamalarında önemli bir yeri vardır [11-13]. Bu çalışmada, hızlı ve şekil sınıflama problemlerinde başarılı olmalarından dolayı giriş katmanı, gizli katman ve çıkış katmanından oluşan çok katmanlı perseptron sinir ağı kullanılmıştır (Şekil 2). Çok katmanlı perseptronda gizli katmandaki j indisli her bir nöron, x_i giriş işaretini bağlantının ağırlığı w_{ji} ile çarptıktan sonra toplar ve y_j çıkışını toplamın fonksiyonu olarak şu şekilde hesaplar:

$$y_j = f\left(\sum w_{ji}x_i\right) \quad (8)$$

burada, f aktivasyon fonksiyonudur. Bu çalışmada, gizli katman ve çıkış katmanında aktivasyon fonksiyonu olarak kullanılan sigmoid fonksiyonu aşağıda verilmiştir:

$$f(\xi) = \frac{1}{1 + e^{-\xi}} \quad (9)$$

Sigmoid fonksiyonu doğrusal değildir ve ağ girişlerinin çıkış vektör uzaylarına karmaşık dönüşümünü yapabilmektedir. Ayrıca, sürekli bir fonksiyondur ve türevi alınabilmektedir. Böylece, ağırlıkların ayarlanmasında kullanılan hatanın



Şekil 2. Çok katmanlı perseptron sinir ağı

gradyanı elde edilebilmektedir.

Çıkış nöronunun istenilen değeri ve gerçek değeri arasındaki farkın toplamının karesi E şu şekilde ifade edilir:

$$E = \frac{1}{2} \sum_j (y_{dj} - y_j)^2 \quad (10)$$

burada, y_{dj} j indisli çıkış nöronunun istenilen değeri ve y_j bu çıkış nöronunun gerçek değeridir. Çok katmanlı perseptron sinir ağı, ağıın çıkışındaki hatayı hesaplar ve hatayı azaltmak için nöronların ağırlıklarını yeniden düzenler. Her bir w_{ji} ağırlığının yeniden düzenlenmesinde ağırlıklara Δw_{ji} eklenir.

Δw_{ji} 'nin hesaplanması eğitim algoritmasına bağlıdır [11-13].

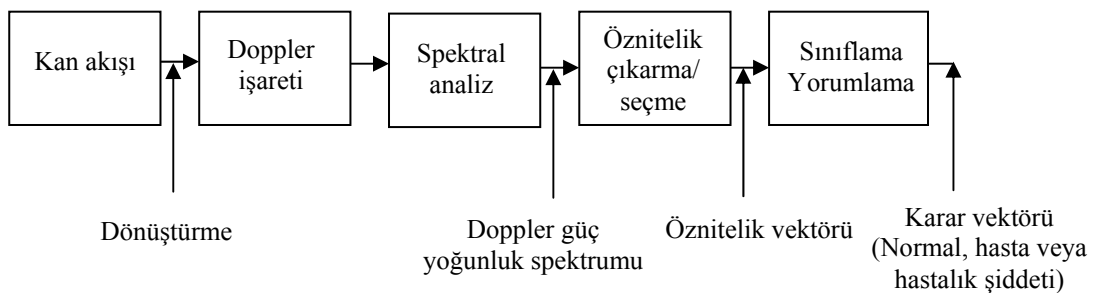
YSA'larda bilgi, nöronlar arasındaki bağlantıların ağırlıklarında yer almaktadır. Ağırlıkların değerlerinin ayarlanması ile sinir ağıının eğitimi yapılmaktadır. Bu nedenle, YSA'ların doğru sonuç vermesi ve yakınsama hızları açısından eğitim algoritması önemlidir. Çok katmanlı perseptron sinir ağlarının eğitimi için farklı eğitim algoritmaları geliştirilmiş olup geri yayılım algoritması en çok kullanılan algoritmadır [14]. Geri yayılım algoritmasında, çıkışta hesaplanan hata, çıkış katmanından gizli katmana ve giriş katmanına doğru geri yayıldığı için bu algoritma

geri yayılım algoritması olarak adlandırılmıştır. Geri yayılım algoritmasındaki her iterasyon iki işlemden oluşmaktadır: çözüme ulaşmak için ileri aktivasyon ve ağırlıkları yeniden düzenlemek için hesaplanan hatanın geriye doğru yayılımı. İleriye ve geriye doğru olan işlemler, YSA sonucu belirli toleranslar içerisinde istenilen sonuca ulaşmaya kadar tekrar edilir. Geriye doğru olan yayılımda ağırlıklar ayarlanır. Bununla birlikte, geri yayılım algoritmasının hata fonksiyonunun global minimumunu bulamaması ve yakınsama hızlarının düşük olması gibi bazı problemleri vardır. Bu yüzden, geri yayılım algoritmasının yakınsama hızını geliştirmek için delta-bar-delta, genişletilmiş delta-bar-delta, hızlı yayılım gibi algoritmalar üzerinde çalışılmıştır [14-17]. Son yıllarda, ikinci dereceden metotlar (birleşik gradyan, quasi-Newton, Levenberg-Marquardt) gibi optimizasyon metotları da YSA'ların eğitiminde kullanılmaya başlanmıştır. Levenberg-Marquardt algoritması, Gauss-Newton tekniği ve diğer ikinci dereceden metotların en iyi özelliklerini birleştirmekte ve onların birçok sınırlamalarından etkilenmemektedir. Özellikle, Levenberg-Marquardt algoritmasının yavaş yakınsama gibi bir problemi yoktur [7, 18, 19]. Çok katmanlı perseptron sinir ağlarının eğitim algoritmalarının karşılaştırılması ile ilgili birçok çalışma yapılmıştır [20-22]. Bu çalışmaların sonuçları, algoritmaların performanslarının çalışmakta olan probleme bağlı olduğunu göstermiştir. Bundan dolayı, bu çalışmada çok katmanlı perseptron sinir ağlarının eğitimi, geri yayılım, delta-bar-delta, genişletilmiş delta-bar-delta, hızlı yayılım ve Levenberg-Marquardt algoritmaları ile yapılmıştır.

5. DENEYSEL SONUÇLAR

5.1. AR ve ARMA Spektral Analiz Metotları ile Oftalmik Atardamar Doppler İşaretlerinden Öznitelik Çıkarma

Doppler işaretlerini ölçme ve teşhis sisteminde spektral analiz yer Şekil 3'te görülmektedir. Ultrasonik Doppler sistemleri ile elde edilen Doppler işareti ölçüm yapılan örnek hacim içerisindeki kan akışı ile ilgili birçok bilgiyi içermektedir. Klinik uygulamalarda kullanılan kan akışı ile ilgili birçok parametre güç yoğunluk spektrumlarından çıkarılabilir [2-4]. Güç yoğunluk spektrumlarının



Şekil 3. Doppler işaretlerini ölçme ve teşhis sisteminde spektral analiz yer

işaret hakkında genel bilgi vermesi ve hastalık durumunun belirlenmesi açısından kullanımı uygundur fakat çok fazla bilgi içerdiği için nicel kararlar verilmeden önce öznitelik çıkarma/seçme işlemi gerçekleştirilmelidir. Öznitelik vektörü değerlendirilerek yorumlama ve sınıflama işlemleri gerçekleştirilir [5-9].

Model tabanlı metotların (AR, MA, ARMA) spektral çözünürlükleri yüksektir ve bu metotların oluşturduğu spektrumlar ayrık değil, sürekli. AR metodunda doğrusal denklemlerin çözülmesi ile AR parametrelerinin kestirimleri kolaylıkla yapılabilir. AR denklemi, eşitlik 3'teki A polinomunun sıfırlarını birim çembere yakın yerleştirerek dar tepeleri bulunan spektrumların modellenmesini yapabilmektedir. Bu önemli bir özelliktir çünkü uygulamalarda dar bantlı spektrumlar ile daha fazla karşılaşmaktadır. Bundan dolayı, AR metodu Doppler işaretlerinin modellenmesinde en çok kullanılan spektral kestirim metodudur [2-4, 10]. MA metodunda, veri tüm-sıfır filtrenin çıkışı olarak modellenmektedir. Bundan dolayı, güç yoğunluk spektrumunun geniş tepeler ve/veya keskin çukurlar ile karakterize edildiği durumlarda MA metodu kullanılır. MA metodu, dar bantlı spektrumların kestiriminde yüksek çözünürlük sağlamamaktadır. Doppler işaretlerinin MA metodu ile spektral analizi sonucu düz güç yoğunluk spektrumları elde edildiği için bu metot Doppler işaretlerinin spektral analizi için uygun değildir [3, 4, 10]. Bu nedenle, bu çalışmada model tabanlı metotlardan AR ve ARMA metotlarının kullanımı ile Doppler işaretlerinin spektral analizi gerçekleştirilmiş ve güç yoğunluk spektrumları incelenmiştir. ARMA metodunda, veri kutup-sıfır filtrenin çıkışı olarak modellendiği için keskin tepeleri ve derin çukurları olan spektrumların kestirimlerinde ARMA metodu kullanılır. Veri genellikle gözlem gürültüsü ile bozulmaktadır ve bu durumlarda ARMA metodu en uygun metot olarak tespit edilmiştir. Bununla birlikte, AR parametrelerinin kestirimi doğrusal denklemlerin çözülmesi ile kolaylıkla yapılmaktadır fakat ARMA parametrelerinin kestirim metotları maksimum olabilirliğe bağlıdır ve doğrusal olmayan denklemlerin çözümü gerekmektedir. Bu yüzden, ARMA parametrelerinin kestirimi için alt optimal olan metotlar üzerinde durulmuştur [3, 4, 10].

Oftalmik atardamar Doppler işaretlerinin spektral analizi, en küçük kareler AR metodu (2. kısım) ve en küçük kareler değiştirilmiş Yule-Walker ARMA metodu (3. kısım) ile gerçekleştirilmiştir. Model tabanlı metotların derecelerinin belirlenmesi kritik bir konudur ve model derecesi verinin karakteristiğine bağlıdır. Model derecesinin düşük olarak seçilmesi durumunda daha düz bir spektrum elde edilirken model derecesinin büyük olarak seçilmesi durumunda ise yanlıcı tepelerin bulunduğu spektrum elde edilir. Bu çalışmada, Akaike bilgi kriteri [23] kullanılarak AR ve ARMA metotlarındaki model dereceleri 10

olarak belirlenmiştir.

Şekil sınıflama işlemini gerçekleştirecek olan bir sinir ağının oluşturulmasında, ağ girişlerinin seçimi oldukça önemlidir çünkü girişlerin doğru seçilmemesi durumunda en iyi sınıflayıcının başarısı bile düşük olacaktır. Giriş seçiminde şu faktörler dikkate alınır: 1) şeklin bileşenleri nelerdir? ve 2) şekli en iyi tanımlayan öznitelik kümesi nedir? Doppler güç yoğunluk spektrumları işaret hakkında önemli bilgi içerdiği için Doppler güç yoğunluk spektrum değerleri işareti temsil eden öznitelik vektörleri olarak ele alınmıştır. Çıkarılan öznitelik vektörlerinin boyutlarının azaltılabilmesi için Doppler güç yoğunluk spektrum değerleri üzerinde istatistiksel özellikler kullanılmıştır. Doppler işaretlerinin güç seviyesi-frekans dağılımını göstermekte kullanılan istatistiksel özellikler aşağıda verilmektedir:

1. Güç yoğunluk spektrum değerlerinin ortalaması.
2. Güç yoğunluk spektrum değerlerinin maksimumu.
3. Güç yoğunluk spektrum değerlerinin kuvvetlerinin ortalaması.
4. Güç yoğunluk spektrum değerlerinin standard sapması.
5. Güç yoğunluk spektrum değerlerinin bozulmasının dağılımı.

Özellik 1-3 işaretin frekans dağılımını gösterirken özellik 4, 5 frekans dağılımındaki değişim miktarını göstermektedir. Bu öznitelik vektörleri, oftalmik atardamar Doppler işaretlerinin sınıflandırılmasında çok katmanlı perseptron sinir ağlarının girişleri olarak seçilmiştir. Bu çalışmada, oftalmik atardamar Doppler işaretlerinin AR, ARMA metotları ile spektral analizinde ve AR, ARMA Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı çok katmanlı perseptron sinir ağlarının gerçekleştirilmesinde MATLAB program paketi kullanılmıştır.

5.2. Çok Katmanlı Perseptron Sinir Ağlarının Oftalmik Atardamar Doppler İşaretlerine Uygulanması

Göz muayeneleri 10 MHz'lik ultrasonik dönüştürücünün kullanıldığı analog Doppler cihazı (Diasonics Synergy marka renkli Doppler ultrasonografi) ile gerçekleştirilmiştir. Ölçme sistemi beş bloktan oluşmaktadır: (i) ultrasonik dönüştürücü, (ii) analog Doppler cihazı, (iii) kayıt cihazı (Sony), (iv) analog/sayısal ara birim kartı (Sound Blaster Pro-16 bit), (v) yazıcı ile bilgisayar. Ultrasonik dönüştürücü göz kapağına yerleştirilmeden önce göz kapağına metil selüloz sürülmüştür. Bu şekilde hava tabakası oluşması engellenmiş ve ultrasonik dalganın dokuya geçmesi sağlanmıştır. Oluşabilecek bozucu etkenlerden kaçınmak için göz kapağına basınç uygulanmamasına dikkat edilmiştir. Ultrasonik dönüştürücü, göz kapağına doğru 60°'lik açı ile

tutularak ölçüm yapılmıştır. Oftalmik atardamar Doppler işaretleri, 63'ü sağlıklı, 52'si oftalmik atardamar daralması, 54'ü Behçet hastası, 45'i üveit hastası olan 214 kişiden alınmıştır.

Çok katmanlı perseptron sinir ağlarında (Şekil 2) giriş ve çıkış katmanları arasındaki katmanlar, dış çevre ile etkileşimde olmadıkları için gizli katman olarak belirtilmektedirler. Doğrusal olmayan sınıflama problemlerinin çözümü açısından giriş katmanı ve çıkış katmanı arasına gizli katman veya katmanların yerleştirilmesi uygundur. YSA'ların mimarisi deneme yanılma yöntemi ile belirlenebilir ve sinir ağının karmaşıklığı gizli katmanların sayısına bağlıdır. Gizli katman sayısı az olan bir ağ karmaşık şekilleri ayırt etmede yetersiz kaldığı gibi gizli katman sayısı fazla olan ağ ise yeni uygulanan veri için genelleştirme yapamamaktadır. Ayrıca, gizli katman sayısının artırılması ile eğitim zamanı artmaktadır. Bu yüzden, YSA'ların doğru sonuç vermesi açısından uygun olan gizli katman sayısının belirlenmesi önemlidir. Oftalmik atardamar Doppler işaretleri için yapılan ağ mimarisi çalışmaları, giriş katman sayısı az olan ağ yapılarının genelleştirme özelliklerinin daha iyi olduğunu ve sınıflama doğruluklarının daha yüksek olduğunu göstermiştir. Bu uygulamada, bir gizli katmanlı çok katmanlı perseptron sinir ağı kullanılmıştır. Geliştirilen en uygun ağ mimarisinde gizli katmandaki nöron sayısı 10'dur. Ağın çıkış vektörleri şu şekilde tanımlanmıştır:


[0 0 0 1] = sağlıklı oftalmik atardamar
 [0 0 1 0] = oftalmik atardamarda daralma
 [0 1 0 0] = Behçet hastası
 [1 0 0 0] = üveit hastası

Ağın başarısı açısından ağın eğitimi ve testi için kullanılacak olan veri sayısının belirlenmesi önemlidir. Bu çalışmada, 214 kişiden oluşan veri tabanından 80'i ağın eğitimi için geriye kalanı ise ağın testi için kullanılmıştır. Ağın daha iyi genelleme yapmasını sağlamak için eğitimde kullanılan 80 kişiden 16 kişiye ait olan veri geçerlilik verisi olarak kullanılmıştır. Ağın eğitimi için kullanılan veri, 20 sağlıklı, 20 oftalmik atardamar daralması, 20 Behçet hastası ve 20 üveit hastası olan kişiden oluşmaktadır. Ağın testi için kullanılan veri, 43 sağlıklı, 32 oftalmik atardamar daralması, 34 Behçet hastası ve 25 üveit hastası olan kişiden oluşmaktadır.


Oftalmik atardamar Doppler işaretlerinin güç yoğunluk spektrumları AR ve ARMA metotları ile elde edilmiştir. Her bir oftalmik atardamar Doppler işaretine ait olan güç yoğunluk spektrumlarının 129 güç seviyesi bulunmaktadır. Çıkarılan öznitelik vektörlerinin boyutunu azaltmak için 5.1 kısmında açıklanan istatistiksel özellikler kullanılmıştır. Böylece çok katmanlı perseptron sinir ağlarının giriş sayısı 5 (öznitelik vektörünün boyutu) olmuştur. Sağlıklı, oftalmik atardamar daralması, Behçet hastası

ve üveit hastası olan kişilerden alınan Doppler işaretlerinin AR ve ARMA metotları ile elde edilen ortalama güç yoğunluk spektrumları Şekil 4 ve 5'te verilmektedir. Bu şekillerden görüldüğü gibi, sağlıklı, oftalmik atardamar daralması, Behçet hastası ve üveit hastası olan kişilere ait olan Doppler güç yoğunluk spektrumları farklıdır. Bu durum, oftalmik atardamar Doppler işaretlerinden öznitelik çıkarmak için Doppler güç yoğunluk spektrumlarının kullanımının uygunluğunu göstermektedir. AR (Şekil 4) ve ARMA (Şekil 5) metotları ile elde edilen spektrumlardaki tepelerin güç seviyelerinin ve frekanslarının benzer olduğu görülmektedir.

Bu uygulama için geliştirilen AR ve ARMA Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı çok katmanlı perseptron sinir ağları, beş farklı algoritma ile eğitilmiş ve yakınsama hızları (eğitim iterasyonlarının sayısı), ortalama karesel hataları ve toplam sınıflama doğruluklarına göre performansları



Şekil 4. Sağlıklı, oftalmik atardamar daralması, Behçet hastası ve üveit hastası olan kişilerden alınan Doppler işaretlerinin AR metodu ile elde edilen ortalama güç yoğunluk spektrumları



Şekil 5. Sağlıklı, oftalmik atardamar daralması, Behçet hastası ve üveit hastası olan kişilerden alınan Doppler işaretlerinin ARMA metodu ile elde edilen ortalama güç yoğunluk spektrumları

değerlendirilmiştir. Ortalama karesel hata, eğitim iterasyonları boyunca ağın çıkışı ile istenilen sonuç arasındaki farkın karesini gösterir. Ağın fazla eğitilmesi durumunda ağın genelleştirme yapması zorlaşır. Bu çalışmada, ağın eğitimini durdurmak için geçerlilik kriteri kullanılmıştır. Geçerlilikteki hatanın artması durumunda iyi bir genelleştirme elde edilebilmek için ağın eğitimi durdurulmuştur. Doğru sınıflandırılan kişi sayısının toplam kişi sayısına oranı olan toplam sınıflama doğruluğu, ağ girişi olarak kullanılan öznitelik vektörlerine bağlıdır. Oftalmik atardamar Doppler işaretlerinin sınıflandırılması için geliştirilen, AR ve ARMA Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı, beş farklı algoritma ile eğitilen çok katmanlı perseptron sinir ağlarının eğitim iterasyonlarının sayısı, ortalama karesel hataları ve toplam sınıflama doğrulukları sırası ile Tablo 1 ve 2'de verilmektedir. Tablo 1 ve 2'den görüldüğü gibi, ARMA Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı çok katmanlı perseptron sinir ağının sınıflama doğruluğu ve yakınsama hızı AR Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı çok katmanlı perseptron sinir ağına göre kısmen yüksektir. Ayrıca, bu tablo değerleri incelendiğinde Levenberg-Marquardt algoritması ile eğitilen çok katmanlı perseptron sinir ağlarının sınıflama doğruluklarının ve yakınsama hızlarının diğer algoritmalar ile eğitilen ağlarınkinden daha yüksek olduğu görülmektedir.

Ağ mimarisindeki gizli katman sayısının sınıflama doğruluğuna olan etkisini incelemek için Levenberg-Marquardt algoritması ile eğitilen, AR ve ARMA Doppler güç yoğunluk spektrum değerlerinden

çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı çok katmanlı perseptron sinir ağları üzerinde denemeler yapılmıştır. Bir gizli katmanlı ağ mimarisinden başka iki, dört ve altı gizli katmanlı olan ağ mimarileri üzerinde çalışmalar yürütülmüştür. AR ve ARMA Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı çok katmanlı perseptron sinir ağları için farklı ağ mimarileri ile elde edilen toplam sınıflama doğrulukları sırası ile Şekil 6 ve 7'de verilmektedir. Bir ve iki gizli katmanlı olan ağ mimarilerinin diğerlerine göre daha yüksek sınıflama doğruluğu olduğu tespit edilmiştir. Ayrıca, bir gizli katmanlı olan ağın sınıflama doğruluğundan daha yüksek olduğu görülmektedir. Bundan dolayı, bu uygulama için bir gizli katmanlı olan çok katmanlı perseptron sinir ağı kullanılmıştır.

6. SONUÇLAR

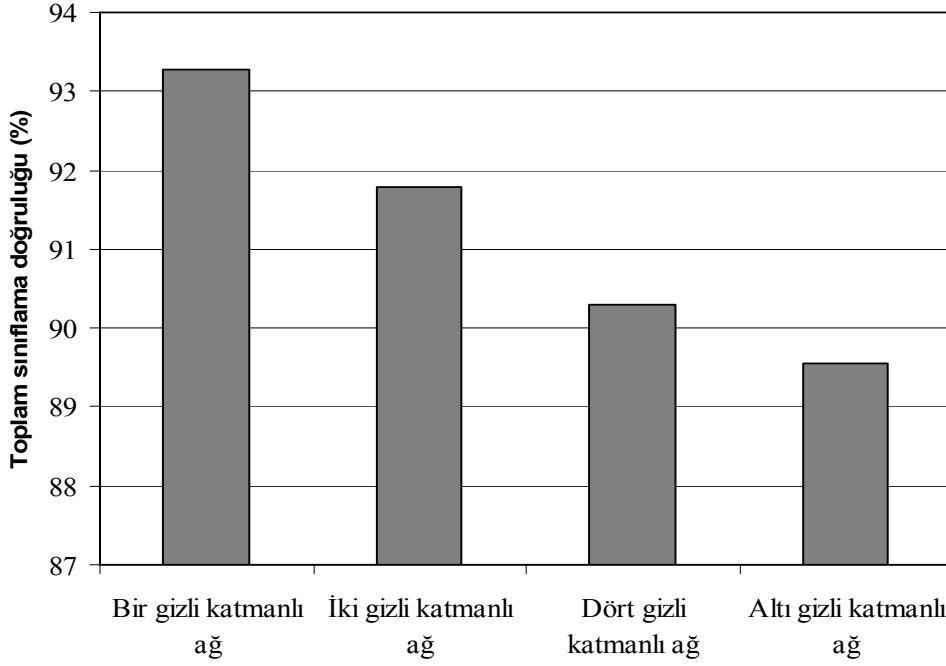
Oftalmik atardamar Doppler işaretlerinin spektral analizi, en küçük kareler AR metodu ve en küçük kareler değiştirilmiş Yule-Walker ARMA metodu ile gerçekleştirilmiştir. AR ve ARMA metotları ile elde edilen Doppler güç yoğunluk spektrumlarının spektral karakteristiklerinin benzer olmasına rağmen ARMA Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı çok katmanlı perseptron sinir ağının sınıflama doğruluğu ve yakınsama hızı AR Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı çok katmanlı perseptron sinir ağına göre kısmen yüksektir. Levenberg-Marquardt algoritması ile eğitilen çok katmanlı perseptron sinir ağlarının sınıflama doğrulukları ve yakınsama hızları geri yayılım, delta-

Tablo 1. AR Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı ve beş farklı algoritma ile eğitilen çok katmanlı perseptron sinir ağının eğitim iterasyonlarının sayısı, ortalama karesel hataları ve toplam sınıflama doğrulukları

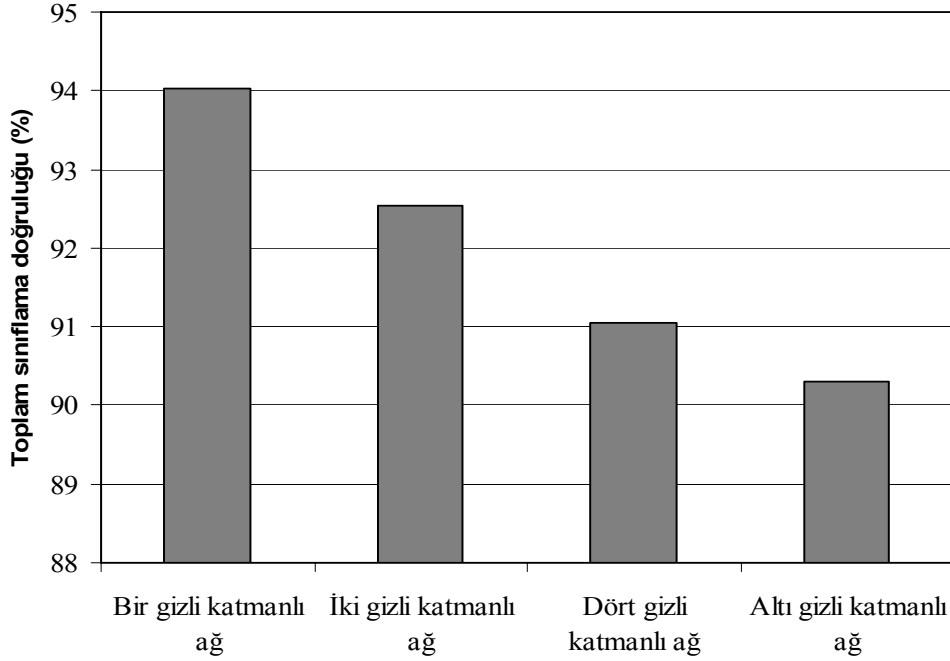
Eğitim algoritmaları	Eğitim iterasyonlarının sayısı	Ortalama karesel hataları	Toplam sınıflama doğrulukları (%)
Geri yayılım	4500	0.00065	88.81
Delta-bar-delta	3700	0.00054	89.55
Genişletilmiş delta-bar-delta	3000	0.00047	90.30
Hızlı yayılım	1800	0.00032	91.04
Levenberg-Marquardt	1000	0.00021	93.28

Tablo 2. ARMA Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı ve beş farklı algoritma ile eğitilen çok katmanlı perseptron sinir ağının eğitim iterasyonlarının sayısı, ortalama karesel hataları ve toplam sınıflama doğrulukları

Eğitim algoritmaları	Eğitim iterasyonlarının sayısı	Ortalama karesel hataları	Toplam sınıflama doğrulukları (%)
Geri yayılım	4200	0.00052	89.55
Delta-bar-delta	3400	0.00041	90.30
Genişletilmiş delta-bar-delta	2800	0.00033	91.79
Hızlı yayılım	1500	0.00024	92.54
Levenberg-Marquardt	800	0.00015	94.03



Şekil 6. Levenberg-Marquardt algoritması ile eğitilen, AR Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı farklı mimarileri olan çok katmanlı perseptron sinir ağlarının toplam sınıflama doğrulukları



Şekil 7. Levenberg-Marquardt algoritması ile eğitilen, ARMA Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı farklı mimarileri olan çok katmanlı perseptron sinir ağlarının toplam sınıflama doğrulukları

bar-delta, genişletilmiş delta-bar-delta ve hızlı yayılım algoritmaları ile eğitilen ağlarınkinden daha yüksektir. Sonuç olarak, Levenberg-Marquardt algoritması ile eğitilen ve ARMA Doppler güç yoğunluk spektrum değerlerinden çıkarılan öznitelik vektörlerinin giriş olarak kullanıldığı çok katmanlı perseptron sinir ağının oftalmik atardamar Doppler işaretlerinin sınıflandırılmasında en yüksek performansa sahip olduğu tespit edilmiştir.

KAYNAKLAR

1. Güler, İ. ve Güler, N.F., "The electronic detail of a pulsed Doppler blood flow measurement system", **Measurement Science and Technology**, Vol 1, No 10, 1087-1092, 1990.
2. Güler, İ., Hardalaç, F. ve Übeyli, E.D., "Determination of Behcet disease with the application of FFT and AR methods",

- Computers in Biology and Medicine**, Vol 32, No 6, 419-434, 2002.
3. Güler, İ. ve Übeyli, E.D., "Application of classical and model-based spectral methods to ophthalmic arterial Doppler signals with uveitis disease", **Computers in Biology and Medicine**, Vol 33, No 6, 455-471, 2003.
 4. Übeyli, E.D. ve Güler, İ., "Spectral analysis of internal carotid arterial Doppler signals using FFT, AR, MA, and ARMA methods", **Computers in Biology and Medicine**, Vol 34, No 4, 293-306, 2004.
 5. Güler, İ. ve Übeyli, E.D., "Detection of ophthalmic artery stenosis by least-mean squares backpropagation neural network", **Computers in Biology and Medicine**, Vol 33, No 4, 333-343, 2003.
 6. Übeyli, E.D. ve Güler, İ., "Neural network analysis of internal carotid arterial Doppler signals: predictions of stenosis and occlusion", **Expert Systems with Applications**, Vol 25, No 1, 1-13, 2003.
 7. Güler, N.F. ve Übeyli, E.D., "Wavelet-based neural network analysis of ophthalmic artery Doppler signals", **Computers in Biology and Medicine**, 2004 (baskıda).
 8. Güler, İ. ve Übeyli, E.D., "Detection of ophthalmic arterial Doppler signals with Behcet disease using multilayer perceptron neural network", **Computers in Biology and Medicine**, 2004 (baskıda).
 9. Güler, İ. ve Übeyli, E.D., "Classification of internal carotid arterial Doppler signals using wavelet-based neural networks", **IJCI Proceedings of International XII. Turkish Symposium on Artificial Intelligence and Neural Networks – TAINN 2003**, Çanakkale, Cilt 1, No 1, 8-12, Temmuz 2003.
 10. Kay, S.M. ve Marple, S.L., "Spectrum analysis – A modern perspective", **Proceedings of the IEEE**, 69, 1380-1419, 1981.
 11. Haykin, S., **Neural Networks: A Comprehensive Foundation**, Macmillan, New York, 1994.
 12. Basheer, I.A. ve Hajmeer, M., "Artificial neural networks: fundamentals, computing, design, and application", **Journal of Microbiological Methods**, Vol 43, No 1, 3-31, 2000.
 13. Chaudhuri, B.B. ve Bhattacharya, U., "Efficient training and improved performance of multilayer perceptron in pattern classification", **Neurocomputing**, Vol 34, 11-27, 2000.
 14. Rumelhart, D.E., Hinton, G.E. ve Williams, R.J., "Learning representations by back-propagating errors", **Nature**, Vol 323, 533-536, 1986.
 15. Jacobs, R.A., "Increased rate of convergence through learning rate adaptation", **Neural Networks**, Vol 1, 295-307, 1988.
 16. Minai, A.A. ve Williams, R.D., "Back-propagation heuristics: a study of the extended delta-bar-delta algorithm", **Proceedings of International Joint Conference on Neural Networks**, San Diego, California, Cilt 1, 595-600, 17-21 Haziran 1990.
 17. Fahlman, S.E., "An empirical study of learning speed in backpropagation networks", **Computer Science Technical Report**, CMU-CS-88-162, Carnegie Mellon University, Pittsburgh, 1988.
 18. Hagan, M.T. ve Menhaj, M.B., "Training feedforward networks with the Marquardt algorithm", **IEEE Transactions on Neural Networks**, Vol 5, No 6, 989-993, 1994.
 19. Battiti, R., "First- and second-order methods for learning: between steepest descent and Newton's method", **Neural Computation**, Vol 4, 141-166, 1992.
 20. Chan, L-W., "Efficacy of different learning algorithms of the back propagation network", **IEEE Region 10 Conference on Computer and Communication Systems**, Hong Kong, Cilt 1, 23-27, 24-27 Eylül 1990.
 21. Sidani, A. ve Sidani, T., "A comprehensive study of the backpropagation algorithm and modifications", **IEEE Conference Record**, Orlando FL USA, 80-84, 29-31 Mart 1994.
 22. Hannan, J.M. ve Bishop, J.M., "A comparison of fast training algorithms over two real problems", **IEE Fifth International Conference on Artificial Neural Networks**, Conference Publication No 440, Cambridge UK, 1-6, 7-9 Temmuz 1997.
 23. Akaike, H., "A new look at the statistical model identification", **IEEE Transactions on Automatic Control**, Vol AC-19, 716-723, 1974.